



ESA tabanlı göz durumu tespitinde görüntü ön işleme yöntemlerinin etkisi

The effect of image preprocessing methods in CNN-based eye state detection

İsmail Kayadibi^{1,*} , Gür Emre Güraksın² , Uçman Ergün³ 

^{1,3} Afyon Kocatepe Üniversitesi, Biyomedikal Mühendisliği Bölümü, 03204, Afyonkarahisar, Türkiye

² Afyon Kocatepe Üniversitesi, Bilgisayar Mühendisliği Bölümü, 03204, Afyonkarahisar, Türkiye

Öz

Bu çalışma göz kırpma, göz yorgunluğu, sürücü uyusukluğu gibi temel problemlerin çözümlenmesinde önemli olan göz durumu tespitine odaklanmaktadır. Bu çalışmada, göz durumu tespiti için görüntü ön işleme yöntemleri ve derin öğrenme tabanlı evrişimsel sinir ağına (ESA) dayanan bir yöntem önerilmiş ve önerilen yöntem ZJU veri seti üzerinde performansı test edilmiştir. Ayrıca, önerilen ESA modelinde farklı havuzlama katmanları değerlendirilmiş ve ZJU veri seti üzerinde elde edilen bulgulara ortalama havuzlama kullanılan önerilen ESA modelinin en iyi performansı elde ettiği görülmüştür. Sonrasında, ZJU veri setine görüntü ön işleme yöntemleri uygulanmış ve işlenmiş ZJU veri seti, önerilen ESA modelinde eğitilerek performansları karşılaştırılmıştır. Elde edilen sonuçlara göre histogram eşitleme yöntemi kullanılarak eğitimi gerçekleştirilen ESA modelinin ZJU veri setinde %94.32 doğruluk, %94.95 duyarlılık, %92.42 özgüllük, %97.41 kesinlik ve %96.16 F1 skor performans metrikleri ile üstün bir başarı elde ettiği görülmüştür. Bu çalışmada elde edilen sonuçlar, ZJU veri setinde yapılan önceki çalışmalarda sunulan performans metrikleri ile karşılaştırılmıştır. Önerilen yöntemin literatür ile karşılaştırıldığında, göz durumu tespitinde güçlü sınıflandırma performansına sahip olduğu tespit edilmiştir.

Anahtar kelimeler: Derin öğrenme, Evrişimsel sinir ağı, Histogram eşitleme, Göz durumu tespiti

1 Giriş

Göz durumu, önemli bir yüz özelliği olmanın yanı sıra fizyolojik ve psikolojik durumların değerlendirilmesi için gerekli kriterlerden biridir. Bu yüzden son zamanlarda göz durumlarının tanımlanması, bilgisayar görme alanında popüler bir araştırma alanı olmuş ve görüntü analizi bakımından en başarılı uygulamalardan biri haline gelmiştir [1]. Ayrıca göz durumunun tespiti, güvenlik uygulamaları, insan-makine etkileşimleri vb. konularda geniş potansiyele sahip bir kullanım alanı oluşturmaktadır.

Göz durumu, göz kırpma tespiti [2] ve göz yorgunluğunun algılanması [3] için geliştirilen bilgisayar görme sistemlerinde kullanılan temel parametrelerden birisi olmuştur. Ancak, göz durumunun tespitinde, aydınlatma vb. çevresel faktörler ve kişinin ten rengi, yüz ifadesi, uzun saçlı olması ve gözlük kullanması gibi kişiye göre değişken durumlar zorluklar yaratabilir [4]. Bu konuda son yirmi yılda

Abstract

This research investigates how eye state detection is used to overcome simple problems including blinking, eyestrain, and driving drowsiness. The study utilized the ZJU dataset, and it suggested an eye state recognition approach based on image preprocessing methods and a deep learning-based convolutional neural network (CNN). First, multiple pooling layers were tested in the suggested CNN model, and it was discovered that the average pooling performed the best in the results. The image preprocessing methods applied on the ZJU dataset were then trained on the proposed CNN model and their results have been compared. The CNN model performed exceptionally well on the ZJU dataset, according to a comparison of the results obtained using the histogram equalization method, with 94.32% accuracy, 94.95% sensitivity, 92.42% specificity, 97.41% precision, and 96.16% F1 score performance metrics. The results of this investigation were compared to prior studies on the ZJU dataset, which had provided performance measures. When compared to the literature, it was obtained that the proposed technique has a high classification performance in detecting vision problems.

Keywords: Deep learning, Convolutional neural network, Histogram equalization, Eye state detection

çok ilerleme kaydedilmiş ve sayısız yüz tanıma algoritması [5] geliştirilmiştir.

Teknolojideki son gelişmeler doğrultusunda dijital ekranların uzun süre kullanılması, kuru göz ve bilgisayarlı görme sendromunda artışa yol açmıştır. Bu sendromun göz kırpma sayısı ile ilişkili olduğu kanıtlanmış ve bu nedenle son yıllarda göz kırpma tespiti konusu araştırmacıların dikkatini çekmiştir [6-8]. Ek olarak göz kırpmasının algılanması, sürücü uyusukluk sistemlerinin gelişiminde de önemli rol oynamaktadır [9]. Bu kaçınılmaz gerçekler ve gelişmeler doğrultusunda göz durumu tespiti konusunda araştırmacılar, hem insan-bilgisayar etkileşimi tasarımlarının gelişimi hem de yatağa bağımlı engellilerin yaşam kalitesinin artırılmasını amaç edinmiş ve bilgisayarlı görü yöntemlerinin etkin kullanımını içeren birçok çalışma yapmıştır [10-11].

* Sorumlu yazar / Corresponding author, e-posta / e-mail: i.kayadibi026@gmail.com (İ. Kayadibi)

Geliş / Received: 11.03.2022 Kabul / Accepted: 29.04.2022 Yayımlanma / Published: 18.07.2022

doi: 10.28948/ngumuh.1086414

Sürücü sersemliği (uykusuzluk, yorgunluk, dikkatsizlik vb.) de göz durumuyla doğrudan ilişkili ve ölüme sonuçlanan araç kazalarının yaygın nedenlerinden biridir. Sürücü sersemliği tespit etmek, gelecekteki otonom sistemlerin ayrılmaz bir parçası olabilir. Sürücü uyuşukluğu fizyolojik, araç temelli ve davranışsal olmak üzere üç kategoride incelenen çeşitli ölçüm yöntemleri kullanılarak tespit edilebilir [3]. Fizyolojik ölçümler, sürücüye yerleştirilen hassas elektrotlardan veya elektronik cihazlardan elde edilen elektrokardiyogram (EKG), elektroensefalogram (EEG) ve elektrookülogram (EOG) gibi fizyolojik sinyalleri içerir. Ancak fizyolojik ölçümler sürücüyü kısıtladığı için yaygın olarak kullanılmamaktadır. Araç kontrol ekipmalarının (direksiyon simidi, şerit izleme ve fren düzenlemeleri) izlenmesi, sürücü becerilerine ve yol kalitesine aşırı bağımlılık nedeniyle düşük güvenilirliğe sahip, invazif olmayan başka bir uyuşukluk algılama yöntemidir. Davranışsal yöntemler, araçtan çok kişiye odaklandıkları için fizyolojik ve araç temelli yöntemlere göre daha güvenilirdir. Yorgunluğu teşhis etmek için videoya kaydedilmiş görsel özellikleri kullanan ve sürücünün hareketini, yüz ifadesini, göz durumunu ve göz kırpma durumunu analiz eden bilgisayarlı görüş sistemlerine dayanırlar. Davranışsal yöntemler, müdahalesiz ve sürücü odaklı oldukları için son zamanlarda popüler olmuştur [12].

