

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY SİNİR AĞI SONUÇLARININ
OYLANARAK GERÇEK ZAMANLI GÖZ
BEBEĞİ MERKEZİNİN TESPİTİ

NECMEDDİN SAİD KARAKOÇ
YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

GEBZE
2019

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY SİNİR AĞI SONUÇLARININ
OYLANARAK GERÇEK ZAMANLI GÖZ
BEBEĞİ MERKEZİNİN TESPİTİ

NECMEDDİN SAİD KARAKOÇ
YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

DANIŞMANI
PROF. DR. YUSUF SİNAN AKGÜL

GEBZE
2019

T.R.
GEBZE TECHNICAL UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

**REAL TIME ESTIMATION OF THE
EYE PUPIL CENTER BY VOTING OVER
NEURAL NETWORK RESULTS**

NECMEDDİN SAİD KARAKOÇ
A THESIS SUBMITTED FOR THE DEGREE OF
MASTER OF SCIENCE
DEPARTMENT OF COMPUTER ENGINEERING

THESIS SUPERVISOR
PROF. DR. YUSUF SİNAN AKGÜL

GEBZE
2019

GTÜ Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 26/06/2019 tarih ve 2019/29 sayılı kararıyla oluşturulan jüri tarafından 25/07/2019 tarihinde tez savunma sınavı yapılan Necmeddin Said KARAKOÇ'un tez çalışması Bilgisayar Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI) : Prof. Dr. Yusuf Sinan AKGÜL

ÜYE

: Dr. Öğr. Üyesi Yakup GENÇ

ÜYE

: Dr. Öğr. Üyesi Tarkan AYDIN



ONAY

Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun

...../...../..... tarih ve/..... sayılı kararı.

ÖZET

Teknolojinin hızlı bir şekilde gelişmesi ile beraber göz bebeği merkezinin kestirimi, son yıllarda bilgisayarla görme alanında üzerinde sıklıkla çalışılan konulardan biri haline gelmiştir. Göz bebeği merkezi tespit sistemleri günlük yaşantıda pek çok insan-bilgisayar etkileşimi uygulamalarında kullanılabilmektedir. Sürücü dikkat takip sistemleri, engelli insanların göz ile kontrol edebildiği sistemler, göz bakış açısı tespit sistemleri, yorgunluk tespit sistemleri ve uyku tespit sistemleri bu tür uygulamalara örnek olarak gösterilebilir.

Ticari amaçlı geliştirilen göz bebeği merkezi tespit sistemleri genellikle bir özel donanıma ihtiyaç duyarlar. Literatürde bu alanda özel donanım gerektiren sistemlere alternatif olarak geliştirilen çalışmalar yaygınlaşmaktadır. Bu çalışmada hiçbir özel donanıma ihtiyaç duyulmadan göz bebeği merkezi gerçek zamanlı olarak tespit edilmiştir. Çalışmada önerilen yöntemde derin öğrenme algoritmalarından KSA kullanılmaktadır. Göz bölgesinden dört farklı ölçekte elde edilen görüntüler birleştirilerek AlexNet ağ yapısı ile eğitilmiştir. Eğitim aşamasında göz bölgesinden elde edilen görüntü parçaları için gerekli olan etiket bilgileri ilgili parçalardaki göz bebeği merkez noktalarına göre belirlenmiştir. Sistemin test aşamasında ağırlıklı ortalama, kaba kuvvet araması tabanlı rastgele nokta, optimizasyon tabanlı rastgele nokta ve iki aşamalı optimizasyon tabanlı rastgele nokta olmak üzere dört farklı yöntem uygulanmıştır.

Gerçekleştirilen deney sonuçlara göre sistem BioID veri kümesi üzerinde optimizasyon tabanlı rastgele nokta yöntemi ile ortalama 12,1 FPS hızına ulaşmıştır. Ayrıca sistem literatürdeki alternatif yöntemlere göre daha yüksek başarı oranları elde etmiştir. En yüksek başarı oranı ise ağırlıklı ortalama yöntemi ile elde edilmiştir.

Anahtar Kelimeler: Göz Bebeği Merkezi Tespiti; Derin Öğrenme; Konvolüsyon Sinir Ağı.

SUMMARY

With the rapid development of technology, estimation of the eye pupil center has become one of the most frequently studied subjects in the field of computer vision in recent years. Systems working on detecting human eye pupil center can be used in many human-computer interaction applications in our daily life. Examples of such applications include driver attention tracking systems, eye-controllable systems for disabled people, human gaze estimation systems, fatigue detection systems and sleep detection systems.

Commercially available systems that detect eye pupil center generally require a specialized hardware. In the literature, studies developed as an alternative to these systems that require a specialized hardware are getting more popular. In this work, eye pupil center was estimated in real time without any need of a specialized hardware. The proposed method in this work uses CNN from deep learning algorithms. Four different scale image patches gathered from the eye region were combined and fed into AlexNet neural network in order to train the model. Class label information required for image patches obtained from the eye region in the training phase was determined according to the eye pupil center locations. In the test phase of the system, four different methods including weighted average, brute force search based random point, optimization based random point and two stage optimization based random point were applied.

According to the experiment results, the system reached an average rate of 12,1 FPS on the BioID dataset with optimization based random point method. Our results achieved more success than similar state of the art methods. The highest success rate was obtained by weighted average method.

Keywords: Pupil Center Estimation; Deep Learning; Convolutional Neural Network.

TEŞEKKÜR

Bizlere her zaman hayatı ile örnek olan, gerek lisans eğitimim ve gerekse yüksek lisans eğitimim boyunca benden desteğini hiçbir zaman esirgemeyen saygıdeğer hocam Prof. Dr. Yusuf Sinan AKGÜL'e en içten teşekkürlerimi sunarım. Ayrıca çalışmalarımı gerçekleştirmemde önemli katkıları olan Şamil KARAHAN'a da teşekkürlerimi sunarım.

Eğitim hayatım boyunca değerli vakitlerinden çaldığım, bana her türlü konuda maddi ve manevi olarak tereddütsüz destek olan, zorluk yaşadığım her anımı kolaylaştırmak için çaba harcayan ve bu tezin yazılmasında çokça katkıları olan başta sevgili eşim Enise KARAKOÇ'a ve sonrasında aileme en içten teşekkürlerimi sunarım.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	v
SUMMARY	vi
TEŞEKKÜR	vii
SİMGELER ve KISALTMALAR DİZİNİ	x
ŞEKİLLER DİZİNİ	xi
TABLolar DİZİNİ	xiii
1. GİRİŞ	1
1.1. Kullanım Alanları	1
1.2. Motivasyon	2
1.3. Tezin Kapsamı	3
2. İLGİLİ ÇALIŞMALAR	5
2.1. Model Tabanlı Yöntemler	5
2.1.1. Makine Öğrenmesi Tabanlı Yöntemler	6
2.1.2. Derin Öğrenme Tabanlı Yöntemler	8
2.2. Öznitelik Tabanlı Yöntemler	9
2.3. Hibrit Yöntemler	12
3. SİSTEMİN EĞİTİM AŞAMASI	14
3.1. Veri Kümesinin Ön İşlemden Geçirilmesi	14
3.2. Ağ Yapısının Eğitimi	18
4. SİSTEMİN TEST AŞAMASI	20
4.1. Ağırlıklı Ortalama Yöntemi	20
4.2. Kaba Kuvvet Araması Tabanlı Rastgele Nokta Yöntemi	23
4.3. Optimizasyon Tabanlı Rastgele Nokta Yöntemi	25
4.4. İki Aşamalı Optimizasyon Tabanlı Rastgele Nokta Yöntemi	28
4.4.1. Birinci Aşama	28
4.4.2. İkinci Aşama	30
5. DENEYLER	32
6. SONUÇLAR	47

KAYNAKLAR	49
ÖZGEÇMİŞ	57
EKLER	58

SİMGELER ve KISALTMALAR DİZİNİ

<u>Simgeler ve Kısaltmalar</u>	<u>Açıklamalar</u>
KSA	: Konvolüsyonel Sinir Ağı
FPS	: Frames Per Second
YGH	: Yönlü Gradyan Histogramı
DVR	: Destek Vektör Regresör
SIFT	: Scale-Invariant Feature Transform
LSVRC	: Large Scale Visual Recognition Challenge
CDF	: Cumulative Density Function
CHT	: Circular Hough Transform
FLD	: Fisher Linear Discriminant
DVM	: Destek Vektör Makineleri
AAM	: Active Appearance Model
2B	: 2 Boyutlu

ŞEKİLLER DİZİNİ

<u>Sekil No:</u>	<u>Sayfa</u>
1.1: Sistemin bir görüntü üzerinde göz bebeği merkezinin tespiti.	4
2.1: Göz bebeği merkezi tespiti yapan literatür çalışmaları.	5
3.1: Dört ölçekli görüntü parçasından etiket fonksiyonunun parametresi olan d mesafesinin elde edilmesi.	15
3.2: Sıfır etiketi için dört ölçekli görüntü parçası elde etme aşamaları.	17
3.3: AlexNet ağ yapısı.	18
3.4: Sistemin eğitiminde kullanılan ağ yapısı.	19
4.1: Sistemin ağırlıklı ortalama yöntemi ile çalışan test aşaması.	21
4.2: Ağırlıklı ortalama yöntemi için farklı büyüme şekillerine göre etiket katsayı dağılımları.	22
4.3: Sistemin kaba kuvvet araması tabanlı rastgele nokta yöntemi ile çalışan test aşaması.	24
4.4: Sol göz için rastgele oluşturulan görüntü parçalarının göz bebeği merkezine olan uzaklığının tahmin edilmesi ile oluşan daireler.	25
4.5: Sistemin optimizasyon tabanlı rastgele nokta yöntemi ile çalışan test aşaması.	27
4.6: Sistemin iki aşamalı optimizasyon tabanlı rastgele nokta yöntemi ile çalışan test aşamasının birinci aşaması.	29
4.7: Sistemin iki aşamalı optimizasyon tabanlı rastgele nokta yöntemi ile çalışan test aşamasının ikinci aşaması.	31
5.1: Hata ölçüm metriği değerlerinin görselleştirilmesi.	33
5.2: Ağırlıklı ortalama yönteminin farklı parametrelerle gerçekleştirilen deney sonuçlarının karşılaştırılması.	35
5.3: Kaba kuvvet araması ve optimizasyon tabanlı rastgele nokta yöntemleri için her bir adımda n değişkenine göre ortalama geçen süreler.	36
5.4: Optimizasyon tabanlı rastgele nokta yöntemi için değişen n değerlerinde elde edilen başarı oranları.	37
5.5: Mesafe hesabı yapılan test yöntemlerinin her bir adımında ortalama geçen zamanın karşılaştırılması.	38
5.6: Sistemin farklı test yöntemlerinin doğruluk oranına göre karşılaştırılması.	39

5.7: A kişisine ait pozitif bir deney sonucu.	43
5.8: B kişisine ait pozitif bir deney sonucu.	43
5.9: C kişisine ait pozitif bir deney sonucu.	44
5.10: D kişisine ait pozitif bir deney sonucu.	44
5.11: E kişisine ait pozitif bir deney sonucu.	45
5.12: F kişisine ait negatif bir deney sonucu.	45
5.13: G kişisine ait negatif bir deney sonucu.	46

TABLÖLAR DİZİNİ

<u>Tablo No:</u>	<u>Sayfa</u>
4.1: Ağırlıklı ortalama yöntemi için etiket katsayı bilgileri.	20
5.1: Ağırlıklı ortalama yönteminin farklı parametrelerle gerçekleştirilen deney sonuçlarının karşılaştırılması.	34
5.2: Dört farklı test yönteminin çalışma zamanına göre karşılaştırılması.	38
5.3: Sistemin farklı test yöntemlerinin doğruluk oranına göre karşılaştırılması.	39
5.4: BioID veri kümesi üzerinde gerçekleştirilen deneylere ait sonuçların literatürdeki model tabanlı yöntemlerle karşılaştırılması.	40
5.5: BioID veri kümesi üzerinde gerçekleştirilen deneylere ait sonuçların literatürdeki öznetelik tabanlı yöntemlerle karşılaştırılması.	41
5.6: BioID veri kümesi üzerinde gerçekleştirilen deneylere ait sonuçların literatürdeki hibrit yöntemlerle karşılaştırılması.	41
5.7: Literatürdeki BioID veri kümesini kullanan çalışmaların hem başarı hem de çalışma zamanı açısından karşılaştırılması.	42

1. GİRİŞ

Göz bebeği merkezinin tespiti ve göz takibi, son zamanlarda dijitalleşmenin de hızla artması ile birlikte literatürde üzerinde çalışılan önemli konulardan biri haline gelmiştir. Göz, insanın günlük yaşantısında kesintisiz şekilde aktif olarak kullandığı bir organdır. Göz bebeğinin merkez noktası, insanın bakışına ait oldukça önemli bilgiler içermektedir. Dolayısı ile gözün takip edilebilmesi, insan hayatında önemli yeri olan uygulamalar geliştirilmesine olanak sağlamaktadır. İnsanın nereye baktığının bilinmesi ile dikkat takibi, uyku tespiti, yorgunluk tespiti, hastalık tespiti gibi pek çok uygulama yapılabilmektedir. Göz bebeği merkezi tespit sistemlerinin gürbüz olabilmeleri için zorlu koşullarda, farklı kafa pozisyonlarında ve düşük çözünürlüklü görüntülerde başarılı sonuçlar vermesi gerekmektedir [1].

Bu alandaki literatür çalışmaları incelendiğinde, gözün geometrik yapısını kullanan birçok çalışma olduğu görülmektedir. Bununla birlikte modele dayalı yöntemler de aktif olarak kullanılmaktadır. Ticari amaç ile geliştirilen göz takipçisi yazılımları ise çoğu zaman özel bir kızılötesi kameraya ihtiyaç duymaktadır [2].

1.1. Kullanım Alanları

Göz bebeği merkezinin tespiti günlük yaşantıda pek çok uygulamada aktif olarak kullanılabilir [3]. Göz bakış açısı kestirimi [4] uygulama alanlarının başında gelmektedir. Göz bebeği merkez noktası bilgisi göz bakış açısının tespitinde önemli ölçüde fayda sağlamaktadır. Yine göz takibi [5] de bir diğer kullanım alanıdır. Gözün merkez noktasının tespit edilmesi, göz takipçisi sistemlerine doğrudan katkı sağlamaktadır.

Göz bebeği merkezi tespiti insan-makine etkileşimi alanında da [6] [7] önemli ölçüde kullanılabilir [8]. İnsan-makine arayüzleri göz bebeği merkezi tespit sistemleri sayesinde kullanıcı deneyimi açısından iyileştirilebilmektedir [9]. İnsanlar bir uygulamayı kullanırken odaklarını o uygulamaya verdikleri için kullanım sonrasında ne gibi deneyimler yaşadıklarını çok iyi hatırlayamazlar. Ancak bu tür sistemler sayesinde kullanıcının tüm uygulama deneyimi süresince yaptığı işlemler takip edilerek dikkatleri tespit edilebilmekte ve bu sayede insan-makine arayüzleri

iyileştirilebilmektedir. Bu tür arayüzler tarayıcı tabanlı, masaüstü tabanlı veya herhangi bir arayüz içeren uygulama olabilmektedir.

Çeşitli görsel dikkat takibi [10] ve sürücüler için yorgunluk tespiti [11] [12] göz takibi ile ilgili farklı önemli kullanım alanlarıdır. Yapılan araştırmalarda kazaların büyük bir bölümünün sürücülerin dikkat eksikliğinden, yorgun olmasından veya uykusuz olmasından kaynaklandığı görülmüştür [13]. Sürücülerin dikkatinin otomatik olarak tespit edilebilmesi ve bu sayede onların önceden uyarılarak olası kazaların önlenmesi, hem insan sağlığı açısından hem de maddi açıdan büyük bir öneme sahiptir. Bu sebeple sürücülerin dikkat takibi için geliştirilen sistemler büyük önem arz etmektedir. Göz bebeği merkezini tespit edebilen sistemler, sürücülerin uykusuzluk durumunu, yorgunluk durumunu veya gözünü yoldan ayırması gibi durumları tespit etme konusunda oldukça kullanışlıdır. Bu tür sistemlerin sürücünün görsel dikkatini ölçebilmesinin yanısıra, sürüş esnasındaki bakış açısının istatistiksel olarak elde edilmesinde de kullanılabilir.