Göz durumunun tespitinde sıklıkla kullanılan özellik tabanlı, görünüm tabanlı ve hareket tabanlı olmak üzere üç tür algılama yöntemi vardır. Özellik tabanlı yöntemler geometrik özellikleri ve gri seviyeli desenleri kullanır. Harekete dayalı yöntemler, göz kapağı hareketinin özelliklerine odaklanır. Görünüme dayalı yöntemler, göz bölgesinin dokusal özelliklerini içerir. Deneysel sonuçlar, görünüme dayalı yöntemlerin diğer yöntemlerden daha iyi performans gösterdiğini belirtmektedir [13].

Son yıllardaki bilgi işlem, depolama ve insan-bilgisayar etkileşimi teknolojilerinin gelişmesiyle birlikte yapay zekâ tekniklerinden özellikle derin öğrenme yöntemi, birçok alanda problemlerin çözümünde üstün performanslar göstermiş ve farklı (eşsiz) senaryoları etkili bir şekilde tanımlayabilen öğrenme algoritmalarına sahip olduğunu kanıtlamıştır. Derin öğrenme (DL), bir makine öğrenmesi alt dalıdır ve insan beyninin sinir sistemine benzer özellik göstererek, yapısında birden çok katmana sahip sinir ağları içermektedir [14].

DL, karmaşık veri kümelerindeki karmaşık yapıları keşfetmek için geri yayılım algoritmasını kullanır. Bu algoritma, bir makinenin DL katmanında bir önceki katman üzerinden temsilini hesaplamak için dahili parametrelerini nasıl değiştirmesi gerektiğini gösterir. Son zamanlarda DL konuşma tanıma, nesne tanıma ve algılama vb. birçok alanda en son teknolojiyi önemli ölçüde geliştirmiştir [14]. DL modelleri bünyesinde birçok derin katmanlar barındırır. Bu çoklu derin katman eğitimini içeren popüler bir DL yöntemi de ESA'dır [29]. ESA, yapay zekada kullanılan etkili bir yöntemlerden biri olmuştur.

Tipik bir ESA, çok katmanlı ve ileri beslemeli bir sinir ağı olarak da bilinir. İleri beslemeli ağlardan farklı olarak, ESA temel yapısı birkaç evrişim ve alt örnekleme katmanları, tam bağlı katman, softmax katmanı ve

sınıflandırma katmanlarından oluşmaktadır. Bu yapı, görüntüleri veya herhangi bir iki boyutlu veriyi işlemek için modellenmiştir. ESA'lar bu işlemleri gerçekleştirmek için yerel bağlantıları kullanır ve daha az parametre ayarı yapılmasını sağlayarak eğitim sürecini azaltır [30].

DL, ham verilerin temsili özelliklerini çıkardıktan sonra tüm düşük seviyeli özellikleri birleştirerek yüksek seviyeli soyut bir temsili otomatik oluşturabilir. Bu yüzden, son zamandaki gelişmeler ışığında ham verilerden temsili özelliklerin manuel olarak çıkartılmasına gerek yoktur. Ancak göz durumu tanıma göz yorgunluğu için bilgisayarlarda, sürücü uyuşukluğu tespiti için araçlarda ve göz kırpma veya yüz ifadesi tespitlerinde insan bilgisayar etkileşimi içeren cihazlarda olmak üzere birçok ortam ve donanımlarda kullanıldığı için son on yılda insan gözünün durumunun tanımlanmasında çeşitli yaklaşımlar önerilmiştir.

Dong vd. göz durumu tanımlanması için çeşitli özellik çıkartma yöntemlerinden elde ettiği özellik setlerini rastgele orman, rastgele eğreltiler ve destek vektör makinesi yöntemleri ile sınıflandırmışlardır. Bu sınıflandırmalar sonucunda histogram yönelimli gradyanın sınıflandırma amacıyla gürültü etkisine karşı daha az etkilendiğini ve yaklaşımlarının %93'e varan başarı oranına ulaştığını bildirmişlerdir [12].

Pauly ve Sankar göz kırpma algılamak için düşük çözünürlüklü göz görüntülerini içeren farklı özellikler (ortalama yoğunluk, Fisher yüzleri ve yönlendirilmiş gradyanların histogram (HOG) özelliği) ile destek vektör makinesi (DVM) ve yapay sinir ağı (ANN) gibi sınıflandırıcılar kullanmışlardır. Çalışmada kullanılan beş farklı yöntemin karşılaştırmalı sonucunda, HOG'dan elde edilen özelliklerin DVM sınıflandırıcı ile kullanımının çalışmada kullanılan diğer yöntemlerden daha iyi performans gösterdiğini ifade etmişlerdir [15].

Pauly and Sankar web kameralarından elde edilen video karelerinde göz takibi ve göz kırpma tespiti için bir yöntem önermişlerdir. Bu yöntem göz takibinde haar-cascade sınıflandırıcıyı ve göz kırpma tespitinde ise DVM sınıflandırıcı ile HOG özelliklerinin bir kombinasyonunu içermektedir. Göz kırpma tespiti için önerilen yöntemleri, iki halka açık veri setinden alınan görüntülerde test etmişler ve ortalama %92.5 doğruluk oranı elde etmişlerdir [16].

Han vd. akıllı telefon platformlarında göz kırpma tespiti veya göz takibi için iki makine öğrenimi tekniğini (DVM ve ESA) birleştiren hibrit bir yaklaşım önermişlerdir. Ayrıca önerilen hibrit yöntem alternatif olarak çok sınıflı DVM kullanmışlar ve hibrit yöntem ile karşılaştırmışlardır. Göz kırpma algılamak için önerilen yöntemlerin karşılaştırmasında LeNet-5 ESA modelinin, çok sınıflı SVM yöntemi ve diğer yöntemlerden daha iyi performans gösterdiğini ifade etmişlerdir. Ek olarak, HOG özelliklerine sahip doğrusal SVM sınıflandırıcı ve LeNet-5 ESA modelinin göz kırpma algılamak için mobil ortamlarda verimli ve güvenilir bir şekilde kullanılabileceğini belirtmişlerdir [17].