Göz kırpma tespiti [14] de göz bebeği merkezi tespitinde önemli olan bir başka kullanım alanıdır. İnsan gözünün kırpma anını tespit etmek, kırpma sıklığını da tespit etmeye olanak sağlamak ve bu sayede gözün kapalılık durumu anlaşılabilir. Bu tür ölçümler sürücülerin sürüş esnasındaki farkındalığını ölçmeye de olanak sağlamaktadır.

Göz takip sistemleri hastalık teşhislerinde de aktif olarak kullanılabilir. Örneğin şizofreni hastalığının tespiti [15] gözün fonksiyonel bozukluğundan anlaşılabilir. Sağlık alanında bir başka kullanım örneği ise engelli insanlar için göz ile kontrol edilebilir sistemlerdir [16]. Özellikle felç geçirmiş veya yatalak hastalar çeşitli göz bebeği merkezi tespit sistemleri sayesinde diğer insanlarla iletişim kurabilmektedirler.

1.2. Motivasyon

Literatürde bu alanda yayınlanmış çalışmalara bakıldığında, gözlerin yüz üzerindeki en önemli özellik olduğu konusunda ortak bir kanıya varıldığı anlaşılmaktadır. Bu sebeple, yüz özellikleri ile ilgili yapılan araştırmalar yoğunluğunu daha çok göz konumlandırmasına vermiştir. Göz konumlandırmasının yüzün diğer özelliklerine göre daha önemli olmasının pek çok sebebi bulunmaktadır. Bu sebeplerin başında gözlerin insanların durumu hakkında bilgi verebilecek çok önemli bir kaynak


olması gelmektedir. Bir insanın resmine bakılırken genelde o kişinin gözlerine odaklanılır ve en çok dikkati gözler çeker. Gözün şekli, boyutu ve rengi, o kişi hakkında önemli bilgiler verir ve kişinin tanınmasına yardımcı olur. Ayrıca yüz tanıma konusunda yüzün üst bölgesinin alt bölgesine göre çok daha önemli bir rol oynadığı gözlemlenmiştir. Gözlerin hareketi, kişinin ilgisini ve dikkatini gösterir ve duygusal durumunun anlaşılmasına yardımcı olur. İnsanlarda iki adet göz bulunur ve genelde ikisinin de görünüşü çok benzerdir, bu sebeple ikisi de aynı yöntem ile eş zamanlı olarak tanınabilmektedir. Bu bilgi ayrıca gözler arası mesafeden yüzün görüntüye oranla ne kadar büyüklükte olduğunun da kabaca tespit edilebilmesine yardımcı olur. Bazı durumlarda bu bilgi kullanılarak görüntü normalleştirilmesi de yapılabilmektedir. Tipik yüz değişimlerine karşı gözlerin görünümünde çok az değişim olmaktadır. Örneğin, sakal ve bıyık olması yüzü değiştirirken göz üzerinde herhangi bir etkisi bulunmamaktadır. Gürbüz bir şekilde göz konumlandırmasının yapılması, yüz üzerindeki diğer özelliklerin de tanınabilmesine olanak sağlar [17].

Literatürde göz bebeği merkezi tespiti alanında çokça çalışma mevcut olsa da bunların çoğunluğu pahalı sensörler, yüksek çözünürlüklü kameralar ve çeşitli özel donanımlar gerektirmektedir [18]. Ticari olarak geliştirilen göz takip sistemleri genellikle kullanıcılardan kafalarına takılan bir cihaz giymelerini beklerler [19], bir ya da birden fazla kızılötesi kamera ya da iktiyaç duyarlar [20] veya yüksek çözünürlüklü görüntülere iktiyaç duyarlar [21]. Kafa pozisyonunun ani değişimlerine karşı hassas olan bu tür sistemler [22], çoğu zaman yalnızca ani değişimlerin olmadığı durumlarda ancak gürbüz sonuçlar elde edebilmektedir. Ticari amaçlı olarak geliştirilen bu tür sistemler genellikle pahalıdır [23], çoğu zaman bir kalibrasyon aşaması gerektirirler [24], kullanıcının hareketini büyük ölçüde kısıtlayarak sistemin kullanımını zorlaştırır ya da gerçek hayat koşullarında başarılı sonuçlar elde edemezler [25] [26] [27]. Ayrıca kızılötesi kameralara bağlı sistemlerin gün ışığında gürbüzlüğü azalmaktadır [22]. Ticari sistemlerin bu tür problemlere yol açması sebebiyle, son zamanlarda literatürde herhangi bir kalibrasyon aşamasına iktiyaç duyulmadan [28] görünüm tabanlı çalışabilen sistemler [29] [30] yaygınlaşmaya başlamıştır.

1.3. Tezin Kapsamı

Bu tez çalışmasında son yıllarda çok sık kullanılan derin öğrenme yöntemlerinden KSA [31] modeli kullanılarak herhangi bir özel donanıma iktiyaç

duyulmadan göz bebeği merkezi gerçek zamanlı olarak tespit edilmiştir. Eğitim için dört ölçekte görüntü parçaları oluşturularak sistemin göz bölgesi dışından gelebilecek olası gürültülere karşı daha gürbüz olması sağlanmıştır [32]. Eğitim esnasında kullanılan ağ yapısı, literatürde yaygın olarak kullanılan AlexNet [33] ağ yapısıdır. Test aşamasında dört farklı yöntem uygulanarak çalışma hızları ve başarı oranları karşılaştırılmıştır. Tek bir web kamerası ile çalışabilen sistemin verilen bir görüntü üzerinde çalışma biçimi en basit haliyle Şekil 1.1’de görsel olarak anlatılmıştır. Web kamerası üzerinden elde edilen her bir görüntüyü sistem girdi olarak alıp, bu görüntüde yer alan göz bebeği merkezlerini gerçek zamanlı olarak tespit etmektedir. Elde edilen deney sonuçlarına göre sistem gerçek zamanlı olarak yüksek başarı oranına sahip bir şekilde çalışabilmektedir.




Şekil 1.1: Sistemin bir görüntü üzerinde göz bebeği merkezinin tespiti.

Tezin kalan bölümleri şu şekilde oluşturulmuştur: Bölüm 2’de literatürde yer alan göz bebeği merkezi tespiti ile ilgili yapılmış çalışmalar anlatılmıştır, Bölüm 3’te önerilen yöntemin eğitim aşaması veri kümesinin işleme adımları ile birlikte anlatılmıştır, Bölüm 4’te önerilen yöntemin test aşamaları anlatılmıştır, Bölüm 5’te önerilen yöntem üzerinde gerçekleştirilen deneyler ve bu deneylerin sonuçlarının literatür çalışmaları ile karşılaştırması yapılmıştır ve son olarak Bölüm 6’da ise gerçekleştirilen tez çalışmasına ait sonuçlar ve gelecekte bu alanda yapılabilecek çalışmalar anlatılmıştır.

2. İLGİLİ ÇALIŞMALAR

Son yıllarda yayınlanmış olan literatürdeki göz bebeği merkez noktasını tespit eden çalışmalar incelendiğinde, bir veya birden fazla özel donanım ve kamera gerektiren sistemlere alternatif olarak görünüm tabanlı olan ve tek web kamerası ile çalışan sistemler üzerinde sıklıkla çalışılmaya başlandığı görülmektedir. Tek web kamerası kullanan bu tür çalışmalar literatürde modele dayalı [34] [35] [36], özniteliğe dayalı [37] [38] ve hibrit [38] [39] olmak üzere 3'e ayrılmaktadır. Literatürde yer alan çalışmalar Şekil 2.1'de gruplanarak görselleştirilmiştir.



Şekil 2.1: Göz bebeği merkezi tespiti yapan literatür çalışmaları.

2.1. Model Tabanlı Yöntemler

Model tabanlı yaklaşımlar gözün bütünsel yapısını kullanarak göz bebeği merkezini tahmin etmeye çalışır. Bu tür yöntemler göz bebeği merkezini tahmin etmek için çoğu zaman bir öznitelik kümesi üzerinde sınıflandırma ya da regresyon yaparlar veya öğrenilmiş bir modeli göze uydurmaya çalışırlar [38]. Model tabanlı yöntemler makine öğrenmesi ve derin öğrenme tabanlı olmak üzere ikiye ayrılmaktadır.