Lee vd. yüz ve göz bölgelerini algılamak için hem AdaBoost yüz dedektörü hem de Lucas-Kanade-Tomasi (LKT) yöntemini kullanmışlardır. Bu yöntemler ile

bölgelerin belirlenmesinin ardından göz bölgelerinin genişlik ve yükseklik özelliklerini, DVM sınıflandırıcısında gözün açık veya kapalı olarak belirlenmesinde kullanarak özellik tabanlı bir yaklaşım önermişlerdir [18].

Zhao vd. göz durumunun tanımlanması için göz bölgesindeki yararlı bilgilere göre sınıflandırmaya dayanan derin entegre sinir ağı önermişlerdir. Bu entegre sinir ağında eğitim tiplerini değiştirerek birçok kombinasyon denemişler ve transfer öğrenme ve veri artırımına ile, küçük veri kümelerinde sınıflandırma yeteneğinin artırılmasına imkân sağlayarak yüksek başarıma ulaştıklarını raporlamışlardır [13].

Wu vd. sürücü uyuşukluğunu algılamak için Local Binary Pattern (LBP) yöntemini kullanarak özellik tabanlı DVM sınıflandırıcı yöntemini önermişlerdir. Deneysel sonuçların değerlendirilmesinde bu yöntemin göz durumu tanıma ve sürücü uyuşukluğunun etkili bir şekilde tespit etmek için kullanılabileceğini belirtmişlerdir [19].

Göz durumu tespiti, birçok alanda etkinliği olduğundan çeşitli gerçek dünya ortamlarıyla karşılaşmaktadır. Bu ortamların görüntü kalitesi değişken olabilmesinden dolayı, göz durumunun tespiti zorlaşabilmektedir [15]. Yapay zekâ destekli sistemlerde, görüntülerin kalitesi sistemin doğruluğuna etki edebilmektedir. Bu yüzden, göz durumu tespitinde, geliştirilen sistemlerin her ortama uygunluğunun sağlanabilmesi için görüntü işleme yöntemlerinin kullanılması önemlidir.

Görüntü önileme yöntemleri, görüntünün elde edilmesi sırasında maruz kalınan gürültü veya donanımdan kaynaklanan gürültüleri gidermek veya iyileştirmek için kullanılmaktadır. Son zamanlarda, farklı bilim alanlarında görüntülerin iyileştirilmesi ve tıbbi görüntü işleme alanında daha iyi yorumlamalar yapmak için görüntü önilemleri kullanılmaktadır [21]. Medikal, uydu görüntüleri vb. analiz gerektiren tüm alanlarda görüntü iyileştirme kullanılmaktadır. Görüntü iyileştirme aslında bir görüntünün bir başka görüntüye dönüşümüdür.

Birçok uygulamada renkli görüntülerin gri seviyeye dönüştürülmesi önemli adımlardan birisidir. Görüntünün gri seviyeye dönüşümü monokrom baskıda, tek kanallı görüntü işleme ve stilizasyonda yaygın olarak kullanılan bir görüntü önileme uygulamasıdır [22]. Renkli bir görüntünün gri seviyeye dönüştürülmesinde kırmızı, mavi ve yeşil kanallarının ağırlıklı toplamı alınarak dönüşüm sağlanır.

Son zamanlarda yapay zekanın gelişimi, derin öğrenme yöntemlerinin ortaya çıkışı ve gelişmelerin artması görüntü sınıflandırılmasında yeni yöntemlerin gelişmesine ve fikirlerin oluşmasına olanak sağlamıştır. Makine öğrenmesi alt dallarından biri olan derin öğrenme, özellikle ESA'nın görüntü sınıflandırma üzerindeki üstün performansı, görüntü tabanlı birçok uygulama alanında önemli bir etki yaratmıştır [14]. ESA, geleneksel makine öğrenmesi yöntemlerinden farklı olarak çok katmanlı yapısında, ham verilerden kendisi temsili öğrenme sağladığı için dikkatli mühendislik ve uzmanlık gerektirmez. Bu sebeple ESA'lar yüksek boyutta kapasiteye sahip görüntü ve özellik vektörleri içeren ham verilerde, özellikle görüntü tanıma ve konuşma tanımda üstün başarılar elde etmiştir. Bu yüzden göz durumu tanımda önceki çalışmalarda kullanılan el yapımı

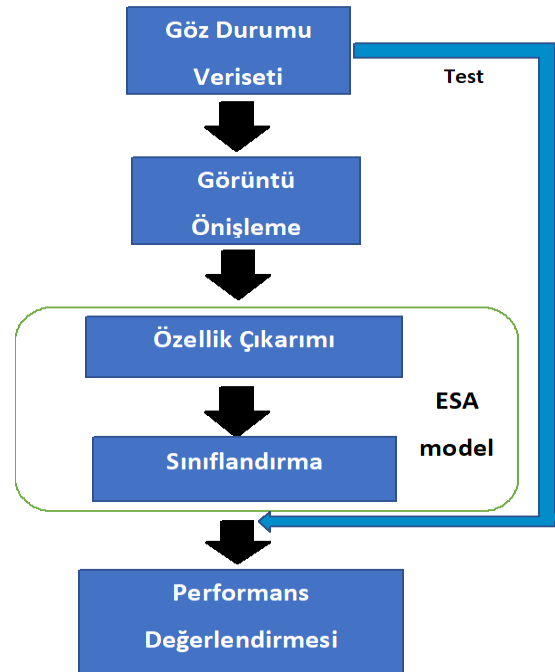
özellik çıkartma yöntemleri yerine ESA yönteminin kullanılması, özellik çıkarımında ve sınıflandırılmasında hem hız hem de kullanım kolaylığı açısından farkındalık yaratmaktadır.

Bu çalışmada göz durumu tespitinde görünüme dayalı yöntem esas alınmıştır. Bu amaçla göz durumu tespiti için derin öğrenmeye dayanan bir ESA modeli önerilmiştir. Bu model, ZJU veri setinde eğitilerek performansı değerlendirilmiş ve yapısında değişiklikler yapılarak en başarılı model elde edilmiştir. Ayrıca, önerilen ESA modeli üzerinde veri setine farklı görüntü önileme yöntemleri uygulayarak model üzerinde önileme etkisi araştırılmıştır. Sonuç olarak, bu çalışmada, performans değerlendirilmesi için kullanılan veri setinde en başarılı model önerilmiş ve bu veri seti üzerinde en yüksek performansa sahip önileme yöntemi belirlenmiştir.

Makalenin organizasyonu şu şekilde yapılandırılmıştır: ilk olarak materyal ve metod başlığı altında çalışmanın akış diyagramı, görüntü önileme yöntemleri, önerilen ESA modeli ve halka açık göz kırpması veri seti tanıtılmıştır. Ardından deneysel bulgular ve tartışma başlığında önerilen yöntemin performansını değerlendirmek için gerçekleştirilen deneysel sonuçlardan bahsedilmiştir. Son olarak da sonuçlar bölümünde deneysel çalışmalardan elde edilen bulguların analiz sonuçlarına yer verilmiştir.

2 Materyal ve metod

Bu çalışmada, göz durumu tespiti için görüntü ön işleme ve ESA modeline dayanan bir yöntem önerilmiştir. Önerilen yöntemin akış diyagramı Şekil 1'de verilmiştir.



Şekil 1. Akış diyagramı

Önerilen yöntem, bir göz durumu veri seti üzerinde değerlendirilmiştir. Bu yüzden öncelikle göz durumu veri setine önileme aşamaları uygulandıktan sonra önerilen ESA


modelinin eğitimi (özellik çıkarımı ve sınıflandırma) gerçekleştirilerek görüntü önışlem yöntemlerinin etkisi incelenmiştir. Son olarak ise, görüntü önışlem ile elde edilen ESA modellerinin performans değerlendirmeleri yapılarak en yüksek performansa sahip ESA modeli belirlenmiştir.

2.1 Göz durumu veri seti

Bu çalışmada, göz durumu veri seti olarak ZJU [20] göz kırpma veritabanı kullanılmıştır. ZJU veri setinde bulunan açık ve kapalı göz durumları, aydınlatma ve çözünürlük açısından gerçek dünya koşulları altında alınmıştır. Bu veri seti, eğitim ve test olarak iki gruba ayrılmış ve iki kategoriden (açık ve kapalı) oluşmaktadır. Tablo 1’de ZJU veri setinin detayları verilmiştir. ZJU veri setindeki açık ve kapalı örnek göz görüntüleri, Şekil 2’de verilmiştir.

Tablo 1. ZJU veri seti detayları

Sınıf	Eğitim	Test
Açık (open) göz	5770	1230
Kapalı (close) göz	1574	410



Şekil 2. ZJU veri setindeki açık ve kapalı örnek göz görüntüleri

2.2 Görüntü önışlem yöntemleri

Bu çalışmada göz durumu tespitinde görüntülerin iyileştirilmesi için kontrast iyileştirme ve filtreleme teknikleri kullanılmıştır.

Görüntü iyileştirme uygulamalarından kullanılan önemli kavramlardan birisi de histogramdır. Bir görüntünün yoğunluk seviyesi $[0, L-1]$ aralığındadır ve L yoğunluk


seviyelerine sahip bir görüntünün histogramı, Denklem 1’de tanımlanmıştır.

$$H(r_k) = n_k \quad (1)$$


Burada, r_k k pikselinin yoğunluk seviyesidir ve n_k , yoğunluk seviyesi r_k olan görüntüdeki piksel sayısıdır. Bir başka konu normalleştirilmiş histogramlardır. Bu histogramlar, tüm öğeleri görüntüdeki toplam piksel sayısına bölerek elde edilebilir. $M \times N$ boyutundaki bir görüntü normalleştirilirse, elde edilecek histogram Denklem 2’de verilmiştir.

$$P(r_k) = \frac{n_k}{M \times N}, k = 0, 1, \dots, [L - 1] \quad (2)$$


Şekil 2’de görüldüğü gibi ZJU veri setinde bulunan açık ve kapalı göz durumu görüntüleri, farklı fiziksel özelliklere sahip ortamlar üzerinde toplanmıştır. Toplanan bu görüntülerde, ortamların fiziksel özelliklerine göre görüntünün aşırı karanlık olabilmesi ya da aydınlık seviyesinin fazlalığından dolayı göz hatlarının belirgin olmayışı, göz durumu tespitinde kullanılan bilgisayarlı görüşmelerinde problem yaratmaktadır. Bu yüzden göz durumu görüntülerinde, zayıf veya aşırı ışıklandırma nedeniyle oluşan kontrast farklılığı kontrast önışlemleri ile iyileştirilebilir. Bir başka açıdan görüntü histogramı kullanarak da düzenli piksel dağılımını sağlayan kontrast ayarı yapılabilmektedir. Ayrıca göz durumu görüntülerinde göz bölgesinin belirgin olmaması durumunda, görüntüdeki gürültüler giderilerek veya kontrastın ayarlanması ile görüntüde iyileştirme gerçekleştirilebilir. Bu çalışmada, ZJU göz durumu veri setindeki görüntülere görüntü kontrast iyileştirme ve filtreleme önışlem teknikleri uygulanmıştır. Önışlem uygulanan görüntüler, önışlem etkilerinin karşılaştırması için önerilen ESA modeli üzerinde performansı değerlendirilmiştir.



Şekil 3. Örnek göz görüntüsüne KG uygulaması: (a-c) önışlemsiz, (b-d) önışlemsiz histogram grafiği, (e-g) önışlem uygulanmış hali ve (f-h) önışlemlili histogram grafiği



Şekil 4. Örnek göz görüntüsüne HE uygulaması: (a-c) önişlemsiz, (b-d) önişlemsiz histogram grafiği, (e-g) önişlem uygulanmış hali ve (f-h) önişlemlili histogram grafiği



Şekil 5. Örnek göz görüntüsüne UHE uygulaması: (a-c) önişlemsiz, (b-d) önişlemsiz histogram grafiği, (e-g) önişlem uygulanmış hali ve (f-h) önişlemlili histogram grafiği

ZJU veri setine ilk olarak zayıf ışıklandırmadan dolayı oluşan düşük kontrastlı görüntüleri iyileştirmek için görüntü önişlem yöntemlerinden kontrast germe kullanılmıştır. Kontrast germe (KG), histogramda alt ve üst sınırları tanımlamak ve bu aralığı genişletmek için dönüşümlerin uygulanmasını içeren, yaygın olarak birçok alanda kullanılan bir görüntü iyileştirme yöntemidir [23]. Bir görüntünün kontrastında ayarlama yapmak, görüntüdeki aydınlatma dağılımını stabilize etmek için önemlidir. Göz görüntülerinde gözün bölümü genellikle aydınlığın az olduğu bölgedir. Bu bağlamda göz görüntülerinin analizinin iyileştirilmesi için ZJU veri setine KG önişlemi uygulanmıştır. ZJU veri setinden örnek açık ve kapalı durumunu belirten göz görüntülerine KG uygulanmış hali ve

bu işlemde elde edilen histogram grafiklerine bir örnek Şekil 3’de gösterilmiştir.


Kontrast iyileştirme önişlemlerinden biri de histogram eşitlemedir. Histogram eşitleme (HE), ZJU veri setinde zayıf aydınlık ışıklandırma veya yoğun histogram dağılımı içeren görüntülerin daha düzenli kontrast dağılımını sağlamak için kullanılmıştır. HE, kullanımı daha kolay ve diğer yöntemlere göre daha verimli olduğu için tüm görüntü türleri için yaygın olarak kullanılan bir yöntemdir. HE, girdi gri seviyeli görüntünün olasılık dağılımını hesaplayarak yeni bir dağılım oluşturur [24]. ZJU veri setinden örnek açık ve kapalı durumunu belirten göz görüntülerine HE uygulanmış hali ve bu işlemde elde edilen histogram grafikleri Şekil 4’de gösterilmiştir.