2.1.1. Makine Öğrenmesi Tabanlı Yöntemler

Hamouz vd. [40] göz köşeleri ve göz bebeği merkezinin özniteliklerini çıkarmak için Gabor filtrelerini kullanmıştır. Daha sonra çıkarılan öznitelikleri kullanarak afin uzayda yüz hipotezlerini oluşturmuştur. En son olarak görünüm tabanlı bir model kullanılarak önceden seçilmiş yüz hipotezlerinin içerisinde en iyisi seçilmiştir.

Markus vd. [35] rastgele regresyon ağaçları topluluğu yöntemi kullanarak göz bebeği merkezi tespiti yapmaktadır. Bu yöntem MS Kinect [41]'in sağladığı insan vücudunun bölümlerini sınıflandırma yöntemindeki yaklaşımından yola çıkarak göz bebeği merkezi etrafındaki rastgele piksel farklarını kullanmaktadır.

Araujo vd. [42] önerdikleri çalışmalarında herhangi bir yüz modeli kullanmadan, Inner Product Detector (IPD) yöntemini kullanarak yüz üzerindeki önemli noktaları tahmin etmektedir. Yöntem korelasyon filtrelerini kullanmaktadır. Bu metodun avantajı istenen örüntülerdeki düşük varyansa olan toleransı, hesaplama maliyetinin düşük olması ve diğer özniteliklere genellenebilir olmasıdır.

Karakoc vd. [43] göz çevresinden elde edilen Yönlü Gradyan Histogramı (YGH) [44] özniteliklerinin Destek Vektör Regresör (DVR) modeli sayesinde öğrenilmesi ile göz bebeği merkezi tespiti yapmıştır. Elde edilen YGH özniteliklerinin etiket bilgileri için göz bölgesinden elde edilen görüntü parçalarının merkezinin parçasındaki göz bebeği merkezine olan öklid uzaklığı kullanılmıştır. Önerilen bu yöntemin farklı göz bakış açısı ve kafa pozisyonuna göre daha gülbüz sonuçlar verdiği gözlemlenmiştir.

Yine regresyon yöntemini kullanan başka bir çalışmada [45] ise göz üzerinde ortalama uydurulan nirengi noktaları başlangıç kabul edilecek şekilde artırılmış olarak uygulanan öğrenilmiş modeli sayesinde göz bebeğini de içeren bu noktaların daha doğru şekilde tespit edilmesi sağlanmıştır. Önerilen bu yöntemde kademeli bir regresyon çerçevesi kullanılmıştır. Her bir iterasyonda göz kapağı ve göz köşelerinden elde edilen öznitelikler birleştirilerek göz bebeği merkezi ve gözün açık ya da kapalı olma ihtimali tahmin edilmiştir. Eğitim için çok sayıda işaretlenmiş görüntü gerekeceğinden, yöntem standart veri kümelerinin yanı sıra oluşturduğu yapay bir veri kümesi de kullanmıştır.

Campadelli vd. [46] çalışmalarında Destek Vektör Makineleri (DVM) kullanarak, birden fazla modülden oluşan göz bebeği merkezi tespiti yapan bir yöntem önermişlerdir. Yöntem yüz bulucusu, göz bulucusu, ağız bulucuzu ve göz bebeği merkezi bulucusu olmak üzere dört farklı modülden oluşmaktadır. İlk modülde Haar

yöntemini kullanan çalışmada, diğer modüllerde DVM ikili sınıflandırıcısı kullanılmıştır.

AdaBoost [47] sınıflandırma algoritmasını kullanan bir çalışmada [48] 2 boyutlu katmanlı bir yapı uygulanarak göz bebeği merkezi tespit edilmiştir. Bu iki boyutlu katmanın ilkinde pozitif olan örnekler öğrenilmiş, ikincisinde ise negatif olan örnekler öğrenilmiştir. 2 katmanlı yapı devasa boyutlardaki eğitim veri kümesi üzerinde sınıflandırma yapmaya olanak tanımış, negatif ve pozitif örneklerdeki önemli değişimlerle kolaylıkla ilgilenebilmiş ve hem eğitim hem de test aşamasında sistemi oldukça verimli hale getirmiştir.

Everingham vd. [49] üç farklı yaklaşım ile göz bebeği merkezi tespiti gerçekleştirmişlerdir. Bu üç yaklaşımda da ilk önce literatürde yaygın olarak kullanılan bir yüz bulucu [50] sayesinde yüz ve göz alanları tespit edilmiştir. İlki olan regresyon modelinde, göz alanından elde edilen görüntü parçalarına karşılık göz pozisyonu öğrenilmiştir. İkinci yöntem, Bayesian yönteminde ise görüntü parçalarının göz olup olmamasına göre sınıflandırılması gerçekleştirilmiştir. Üçüncü yöntemde ise AdaBoost [47] sınıflandırıcısı kullanılmıştır. İki farklı veri kümesi üzerinde yapılan deney sonuçlarına göre Bayesian yöntemi en iyi performansı göstermiştir.

Kim vd. [51] çok ölçekli bir yaklaşım ile Gabot jetleri yöntemini kullanarak göz bebeği merkezini tespit etmektedir. Yöntemde ilk önce bir yüz bulucu sayesinde girdi görüntüsü üzerinde yüz alanını dikdörtgen şekilde bulunmuştur. Daha sonra tüm yüzlerin aynı boyutta olması için yüz görüntüsü sabit bir boyuta getirilerek normalleştirilmiştir. Sonrasında ise yüz alanı yeniden boyutlandırılarak küçültülmüş ve üç farklı ölçekte görüntü elde edilmiştir. Bir sonraki aşamada en küçük görüntü üzerinde Gabor jetleri benzerlik algoritmasına göre göz bebeği merkezi tespit edilmiştir. Bulunan bu noktalar daha büyük ölçekteki görüntüler üzerinde aynı algoritmanın çalıştırılması ile iyileştirilmiş ve nihai merkez noktalar elde edilmiştir.

DVM kullanan bir diğer çalışmada Chen vd. [52] DVM'nin yaşadığı performans problemine çözüm üretmek amacıyla daha verimli çalışan bir DVM modeli geliştirmişlerdir. Yöntem ilk önce Bayesian ayırt edici özellikler metodunu [53] kullanarak yüz bölgesini belirleyip normalize etmiştir. Sonrasında bazı geometrik kısıtlar ile göz alanı belirlenmiştir. Görüntü üzerinde yer alan çeşitli ışık değişimleri Gamma düzeltmeleri, Gaussian filtreleri ve kontrast eşitlemeleri ile azaltılmıştır. Yöntem ayırmacı Haar özniteliklerini kullanmaktadır. Daha sonra 2B Haar öznitelikleri

çıkarılarak verimli DVM sınıflandırıcısı eğitilmiştir. Eğitilen verimli DVM sayesinde test aşamasında gerçek zamanlı hıza yaklaşılmıştır.

2.1.2. Derin Öğrenme Tabanlı Yöntemler

Derin öğrenmenin popülerliğini artırması ile birlikte [54], derin öğrenme tabanlı göz bebeği merkezi tespit sistemleri üzerinde çalışılmaya başlanmıştır. Chinsatit vd. [55] çalışmalarında bir giyilebilir göz bakış açısı kestirimi sistemi için KSA tabanlı göz bebeği merkezi tespiti yöntemi önermiştir. Yöntemde kızılötesi göz görüntüleri kullanılmıştır. Çalışmada iki adet KSA kullanılmıştır. Bunlardan ilki kullanılarak gözün açık veya kapalı olma durumu sınıflandırılmış, ikincisi ile de göz bebeği merkezinin konumu tespit edilmiştir. İlkinde elde edilen sonuca göre eğer göz kapalı ise, ikinci aşamaya geçilmeden sistem sonlandırılmıştır.