Kontrast iyileştirme yöntemlerinden bir diğeri Uyarlamalı Histogram Eşitleme (UHE) ise, ZJU veri setinde çoğunlukla zayıf ışıklandırma ortamında elde edilen görüntülerin kontrastını arttırmak için kullanılmıştır. Bu yöntem görüntü iyileştirmesi için yaygın olarak kullanılmaktadır. Ancak görüntünün homojen bölgelerinde hızın düşmesine ve gürültünün artmasına neden olabilir [25]. ZJU veri setinden örnek açık ve kapalı durumunu belirten göz görüntülerine UHE uygulanmış hali ve elde edilen histogram grafiklerine bir örnek Şekil 5’de gösterilmiştir.

Görüntü ön işlemede filtreleme teknikleri görüntüyü yumuşatmak ya da kenarları belirginleştirmek için sıklıkla kullanılmaktadır. ZJU veri setinde göz bölgelerinin daha belirgin olması ve veri seti toplanırken cihazdan kaynaklı oluşan gürültüleri yumuşatmak için Gauss Filtresi (GF) kullanılmıştır. GF, bazı yönlerden gürültü bastırma için ideal filtre olarak kabul edilir ve bu nedenle görüntü işleme ve bilgisayarla görmede yaygın olarak kullanılır. Ancak, GF gürültüyü bastırır ama aynı zamanda sinyali bozma ihtimali de bulunmaktadır [26]. GF, görüntü iyileştirmede iki boyutlu operatör kullanır ve görüntüleri bulanıklaştırarak gürültüleri ortadan kaldırmaktadır. GF’de kullanılan iki boyutlu gauss denklemi Denklem 3’de verilmiştir.

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (3)$$

ZJU veri setinden örnek açık ve kapalı durumunu belirten göz görüntülerine GF uygulanmış hali, Şekil 6’de gösterilmiştir.




Şekil 6. Örnek göz görüntüsüne Gaussian filtresi uygulaması: (a-c) önışlemsiz ve (b-d) önışlem uygulanmış hali

Görüntü önışlem yöntemlerinde kullanılan bir diğere filtre de medyan filtredir. Medyan Filtre (MF), bir görüntünün kalitesini iyileştirmek ve gürültünün giderilmesi için kullanılır. Bu çalışmada da ZJU veri setindeki göz görüntülerinin, görüntü kalitesinin iyileştirilmesi için kullanılmıştır. Doğrusal filtrelemeden daha üstün olan MF, doğrusal olmayan bir filtreleme yöntemidir [27]. Bir x_{ij} ,

$(i, j) \in Z^2$ görüntüsü için A filtre boyutunda MF, Denklem 4’deki gibi tanımlanır [28].

$$y_{ij} = \frac{\text{Median}x_{ij}}{A} = \text{Median}[x_{i+r, j+s}(r, s) \in A], (i, j) \in Z^2 \quad (4)$$

ZJU veri setinden örnek açık ve kapalı durumunu belirten göz görüntülerine MF uygulanmış haline bir örnek Şekil 7’de gösterilmiştir.



Şekil 7. Örnek göz görüntüsüne medyan filtresi uygulaması: (a-c) önışlemsiz ve (b-d) önışlem uygulanmış hali

2.3 Derin öğrenme

DL, verilen bir veri seti üzerinden öğrenimler elde eden ve birden fazla katmandan oluşan bir makine öğrenmesidir. Son zamanlarda DL yöntemleri arasında ESA’nın görüntü sınıflandırma üzerindeki üstün başarısı, görüntü içeren sınıflandırma problemlerinde ESA’nın kullanılmasını kaçınılmaz hale getirmiştir.

Bu çalışmada, göz durumu tespiti için bir ESA modeli önerilmiştir. Önerilen ESA modelinde, görüntü giriş, evrişim, toplu normalleştirme ve ortalama havuzlama, tam bağlı, softmax ve sınıflandırma katmanları kullanılmıştır. Önerilen ESA modelinin tipik katman yapısı Şekil 8’de verilmiştir.

Tipik ESA’larda genellikle ardışık evrişim katmanları arasına bir havuzlama katmanı eklenir. Havuzlamanın temel amacı, filtre çıktılarını toplamak ve temsili özellikleri kaldırmaktır. Ardından Rektifiye Lineer Birim (ReLU) aktivasyon fonksiyonu, filtre çıktılarının aktivasyonu için kullanılır. Normalleştirme katmanı, ESA’nın eğitimini hızlandırmak ve ağ başlatma durumuna duyarlılığı azaltmak için doğrusal olmayan katmanlar (evrişim ve ReLU) arasına yerleştirilir.

Havuzlama katmanı da genellikle ReLU katmanından sonra yerleştirilir. Bu katmanda gerçekleştirilen işleme “alt örnekleme” denir. Bu katmanın asıl iki amacı sonraki

katmanlar için daha az hesaplama yükü yaratmak ve modelin ezberlemesini engellemektir. En yaygın kullanılan havuzlama katmanı maksimum ve ortalamadır. Maksimum havuzlama hesaplaması **Denklem 5** ve ortalama havuzlama hesaplaması da **Denklem 6**'da verilmiştir.

$$Z_f = \max \{s\} = \max \{s_1, s_2 \dots s_n\} \quad (5)$$

$$Z_f = \text{ave} \{s\} = \text{ave} \{s_1, s_2 \dots s_n\} \quad (6)$$

Denklem 5'te, S filtre boyutunda maksimum değer seçilerek diğer değerler indirgenir ve işleme devam edilir. **Denklem 6**'da S filtre boyutundaki değerlerin toplamı alınarak ortalaması alınarak diğerleri indirgenir ve işlem devam ettirilir. ESA'nın evrişim filtrelerinden çıkarttığı özellikler, tam bağlı katmanda birleşir ve sınıflandırma katmanına doğru iletilir. Sınıflandırma katmanı ise, softmax aktivasyonunu kullanarak olasılık hesaplamasının ardından sınıflandırma yapmaktadır.


Önerilen ESA modelinin görüntü giriş katmanı (GGK), sırasıyla görüntünün yüksekliğini, genişliğini ve renk katmanını gösteren 24 x 24 x 1'e karşılık gelen görüntü boyutunu belirtir. GGK, veri normalizasyonu veya dönüşümü ile ilgili verilerin rastgeleleştirilmesine veya çıkarılmasına izin verir. Veri değerlendirmeleri, aşırı kullanımı önlemek için genellikle eğitimin başında otomatik olarak gerçekleştirilir. Önerilen ESA modeli altı evrişim katmanına sahiptir. Birinci, ikinci ve üçüncü evrişim katmanları 32 özellik haritası ve dördüncü, beşinci ve altıncı evrişim katmanları 64 özellik haritası çıkarmak için ayarlanmıştır. 1, 3, 5 ve 6'ncı evrişim katmanlarında kenar

özelliklerin kullanılması için "same" özelliği kullanılmıştır. Her evrişim katmanında sonra sırasıyla mini toplu normalleştirme ve ReLU katmanı kullanılmıştır. Bu katmanların ardından, ağın parametre sayısını ve geliştirilmesini azaltmak için havuzlama katmanı kullanılmıştır. Önerilen ESA modelinde, havuzlama katmanının etkisini incelemek için, ortalama ve maksimum havuzlama katmanı bir de havuzlama katmanı olmadan eğitim gerçekleştirilerek sistem performansı değerlendirilmiştir. Bu çalışmadaki kullanılan havuzlamalar 2x2 bir pencere üzerinde gerçekleştirilmiştir.