Fuhl vd. [56] gürbüz göz bebeği merkezi tespiti için iki aşamalı KSA kullanan bir yöntem önermişlerdir. İlk aşamada sistem kabaca göz bebeği merkezinin konumunu tespit eder ve boyutu küçültülmüş görüntü üzerinde küçük göz alanları elde edilir. Bu sayede yöntem hesaplama işlemleri için gereken maliyeti düşürmüş olur. İkinci aşamada ise, ilk aşamadan kabaca elde edilen göz bebeği merkezlerinin etrafından alınan alanlar kullanılarak bir başka KSA algoritması çalıştırılıp ilk adımdaki pozisyon iyileştirilir. Yapılan deneylerde bu iyileşmenin başarıyı %25'e kadar artırdığı gözlemlenmiştir.

Amos vd. [57] mobil uygulamalarda kullanılabilecek genel amaçlı bir yüz tanıma kütüphanesi geliştirmişlerdir. Geliştirilen çalışmada, yüz modelini açıklamak için yüz üzerinde yer alan 68 tane özellik noktasını KSA modeli sayesinde eğitmişlerdir. Bu noktaların 12 tanesi için göz özellikleri göz çevresinden alınmıştır. Önerilen yöntemde halka açık yüz tanıma sistemleri ile özel olan yüz tanıma sistemleri arasındaki açığın kapatılması hedeflenmiştir.

Li vd. [58] önerdikleri çalışmada yüze ait görüntüler üzerinde kademeli KSA yöntemini kullanarak verimli bir şekilde göz bebeği merkezi tespit etmişlerdir. Yöntemde ilk önce bir grup aday göz bölgeleri tespit edilir, ardından bir KSA kümesi kullanılarak sol ve sağ göz bölgeleri belirlenir. En son olarak da bu göz bölgelerinde yer alan göz bebeği merkezleri diğer KSA modelleri kullanılarak tespit edilir. Önerilen yöntemin alternatiflere göre daha hızlı çalıştığı belirtilmektedir.

Saha vd. [59] derin öğrenme tabanlı bir göz bakış açısı kestirimi yöntemi önermişlerdir. Yöntemde, önerilen KSA mimarisi sayesinde tespit edilen gözlerden göz bakış açısı belirlenmiştir. Yöntem ayrıca literatürde yer alan veri kümelerinin yanı sıra kendi veri kümesini de oluşturmuştur. Ayrıca, önerilen algoritmanın üzerinde kullanıldığı, gerçek zamanlı robotik bir araç prototipi de geliştirmişlerdir.

Literatürdeki yer alan veri kümelerinin yetersiz olmasından yola çıkarak Eivazi vd. [60] çalışmalarında veri artırma yöntemlerini kullanarak eğittikleri KSA modeli sayesinde göz bebeği tespiti gerçekleştirmişlerdir. Alana özgü olarak da gerçekleştirilen bu veri artırımı işlemi farklı video'lerden faydalanılarak elde edilmiştir. Veri artırma işlemi görüntüyü yeniden boyutlandırma, gürültü ekleme ve kesme gibi teknikler ile yapılmıştır. Gerçek zamanlı olarak çalışabilen sistemin deney sonuçlarına göre başarılı sonuçlar verdiği gözlemlenmiştir.

Banke [61] gerçekleştirdiği çalışmada hiyerarşik yinelemeli ağ yapılarını kullanarak yüzü ve gözleri konumlandırmıştır. Yöntem karmaşık arka plana sahip, zorlu ışıktandırmalar içeren ve gürültüye sahip görüntüler üzerinde çalışabilmeyi amaçlamıştır. Sistemin eğitimi literatürde bilinen bir veri kümesinin yanısıra elle işaretlenmiş görüntüler de kullanılarak gerçekleştirilmiştir. Sistemin test aşamasında artırımı bir yaklaşım ile ilk olarak elde edilen sonuç iyileştirilmiş ve bu sayede bilinmeyen görüntüler üzerinde başarılı sonuçlar alınabilmektedir.

Derin öğrenme tabanlı yöntemler, geleneksel yöntemlerle karşılaştırıldığında yüksek gürbüzlük ve doğruluk sağlamaktadır. Ancak bununla beraber, verimli çalışabilmesi hala bir problemdir. Yüz görüntüleri çoğu zaman 640x480 boyutunda veya daha büyüktür. KSA kullanılarak görüntünün tamamı üzerinde göz bebeği merkezi aranmak istenirse, yüksek miktarda bilgisayar kaynağı gereksinimi doğacaktır. Bu nedenle, literatürde yalnızca seçilen aday bölgelerin KSA'ya girdi olarak verileceği şekilde aday bölgeleri tespit edebilen hızlı ve etkili bir yöntem gereklidir.

2.2. Öznitelik Tabanlı Yöntemler

Öznitelik tabanlı yöntemler herhangi bir öğrenme kullanmazlar. Bu tür yöntemler göz özelliklerini kullanarak yerel imge özniteliklerinden (köşeler, kenarlar, gradyanlar gibi) aday merkez noktaları elde etmeye çalışırlar.

Timm vd. [37] imge gradyanlarını analiz etmeye dayalı bir yöntem önermişlerdir. Önerdikleri yöntemde tüm gradyan vektörlerinin göz bebeği merkezinde kesiştiğini varsayan bir amaç fonksiyonu tanımlamışlardır. Bu yöntem göz bölgesinden elde edilen gradyan bilgilerini kullanma açısından DVR uygulanan yönteme [43] benzese de, DVR uygulanan yöntem kafa pozisyonu veya göz bakış açısı gibi değişimlere karşı çok daha gürbüz sonuçlar vermiştir.

Asadifard vd. [62] önerdikleri yöntemde CDF analizini kullanarak göz bebeği merkezini tespit etmektedir. Yöntemde ilk önce bilinen teknikler kullanılarak yüz ve göz bölgeleri belirlenmiş ve ardından göz bölgelerinin histogramı CDF analizi sayesinde çıkarılmıştır. Daha sonra elde edilen bu histogram bilgisinden göz kapağı ve iris pozisyonu belirlenerek merkez nokta tespit edilmiştir.

Leo vd. [63], iki adımdan oluşan gözetimsiz yöntem ile göz bebeği merkezi tespiti yapmışlardır. İlk adımda yerel bölgelerdeki görünüm değişiklikleri dikkate alınarak kendi kendine benzerlik bilgileri çıkarılmıştır. İkinci adımda ise, ilk adımdaki bu benzerlik bilgileri bir çeşit dairesel Hough dönüşümü (CHT) tabanlı dairesel şekil bulucu ile birleştirilerek merkez nokta tespit edilmiştir. Bu yöntem başarılı sonuçlar verebilse de hesaplama maliyeti yüksektir. Aynı yazarların bir başka çalışmalarında [64] görüntüdeki yoğunluğa ve benzerlik skorlarına göre elde edilen yerel görünüm değişiminin diferansiyel analizine dayalı bir yaklaşım kullanılmıştır. Diferansiyel analiz sayesinde yöntemin hesaplama maliyeti açısından daha verimli olması amaçlanmıştır.

Skodras vd. [65] düşük çözünürlüklü görüntüler üzerinde göz bebeği merkezinin kestirimini yapan bir yöntem önermişlerdir. Metot orijinal göz görüntüsü ve görüntü üzerindeki renk değerlerinden elde edilen göz haritası üzerinde yarıçapsal simetri transformunu kullanmaktadır. Renk değerlerinden elde edilen göz haritası iris alanını görüntü üzerinde vurgulamakta ve göz bebeği merkezinin kestirimini yapılmasında yardımcı olmaktadır.

Düşük çözünürlüklü görüntüler üzerinde göz bebeği merkezi tespitini amaçlayan bir başka çalışmada [66] ise iki aşamalı bir algoritma önerilmiştir. Yöntem gözün geometrik karakteristiğini kullanmaktadır. İlk aşamada önceden belirlenmiş yüzün irise olan oranı dikkate alınarak kabaca bir merkez nokta belirlenmiştir. Sonrasında ise RANSAC elips uydurma yöntemi [67] uygulanarak merkez nokta tespit edilmiştir.