ESA modelinin evrişim katmanlarını ve alt örnekleme bölümlerinin ardından tüm ilgili özellikleri birleştirerek göz durumunun açık veya kapalı olmasını temsil eden 2 çıkışa sahip tam bağlantılı katman kullanılmıştır. Tam bağlantılı katman tüm çıkartılan özellikleri toplar ve modeli sınıflandırma için hazırlar. Sınıflandırma için, tam bağlantılı katmandan sonra softmax aktivasyon işlevi kullanılmıştır. Son olarak, sınıflandırma katmanı Softmax'ın aktivasyonundan elde edilen olasılıkları kullanarak sınıflandırma gerçekleştirmiştir.

ESA'ların eğitimi için hiperparametre seçimi önemli noktalardan biridir. ESA için belirlenmesi gerekli hiperparametreler kayıp fonksiyonu, optimizasyon yöntemi, öğrenme oranı, parti boyutu (batch size) ve periyot (epoch) sayısıdır.

Önerilen ESA modelinin hiperparametreleri kayıp fonksiyonu olarak çapraz entropi, optimizasyon yöntemi olarak momentumlu stokastik gradyan inişi (sgdm), öğrenme oranı 0.0001, parti boyutu 64 ve epoch sayısı da 100 olarak ayarlanmış ve bu hiperparametre ayarı ile önerilen ESA'nın eğitimi gerçekleştirilmiştir.



Şekil 8. Önerilen ESA modeli

3 Bulgular ve tartışma

Önerilen ESA modeli üzerinde yapılan deneyler, yaygın kullanılan karışıklık matrisi performans metrikleri olan doğruluk (Denklem 7), özgüllük (Denklem 8), duyarlılık (Denklem 9), kesinlik (Denklem 10), ve F1 skor (Denklem 11) kullanılarak değerlendirilmiştir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

$$\text{Özgüllük} = \frac{TN}{TN + FP} \quad (8)$$

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (9)$$

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (10)$$

$$F_1 \text{ skor} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (11)$$

Doğru pozitif (TP), göz durumunun gerçekte açık olup sınıflandırma tahmini sonucunda da açık olarak sınıflandırılmasıdır. Doğru negatif (TN), göz durumunun gerçekte kapalı olup sınıflandırma tahmini sonucunda da kapalı olarak sınıflandırılmasıdır. Yanlış pozitif (FP), gözün kapalı olup açık olarak sınıflandırılmasıdır. Yanlış negatif (FN) ise gözün açık olup kapalı olarak sınıflandırılmasıdır.

Önerilen ESA modeli ilk olarak, havuzlama katmanı etkisi incelemek için ZJU veri seti gri seviyeye dönüştürülmüştür. Sonrasında, bu veri seti üzerinde önerilen ESA modeli havuzlama katmanı olmadan, sadece ortalama havuzlama ve maksimum havuzlama katmanı kullanılarak 3 farklı şekilde eğitimi gerçekleştirilmiştir. Bu analizler, Matlab R2020a ve i5-6200U, 2,40 GHz CPU, 12 GB RAM NVIDIA Ge Force 1050 Ti GPU ve Windows 10 işletim sistemine sahip bir bilgisayar ortamında gerçekleştirilmiştir. Eğitim tamamlanmasından sonra modeller, ZJU veri setinin test kümesinde test edilmiş ve performans metrikleri karşılaştırma için hesaplanmıştır. Önerilen modelin 3 farklı havuzlama katmanı tipine ilişkin yapılan eğitimin değerlendirme sonucuna ilişkin performans karşılaştırması **Tablo 2**'de verilmiştir.

Tablo 2. Havuzlama katmanı performans değerlendirmesi

Havuzlama Tipi	Kapalı	Açık
-	0.8976	0.9171
Maksimum	0.9171	0.9260
Ortalama	0.9244	0.9488

Tablo 2'de yapılan karşılaştırmalar sonucunda, önerilen ESA modelinde ortalama havuzlama katmanı diğer havuzlama katmanlarına göre daha iyi sonuçlar elde etmiştir. Ortalama havuzlama katmanı, önerilen ESA modeli için en uygun havuzlama olarak belirlenmiş ve çalışmanın devamında bu katman referans alınarak devam edilmiştir.

Bir sonraki adımda, önerilen ESA modeli üzerinde görüntü önileme etkisi değerlendirilmesi için ZJU veri setine ayrı ayrı KG, HE, UHE, GF ve MF önilemleri uygulanmıştır. Görüntü önileme uygulanan ZJU verisetleri önerilen ESA modeli üzerinde eğitilmiş ve ZJU'nun test kümesinde performansı ölçülmüştür. İşlenmiş ZJU verisetlerinin önerilen ESA modelinde test edilmesi sonucu elde edilen performans sonuçları **Tablo 3**'de verilmiştir.

UHE ve HE, önerilen ESA modelinin performansını iyileştirirken KG, MF, GF performansı iyileştirememiştir. HE, performansını iyileştirmede AHE'den daha iyi performans göstermiştir. GF ve MF gibi filtreleme önilemlerinin uygulanması, önerilen ESA modeli üzerinde olumlu bir etki yaratmamıştır.

Bu çalışmada filtreleme tekniklerinden sonra kontrast iyileştirme yöntemleri (HE, UHE ve KG) kullanılarak önerilen ESA modeli üzerindeki performans etkileri analiz edilmiştir. ZJU veri setine MF uygulandıktan sonra HE, UHE ve KG'nin uygulanması sonucu eğitilen ESA modellerinin performansları analiz edilmiş ve elde edilen sonuçlar **Tablo 4**'de verilmiştir.

Tablo 3. Önerilen ESA modelinin ZJU veri seti üzerinde önileme değerlendirilmesi

Yöntem	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 skor
-	0.9366	0.9479	0.9024	0.9668	0.9572
UHE	0.9414	0.9650	0.8707	0.9572	0.9610
HE	0.9432	0.9495	0.9243	0.9741	0.9616
KG	0.9268	0.9447	0.8731	0.9571	0.9509
MF	0.9231	0.9243	0.9195	0.9717	0.9474
GF	0.8853	0.8731	0.9219	0.9710	0.9194

Tablo 4. ZJU veri setinde medyan filtre ve kontrast artırma yöntemlerinin etkisi

Yöntem	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 skor
MF+HE	0.8798	0.8617	0.9341	0.9751	0.9148
MF+UHE	0.9298	0.9512	0.8658	0.9551	0.9531
MF+KG	0.9317	0.9308	0.9341	0.9769	0.9532

Tablo 5. ZJU veri setinde Gaussian filtre ve kontrast artırma yöntemlerinin etkisi

Yöntem	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 skor
GF+HE	0.9317	0.9423	0.9000	0.96580	0.9539
GF+UHE	0.9085	0.9073	0.9121	0.96875	0.9370
GF+KG	0.8914	0.8837	0.9146	0.96880	0.9242

ZJU veri setinde MF ve KG birlikte uygulanması, UHE ve HE kullanımına göre daha iyi performans göstermiştir. Ancak elde edilen bulgular, önilemsiz ZJU veri setinden elde edilen performanstan iyi değildir (**Tablo 3**). Bir başka değerlendirme ise GF sonrası, HE, UHE ve KG uygulanmasıdır. ZJU veri seti üzerinde uygulanan GF sonrası HE, UHE ve KG önilemleri sonrası önerilen ESA modelde eğitimler yapılmış ve yapılan performans değerlendirmesi **Tablo 5**'de verilmiştir.

Tablo 6. Önerilen ESA modelinin ZJU veri setinde önceki yapılan çalışmalar ile performans karşılaştırması

Çalışma	Yöntem	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	F1 skor
Dong vd. [12]	Haar+DVM	92.74	-	-	-	-
Pauly vd. [15]	HOG+DVM	85.5	95.52	79.26	74.75	-
Pauly vd. [16]	HOG+DVM	85.0	-	-	-	-
Han vd. [17]	DVM+ESA	-	89.7	-	94.4	-
Lee vd. [18]	DVM	95.14	91.7	-	94.4	-
Önerilen Yöntem	HE+ESA	94.32	94.95	92.43	97.41	96.16

ZJU veri setine uygulanan GF ve HE önışlemleri, önerilen ESA modelinde uygulanan diğer önışlemlere göre en iyi performansı göstermiştir. Ancak bu elde edilen performans, ham ZJU veri setinden elde edilen performanstan daha iyi değildir.

Elde edilen bulgular ve yapılan karşılaştırmalar sonucunda ZJU veri setinin HE uygulanmış hali önerilen ESA modelinde en üstün performansı göstermiştir. Önerilen ESA modelinin HE önışlemi ile eğitilmesiyle elde edilen en yüksek performansın, ZJU veri setindeki önceki yapılan çalışmalarla karşılaştırması Tablo 6’da verilmiştir.

Tablo 6’da yapılan karşılaştırmalar sonucunda, önerilen yöntemimiz özgüllük, kesinlik ve F1 skor performans metriğinde en üstün performans göstermiştir. Ancak doğruluk ve duyarlılık performans metriğinde karşılaştırmada ikinci sırada yer almıştır. Lee vd. [18] çalışması doğruluk metriğinde en üstün performans gösterirken duyarlılık metriğinde önerilen yöntemimizin gerisinde kalmıştır. Pauly vd. [15] çalışması duyarlılık metriğinde en üstün performans göstermişken doğruluk metriğinde önerilen yöntemimizin gerisinde kalmıştır. Diğer çalışmalara bakıldığında özgüllük ve F1 skor metriği çok tercih edilmemiştir. Önerilen ESA modelinin çalışmada kullanılan performans metriklerinde performans değerlendirilmesi Tablo 6’da sunulmuş ve ZJU veri setinde önceki yapılan çalışmalar ile karşılaştırmasında, göz durumu tespiti etkili ve güvenilir sınıflandırma kabiliyeti olduğunu göstermiştir. Göz bölgesinin aydınlatma gibi çevresel faktörlerden etkilendiği açıktır. Bu bağlamda, bu çalışmada görüntü işleme yöntemlerinin önerilen ESA modelinde etkisi incelenerek HE önışleminin performans arttırımana etkisi ortaya çıkartılmıştır. Bir başka açıdan önerilen yöntemde derin öğrenme tabanlı ESA kullanılması, literatürde göz durumu tespitinde son teknoloji yöntemlerin gelişmesine de katkıda bulunacaktır.

4 Sonuçlar

Bu çalışmada göz durumu tespiti için görüntü ön işleme ve derin öğrenmeye dayanan ESA modeli önerilmiş ve ZJU veri setinde test edilmiştir. Elde edilen bulgular doğrultusunda öncelikle ESA modelinde en başarılı havuzlama katmanı değerlendirmesi yapılmış ve ortalama havuzlama en başarılı katmanlardan birisi olmuştur. Göz bölgesinde oluşan aydınlatma problemini ortadan kaldırmak ve görüntü önışlemlerin ESA modelinde etkisini incelemek için ZJU veri setine çeşitli görüntü önışlem yöntemleri uygulanmıştır. ZJU veri setine uygulanan çeşitli önışlem kombinasyonlarının ESA modelinde test edilmesiyle HE en yüksek performansı elde eden önışlem olmuştur. Kontrast iyileştirme yöntemi olan HE’nin önerilen ESA modelinde

etkisini göstermesi, göz durumu tespiti sınıflandırma problemlerinde etkin kullanılabileceğini göstermiştir. Bir sonraki çalışmada, göz durumu veri setinin çeşitlendirilip yeni ESA modellerin oluşturularak performans arttırımının gerçekleştirilmesi planlanmaktadır.

Göz durumu tespiti üzerine yapılacak çalışmalarda, gözün açık ve kapalı durumlarını içeren çeşitli gerçek dünya senaryolarından görüntüler toplayıp yeni bir veri seti üretilebilir. Bu veri seti üzerinde de yeni geliştirilen metotların doğrulaması gerçekleştirilebilir. Halihazırda ulaşılabilir olan göz durumu veri setleri ile birleştirilerek önerilen yöntemin kapsamlı bir değerlendirmesi yapılabilir. Gerçek dünya senaryosundan alınmış bir video veya bir gerçek zamanlı uygulama üzerinden de göz durumu tespitinin değerlendirilmesi yapılabilir. Bu yöntemlerin avantaj ve dezavantajları tartışılarak literatüre daha etkili ve güvenilir bir yöntem ile katkı sağlanabilir.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %9

Kaynaklar

- [1] M. H. Yang, D. J. Kriegman and N. Ahuja, Detecting faces in images: A survey. IEEE Transactions on pattern analysis and machine intelligence, 24(1), 34-58, 2002. <https://doi.org/10.1109/34.982883>
- [2] T. Soukupova and J. Cech, Eye blink detection using facial landmarks. In 21st computer vision winter workshop, Rimske Toplice, Slovenia, 3-5 February 2006.
- [3] R. Huang, Y. Wang and L. Guo, P-FDCN based eye state analysis for fatigue detection. In 2018 IEEE 18th International Conference on Communication Technology (ICCT), pp. 1174-1178, Chongqing, China, 8-11 October 2018. <https://doi.org/10.1109/ICCT.2018.8599947>
- [4] D. M. Joshi, N.K. Rana and V. Misra, Classification of brain cancer using artificial neural network. In 2010 2nd international conference on electronic computer technology, pp. 112-116, 19-21 March 2010. <https://doi.org/10.1109/ICECTECH.2010.5479975M>
- [5] W. Zhao, R. Chellappa, P.J. Phillips and A. Rosenfeld, Face recognition: A literature survey. ACM computing surveys (CSUR), 35(4), 399-458, 2003. <https://doi.org/10.1145/954339.954342>
- [6] M. Divjak and H. Bischof, Eye Blink Based Fatigue Detection for Prevention of Computer Vision Syndrome. In MVA, pp. 350-353, 2009.