Asteriadis vd. [68] gözün yalnızca geometrik bilgisini kullanarak göz bebeği merkezi tespitini amaçlayan bir çalışma gerçekleştirmişlerdir. Önerilen yöntemde ilk

aşamada bir yüz bulucusu aracılığı ile görüntü üzerindeki yüz alanı dikdörtgen şekilde tespit edilmiştir. Daha sonra ise elde edilen bu yüz alanı içerisinde göz alanları önceden tanımlanmış sol ve sağ göz yapılarına göre çalışan algoritma aracılığı ile bulunmuştur. Sonrasında ise Canny kenar bulma algoritması [69] kullanılarak tespit edilen göz alanları üzerindeki kenarlar bulunmuştur. Kenar tespitinden sonra göz alanında yer alan her bir piksel için en yakın kenara göre vektör ataması yapılmıştır. En nihayetinde ise elde edilen bu vektörlerin uzunluk ve eğim bilgileri kullanılarak gözler ve göz bebeği merkezleri tespit edilmiştir.

Özel donanım gerektiren bir diğer çalışmada Santini vd. [70] gözün geometrik bilgisini kullanarak bir göz takipçisi sistemi geliştirmişlerdir. Önerilen yöntem göz takipçisi cihazı ve kızılötesi kamera gerektirmektedir. Yöntemde ilk önce göz bölgesinden alınan görüntü belli bir oranda küçültülmüştür. Daha sonra küçültülen bu görüntü üzerinde literatürde çok yaygın olarak kullanılan Canny kenar bulma algoritması [69] ile kenar tespiti yapılmıştır. Sonrasında ise biçimbilimsel bir yaklaşım ile bulunan kenarlar keskinleştirilerek kenar bölütleri elde edilmiştir. Bir sonraki adımda da, elde edilen kenar bölütleri elips uydurma algoritmalarından geçirilerek göz bebeği olmaya aday bölütler seçilmiştir. Elde edilen aday bölütlerinden göz bebeğine en uygun olanı seçilirken elipslerin en-boy oranlarına, açısız kenar yayılımlarına ve anahat kontrastlarına bakılarak karar verilmiştir. En nihayetinde algoritma sadece göz bebeği merkezini değil göz bebeğini çevreleyen anahattı da tahmin etmiştir. Yöntem kafaya giyilebilen göz takipçisi cihazlardan alınmış çok sayıda görüntü üzerinde test edilmiştir.

Bai vd. [71] gözün simetrik yapısından faydalanarak göz bebeği merkezi tespiti yapmışlardır. Çalışmada ilk önce girdi görüntüleri 5x5 boyutundaki Gaussian filtresinden geçirilerek görüntü üzerindeki gürültüler temizlenmiştir. Daha sonra bir yüz bulucu aracılığı ile yüz ve göz alanları belirlenmiştir. Bir sonraki aşamada, gözün iris tabakasının çeşitli açılardan simetrik olmasından yola çıkılarak göz alanlarına açısız simetri dönüşümü uygulanması ile bir simetri haritası elde edilmiştir. Elde edilen bu simetri haritasına 5x5 boyutunda ortalama filtresi uygulanarak gürültüler kaldırılmıştır. Son olarak elde edilen gürültülerden arındırılmış simetri haritasına eşiklendirme işlemi yapılarak ikili bir görüntü elde edilmiştir. Elde edilen bu ikili görüntüdeki yüksek simetri bölgesinden göz bebeği merkezi belirlenmiştir.

Zhang vd. [72] iki ayrı yöntemden oluşan bir göz bebeği merkezi konumlandırıcısı geliştirmişlerdir. Çalışmada ilk önce literatürde yer alan pek çok

çalışmada olduğu gibi yüz ve göz alanları Viola vd. [50] tarafından önerilen metot ile tespit edilmiştir. İlk yöntemde göz çevresindeki eş aydınlık bilgileri kullanılmıştır. Gözün iris tabakası ve göz bebeğinin kenarlarında yer alan eş aydınlıklar, bu alanların geometrik özelliklerini göstermektedir. Bu bilgiden yola çıkılarak irisin ve göz bebeğinin kenarlarını takip eden eş aydınlıkların merkezi, göz bebeği merkezi olarak alınmıştır. İkinci yöntemde ise ilkinde elde edilen merkez noktalar gradyan tabanlı filtreler sayesinde iyileştirilmiştir.

2.3. Hibrit Yöntemler

Hibrit yöntemlerde ise hem öznitelik tabanlı yöntemler hem de model tabanlı yöntemler birlikte kullanılır. Her zaman olmasa da, genellikle ilk önce göz bebeği merkezi olmaya aday noktalar öznitelik tabanlı yöntemler kullanılarak belirlenir. Daha sonra model tabanlı yöntemler uygulanarak içlerinden göz bebeği merkezi olabilecek en optimal nokta seçilir.

Valenti vd. [38] göz bebeği merkezi olmaya aday olan noktaları eş aydınlıklar eğrisi yöntemi ile elde eder. Sonrasında ise her bir aday nokta için SIFT [73] öznitelik vektörü elde ederek, daha önce SIFT öznitelikleri ile eğittiği modeli ile nihai merkez noktayı tespit etmektedir.

Krron vd. [74] göz bebeği merkezi tespitinin yüz eşleştirme probleminin performansını ne ölçüde etkilediğine dair bir çalışma gerçekleştirmişlerdir. Çalışmada göz bebeği merkezi üç ayrı yöntem ile tespit edilmiştir. İlki olan model tabanlı yöntemde yüz üzerinden elde edilen göz bölgeleri eğitilerek merkez nokta tespit edilmektedir. İkinci yöntemde göz alanından elde edilen görüntüdeki karanlık piksellerden yola çıkılarak merkez nokta kestirilmektedir. Üçüncü yöntemde ise ikinci adımdan yola çıkılarak, öncesinde FLD [75] sınıflandırıcısı yardımı ile oluşturulan bir filtre uygulanarak merkez nokta tahmin edilmektedir.

Chen vd. [76] göz bebeği merkezi tespiti için kümeleme tabanlı diskriminant analizi yöntemi (CDA) önermişlerdir. Önerilen yöntem görüntüleri 2B Haar dönüşümleri ile temsil ettikten sonra CDA yöntemi sayesinde göz bölgesi için öznitelikleri elde etmektedir. Üç farklı CDA modeli kullanılan yöntemde, daha sonra bazı benzerlik ölçüleri ile birlikte en yakın komşu algoritması sayesinde sınıflandırma yapılmaktadır.

Hibrit olarak göz bebeği merkezi tespiti yapılan bir başka çalışmada [77] ilk önce kademeli regresyon modeli kullanılarak merkez nokta tespiti yapılmıştır. Daha sonra daire uydurma yöntemi sayesinde bulunan merkez nokta daha da iyileştirilmiştir. Ayrıca, elips uydurma yöntemi ile göz eşyükselti eğrileri kullanılarak gözler tam açık, yarı açık ve kapalı olacak şekilde sınıflandırılmıştır. Bu sınıflandırma sonucuna göre regresör ve daire uydurma yöntemleri kullanılmıştır.

Mobil bir göz takip sistemi olarak geliştirilen başka bir çalışmada [78] göz bakış açısı ilk olarak derin öğrenme yöntemlerinden KSA modeli sayesinde tespit edilmiş ve daha sonra gözün geometrik modelinden faydalanılarak tam doğru bakış açısı pozisyonu belirlenmiştir. Önerilen yöntemde özel donanım ve kalibrasyon aşamasına ihtiyaç duyulmaktadır.

Türkan vd. [79] çalışmalarında görüntü ve videolar üzerinde kenar projeksiyonu [80] yöntemleri ile göz bebeği merkezini tespit etmişlerdir. Yöntemde ilk aşamada yüz alanı üzerinde bir dalgacık dönüşümü filtresi uygulanarak göz bölgesinin kenarları belirlenmiştir. Daha sonra elde edilen bu kenar bilgilerinin yatay projeksiyonu sayesinde gözün aday noktaları elde edilmiştir. En sonunda ise bu aday noktalar içerisinde göz bebeği merkezi DVM sınıflandırıcısı sayesinde tespit edilmiştir.

Cristinacce vd. [81] önerdikleri çalışmada çoklu aşamadan oluşan bir yaklaşım ile yüze ait önemli noktaları tespit etmişlerdir. İlk adımda Viola ve Jones'un [50] önerdiği AdaBoost algoritması ile yüz ve göz bölgeleri dikdörtgen olarak tespit edilmiştir. Daha sonra yüz üzerinde tespit edilecek her bir önemli nokta için ayrı ayrı eğitilmiş bulucular çalıştırılmış ve önemli noktalar elde edilmiştir. Bir sonraki adımda önceki adımda elde edilen noktalar AAM arama algoritmasının kenar ve köşe özniteliklerine göre ayarlanmış bir versiyonu kullanılarak iyileştirilmiştir. Tüm bu aşamaların uygulanması sayesinde sonuçların iyileştiği görülmüştür.