- [7] C. L. Chou, Y. H. Huang and S. C. Ho, Blink Detection Using Facial Landmark Blink Detector and Multi-Layer Perceptron. In NCS 2019, pp. 542-545, 2019.
- [8] M. Lalonde, D. Byrns, L. Gagnon, N. Teasdale and D. Laurendeau, Real-time eye blink detection with GPU-based SIFT tracking. In Fourth Canadian Conference on Computer and Robot Vision (CRV'07), Montreal, Quebec, Canada, pp. 481-487, Montreal, Quebec, Canada, 28-30 May 2007. <https://doi.org/10.1109/CRV.2007.54>
- [9] J. He, W. Choi, Y. Yang, J. Lu, X. Wu and K. Peng, Detection of driver drowsiness using wearable devices: A feasibility study of the proximity sensor. *Applied ergonomics*, 65, 473-480, 2017. <https://doi.org/10.1016/j.apergo.2017.02.016>
- [10] M. Su, C. Yeh, S. Lin, P. Wang and S. Hou, An implementation of an eye-blink-based communication aid for people with severe disabilities. In 2008 International Conference on Audio, Language and Image Processing, pp. 351-356, Shanghai, China, 7-9 July, 2008. <https://doi.org/10.1109/ICALIP.2008.4590090>
- [11] S. Soltani and A. Mahnam, A practical efficient human computer interface based on saccadic eye movements for people with disabilities. *Computers in biology and medicine*, 70, 163-173, 2016. <https://doi.org/10.1016/j.combiomed.2016.01.012>
- [12] Y. Dong, Y. Zhang, J. Yue and Z. Hu, Comparison of random forest, random ferns and support vector machine for eye state classification. *Multimedia Tools and Applications*, 75(19), 11763-11783, 2016. <https://doi.org/10.1007/s11042-015-2635-0>
- [13] L. Zhao, Z. Wang, G. Zhang, Y. Qi and X. Wang, Eye state recognition based on deep integrated neural network and transfer learning. *Multimedia Tools and Applications*, 77(15), 19415-19438, 2018. <https://doi.org/10.1007/s11042-017-5380-8>
- [14] Y. LeCun, Y. Bengio and G. Hinton, Deep learning. *nature*, 521(7553), 436-444, 2015. <https://doi.org/10.1038/nature14539>
- [15] L. Pauly and D. Sankar, Non intrusive eye blink detection from low resolution images using HOG-SVM classifier. *International Journal of Image, Graphics and Signal Processing*, 8(10), 11, 2016. <https://doi.org/10.5815/ijigsp.2016.10.02>
- [16] L. Pauly and D. Sankar, A novel method for eye tracking and blink detection in video frames. In 2015 IEEE International Conference on Computer Graphics, Vision and Information Security (CGVIS), pp. 252-257, Bhubaneswar, India, 2-3 November 2015. <https://doi.org/10.1109/CGVIS.2015.7449931>
- [17] Y. J. Han, W. Kim and J. S. Park, Efficient eye-blinking detection on smartphones: A hybrid approach based on deep learning. *Mobile Information Systems*, 2018, 2018. <https://doi.org/10.1155/2018/6929762>
- [18] W. O. Lee, E. C. Lee and K. R. Park, Blink detection robust to various facial poses. *Journal of neuroscience methods*, 193(2), 356-372, 2010. <https://doi.org/10.1016/j.jneumeth.2010.08.034>
- [19] Y. S. Wu, T. W. Lee, Q. Z. Wu and H. S. Liu, An eye state recognition method for drowsiness detection. In 2010 IEEE 71st Vehicular Technology Conference, pp. 1-5, Taipei, Taiwan, 16-19 May 2010. <https://doi.org/10.1109/VETECS.2010.5493951>
- [20] B. Wu and R. Nevatia, Cluster boosted tree classifier for multi-view, multi-pose object detection. In 2007 IEEE 11th International Conference on Computer Vision, pp. 1-8, Rio de Janeiro, Brazil, 14-21 October 2007. <https://doi.org/10.1109/ICCV.2007.4409006>
- [21] L. Cadena, A. Zotin, F. Cadena, A. Korneeva, A. Legalov and B. Morales, Noise reduction techniques for processing of medical images. In Proceedings of the World Congress on Engineering Vol. 1, pp. 5-9, London, U.K., 5-7 July, 2017.
- [22] C. Saravanan, Color image to grayscale image conversion. In 2010 Second International Conference on Computer Engineering and Applications Vol. 2, pp. 196-199, Bali Island, 19-21 March 2010. <https://doi.org/10.1109/ICCEA.2010.192>
- [23] C. Munteanu and V. Lazarescu, Evolutionary contrast stretching and detail enhancement of satellite images. In Proc. Mendel Vol. 99, pp. 94-99, 1999.
- [24] M. Abdullah-Al-Wadud, M. H. Kabir, M. A. A. Dewan and O. Chae, A dynamic histogram equalization for image contrast enhancement. *IEEE Transactions on Consumer Electronics*, 53(2), 593-600, 2007.
- [25] S. M. Pizer, E. P. Amburn, J. D. Austin, R. Cromartie, A. Geselowitz, T. Greer and K. Zuiderveld, Adaptive histogram equalization and its variations. *Computer vision, graphics, and image processing*, 39(3), 355-368, 1987. [https://doi.org/10.1016/S0734-189X\(87\)80186-X](https://doi.org/10.1016/S0734-189X(87)80186-X)
- [26] G. Deng and L. W. Cahill, An adaptive Gaussian filter for noise reduction and edge detection. In 1993 IEEE conference record nuclear science symposium and medical imaging conference, pp. 1615-1619, San Francisco, CA, USA, 31 Oct-6 Nov 1993. <https://doi.org/10.1109/NSSMIC.1993.373563>
- [27] T. Chen, K. K. Ma and L. H. Chen, Tri-state median filter for image denoising. *IEEE Transactions on Image processing*, 8(12), 1834-1838, 1999.
- [28] Y. Guo, Y. Liu, A. Oerlemans, S. Lao, S. Wu and M.S. Lew, Deep learning for visual understanding: A review. *Neurocomputing*, 187, 27-48, 2016. <https://doi.org/10.1016/j.neucom.2015.09.116>
- [29] I. Goodfellow, Y. Bengio and A. Courville, Deep learning. MIT press, London, England, 2016.
- [30] V. Suárez-Paniagua and I. Segura-Bedmar, Evaluation of pooling operations in convolutional architectures for drug-drug interaction extraction. *BMC bioinformatics*, 19(8), 39-47, 2018. <https://doi.org/10.1186/s12859-018-2195-1>