Ren vd. [82] yaptıkları çalışmada, görüntülerin dönme açılarından bağımsız bir şekilde çalışabilen bir göz bebeği merkezi tespit sistemi geliştirmişlerdir. Yöntemde ilk önce gözün öznitelik tabanlı yapısal bilgileri SIFT [73] yöntemi ile elde edilmiştir. Yöntemin görüntünün dönmesine karşı gürbüz oluşu görüntüler üzerindeki gradyan yönlerini de bilgi olarak kullanmasından gelmektedir. Öznitelikler elde edildikten sonra iki sınıflı bir sınıflandırıcı (göz ve göz olmayan) eğitilmiştir. En son ise piramide benzer bir yaklaşım ile, sıcaklık haritası bir sınıflandırıcı kullanılarak elde edilmiş ve buradan da göz bebeği merkezleri tespit edilmiştir.

3. SİSTEMİN EĞİTİM AŞAMASI

Sistemin eğitim aşamasında ilk önce veri kümesi ön işlemten geçirilerek eğitilecek görüntü parçaları ve bu parçalar için gerekli olan etiket bilgileri oluşturulmuştur. Daha sonra ise elde edilen bu veri kümesi ve etiket bilgileri sayesinde kullanılan ağ yapısının eğitimi gerçekleştirilmiştir.

3.1. Veri Kümesinin Ön İşlemden Geçirilmesi

Sistemin eğitimi için veri kümesi ön işlemten geçirilirken ilk önce görüntüdeki göz bölgesinden rastgele bir nokta seçilmiştir. Daha sonra bu noktayı merkez alacak şekilde 4 farklı ölçekte görüntü parçaları elde edilmiştir. Elde edilen bu görüntü parçaları birleştirilerek Şekil 3.1'deki gibi nihai 64x64 boyutunda bir görüntü parçası oluşturulmuştur. Elde edilen 64x64 boyutundaki eğitime hazır görüntü parçaları için etiket bilgileri ise göz bebeği merkezinden (Şekil 3.1 üzerinde p_2) parçaların merkezine (Şekil 3.1 üzerinde p_1) olan Öklid uzaklığın (Şekil 3.1 üzerinde d) Denklem 3.1'de yer alan f fonksiyonuna girdi olarak verilmesi ile elde edilmiştir. d mesafesinin dört ölçekli görüntü parçasından elde edilmesi Şekil 3.1'de görsel olarak anlatılmıştır. Mesafe hesabının yapılabilmesi için dört ölçekli görüntü parçasında yer alan dört parçanın her biri kullanılabilir. Şekil üzerinde d mesafesinin elde edilmesi yalnızca sağ üst parça üzerinde gösterilmiştir.




Şekil 3.1: Dört ölçekli görüntü parçasından etiket fonksiyonunun parametresi olan d mesafesinin elde edilmesi.

Şekil üzerinde p_1 parçanın merkezi ve p_2 ise gerçekteki göz bebeği merkezidir. f fonksiyonu kullanılarak en fazla 80 piksel uzaklığa kadar olan mesafeler için etiket bilgisi üretilmiştir. Bu fonksiyon toplamda 25 farklı etiket bilgisi üretmektedir. Fonksiyonun ürettiği etiket bilgisi mesafenin piksel uzaklığı cinsinden 21'e kadar olduğu durumlarda mesafenin kendisini, 22 ile 30 arası olduğu durumlarda 22, 31 ile 50 arası olduğu durumlarda 23 ve 51 ile 80 arası olduğu durumlarda da 24 etiketini üretmektedir. Etiketlemenin mesafeye göre daha yavaş artması ile eğitilen modelin gürültüye karşı daha gürbüz olması sağlanmıştır.

$$f(d) = \begin{cases} 22 & 22 \leq d \leq 30 \text{ ise} \\ 23 & 31 \leq d \leq 50 \text{ ise} \\ 24 & 51 \leq d \leq 80 \text{ ise} \\ d & \text{diğer durumlarda,} \end{cases} \quad (3.1)$$

$$d = \sqrt{(p_{1x} - p_{2x})^2 + (p_{1y} - p_{2y})^2}$$


Sistemin eğitimi için görüntü parçaları oluşturulurken ilk önce göz bölgesinden göz bebeği merkezine uzaklığı en fazla 80 piksel olacak şekilde rastgele bir nokta seçilmiştir. Sonrasında ise elde edilen bu nokta görüntü parçasının merkez noktası olacak şekilde 32x32 ölçeğinde bir görüntü orijinal görüntüden eğitimi yapılacak 64x64 ebatında görüntünün sağ üst kısmına kaydedilmiştir. Daha sonra yine seçilmiş olan nokta görüntü parçasının merkez noktası olacak şekilde 64x64 ölçeğinde bir başka görüntü orijinal görüntüden alınarak 32x32 ölçeğine tekrar boyutlandırılmış ve eğitilecek görüntünün sol üst kısmına kaydedilmiştir. Sonrasına yine aynı şekilde seçilmiş noktanın görüntü parçasının merkez noktası olması şartı ile göz bölgesinden 128x128 ölçeğinde bir görüntü parçası alınmış, 32x32 ölçeğine tekrar boyutlandırıldıktan sonra eğitimi gerçekleştirilecek görüntü parçasının sol alt kısmına kaydedilmiştir. Son olarak yine bu seçilen noktanın merkezde olması kuralı ile ilgili göz bölgesinden 256x256 ölçeğinde bir görüntü parçası alınıp 32x32 ölçeğine tekrar boyutlandırılarak eğitimi yapılacak görüntü parçasının sağ alt kısmına kopyalanmış ve böylece dört ölçekli görüntü parçası elde etme aşamaları tamamlanmıştır. Göz bölgesinden göz bebeği merkezine uzaklığı en fazla 80 piksel olacak şekilde rastgele seçilen nokta eğer sağ gözden seçilmiş ise, farklı boyutlarda elde edilmiş görüntü parçaları yatay eksende tersi yönüne çevrilerek eğitimin tek gözden elde edilmiş görüntüler ile yapılması sağlanmıştır. 64x64, 128x128 ve 256x256 gibi farklı boyutlardan görüntü parçaları göz bölgesinden alınırken zaman zaman bu boyutlar orijinal görüntünün dışına taşmaktadır. Bu tür durumlarda orijinal görüntünün dışında kalan alanlar siyah renge boyanmıştır. Sıfır etiketi için göz bölgesinden dört ölçekli görüntü parçası elde etme aşamaları Şekil 3.2’de görsel olarak anlatılmıştır.



Şekil 3.2: Sıfır etiketi için dört ölçekli görüntü parçası elde etme aşamaları.


3.2. Ağ Yapısının Eğitimi

Dört ölçekli görüntü parçaları elde edildikten sonra sistemin eğitimi son zamanlarda derin öğrenme konusunda çok yaygın bir şekilde kullanılmaya başlanmış olan TensorFlow [83] kütüphanesi ile gerçekleştirilmiştir. TensorFlow, büyük ölçekte ve heterojen ortamlarda çalışabilen bir makine öğrenmesi kütüphanesidir. Sistemin eğitimi NVIDIA GTX 1050 Ti ekran kartı ile gerçekleştirilmiştir. Eğitim için ağ yapısı olarak AlexNet [33] kullanılmıştır. AlexNet, 2012 yılında ImageNet [84] veri kümesinin bir alt kümesini kullanarak LSVRC yarışmasını [85] kazanmış olan ağ yapısıdır. Yarışmada kullanılan veri kümesinde 1000 farklı sınıfa ait yaklaşık 1.2 milyon yüksek çözünürlüklü görüntü yer almaktadır. AlexNet ağının yapısı Şekil 3.3'de yer almaktadır.



Şekil 3.3: AlexNet ağ yapısı.

AlexNet varsayılan olarak 224x224 boyutlarında görüntüleri girdi olarak almakta ve 1000 farklı kategori için sınıflandırma yapmaktadır. Önerilen yöntemde üretilen dört ölçekli görüntü parçaları 64x64 boyutunda ve tahmin edilen sınıf sayısı da 25 olduğu için AlexNet'in ağ yapısı girdi görüntüsü 64x64 ve çıktı sınıf sayısı da 25 olacak şekilde yeniden yapılandırılmıştır. Yapılandırılan bu yeni ağ Şekil 3.4'de görsel olarak anlatılmıştır.



Şekil 3.4: Sistemin eğitiminde kullanılan ağ yapısı.

4. SİSTEMİN TEST AŞAMASI


Sistemin test aşaması ağırlıklı ortalama, kaba kuvvet araması tabanlı rastgele nokta, optimizasyon tabanlı rastgele nokta ve iki aşamalı optimizasyon tabanlı rastgele nokta olmak üzere dört farklı yöntem ile gerçekleştirilmiştir.

4.1. Ağırlıklı Ortalama Yöntemi

Sitemin ağırlıklı ortalama ile çalışan test aşaması Şekil 4.1’de anlatılmıştır. Sisteme girdi olarak bir görüntü alınmış ve ilk önce yüksek başarı oranına sahip olan ve gerçek zamanlı olarak çalışması ile bilinen Haar [50] yöntemi kullanılarak görüntüdeki yüz ve göz bölgeleri dikdörtgen olarak belirlenmiştir (E_L ve E_R). Daha sonra ise belirlenen bu göz alanları üzerinde kayan pencere yöntemiyle [86] alandaki her bir piksel noktası için Şekil 3.2’de yer alan eğitim aşamasında oluşturulduğu şekilde dört ölçekli görüntü parçaları oluşturulmuştur ($P_L^1, P_L^2, P_L^3, \dots, P_L^m$ ve $P_R^1, P_R^2, P_R^3, \dots, P_R^m$). Görüntü parçaları oluşturulurken sağ gözden elde edilen parçalar (P_R^m) yatay ekseninde tersi yönüne döndürülerek test aşamasında görüntülerin tamamının sol gözden elde edilmiş olması sağlanmıştır. En nihayetinde elde edilen tüm bu görüntü parçaları için parçanın merkez noktasının göz bebeği merkezine uzaklığını veren etiket bilgisi, öğrenilmiş model sayesinde tahmin edilmiştir ($s_L^1, s_L^2, s_L^3, \dots, s_L^m$ ve $s_R^1, s_R^2, s_R^3, \dots, s_R^m$). Daha sonra ise, tahmin edilen etiket bilgileri ile bir skor görüntüsü oluşturulmuş ve bu etiketlerin bulunduğu noktaların ağırlıklı ortalamaları Tablo 4.1’de yer alan katsayılara göre (sabit, lineer ve üstel olarak değişen) alınarak nihai göz bebeği merkezi tahmin edilmiştir. Ağırlıklı ortalama hesabına ağ çıktısı olarak elde edilen ve 0 ile 1 arasında değişen ağ güven değeri de dahil edilmiştir.


Tablo 4.1: Ağırlıklı ortalama yöntemi için etiket katsayı bilgileri.

Etiket	Sabit Katsayı	Lineer Katsayı	Üstel Katsayı
0	1	6	32
1	1	5	16
2	1	4	8
3	1	3	4
4	1	2	2
5	1	1	1



Şekil 4.1: Sistemin ağırlıklı ortalama yöntemi ile çalışan test aşaması.

Farklı büyüme şekilleri için katsayıların etiketlere göre değişimini gösteren grafik Şekil 4.2’de yer almaktadır.



Şekil 4.2: Ağırlıklı ortalama yöntemi için farklı büyüme şekillerine göre etiket katsayı dağılımları.

Ağırlıklı ortalama hesabı yapılırken Denklem 4.1’de yer alan formüller kullanılmıştır. Burada $\bar{x}$ ve $\bar{y}$ nihai tahmin edilen göz bebeği merkezini, n ağırlıklı ortalaması alınan etiket sayısını (0, 1, 2, 3, 4 ve 5 olmak üzere toplamda 6), m ilgili etiket bilgisinin tahmin edildiği nokta sayısını, x_{ij} ve y_{ij} ilgili etiketin tahmin edildiği noktanın konum bilgilerini, w_i tahmin edilen etiket bilgisine denk gelen ağırlıklı ortalama katsayısını ve c_i ise ağ çıktısından elde edilen güvenilirlik değerini ifade etmektedir.


$$\bar{x} = \frac{\sum_{i=1}^n \sum_{j=1}^m (x_{ij} \times w_i \times c_i)}{\sum_{i=1}^{n+m} (w_i \times c_i)} \quad (4.1)$$

$$\bar{y} = \frac{\sum_{i=1}^n \sum_{j=1}^m (y_{ij} \times w_i \times c_i)}{\sum_{i=1}^{n+m} (w_i \times c_i)}$$

4.2. Kaba Kuvvet Araması Tabanlı Rastgele Nokta Yöntemi

Kaba kuvvet araması tabanlı rastgele nokta yöntemi ile çalışan test aşamasının tüm adımları Şekil 4.3’de gösterilmiştir. Bu yöntemde de ilk önce yüz ve göz alanları ağırlıklı ortalama yöntemi ile aynı şekilde belirlenmiştir (E_L ve E_R). Daha sonra göz alanında rastgele n tane nokta seçilerek bu noktalar için dört ölçekli görüntü parçaları oluşturulmuştur ($P_L^1, P_L^2, P_L^3, \dots, P_L^m$ ve $P_R^1, P_R^2, P_R^3, \dots, P_R^m$). Bu görüntü parçaları oluşturulurken ilgili gözün sağ göz olması durumunda görüntü parçası yatay ekseninde tersine çevrilerek testin tek gözden elde edilmiş görüntüler ile yapılması sağlanmıştır. Görüntü parçaları eğitim aşamasında üretildiği şekilde (Şekil 3.2) oluşturulmuştur. Sonrasında elde edilen n adet görüntü parçası için etiket bilgileri, eğitilmiş olan modele sorularak tahmin edilmiştir ($s_L^1, s_L^2, s_L^3, \dots, s_L^m$ ve $s_R^1, s_R^2, s_R^3, \dots, s_R^m$). Elde edilen her bir etiket bilgisi, yarıçapı etiket kadar olan ve idealde göz bebeği merkezi ile teğet geçmesi beklenen daireler oluşturmaktadır. Örnek bir test görüntüsü üzerinde sol göz için rastgele seçilen noktalardan elde edilen görüntü parçalarının modele sorularak tahmin edildiği etiket bilgilerinin oluşturduğu daireler Şekil 4.4’de gösterilmiştir. Son adım olarak elde edilen bu dairelere mesafesi en az olan nokta belirlenmiştir. Dairelere mesafesi en az olan nokta belirlenirken göz alanı içerisinde yer alan tüm noktaların, elde edilen tüm dairelere olan uzaklıkları ayrı ayrı hesaplanmıştır. Bu hesaplama sonucunda en az bulunan mesafe değerine denk gelen nokta, göz bebeği merkezi olarak kabul edilmiştir. Göz alanındaki bir nokta için tüm dairelere olan mesafenin hesaplanmasında Denklem 4.2’de yer alan formül kullanılmıştır.

$$d = \sum_{i=1}^n \left| \sqrt{(x - c_{x_i})^2 + (y - c_{y_i})^2} - r_i \right| \quad (4.2)$$



Şekil 4.3: Sistemin kaba kuvvet araması tabanlı rastgele nokta yöntemi ile çalışan test aşaması.



Şekil 4.4: Sol göz için rastgele oluşturulan görüntü parçalarının göz bebeği merkezine olan uzaklığının tahmin edilmesi ile oluşan daireler.

4.3. Optimizasyon Tabanlı Rastgele Nokta Yöntemi

Kaba kuvvet araması tabanlı rastgele nokta yöntemi kabul edilebilir düzeydeki n değerleri için model üzerindeki sorgulama işlemleri açısından kıyaslandığında ağırlıklı ortalama yöntemine göre epey zaman kazandırsa da, tüm göz alanı için her bir noktanın teker teker dairelere olan uzaklığının hesaplanması sebebi ile zaman kaybettirmektedir. Bu sebeple geliştirilen optimizasyon tabanlı yöntemde, göz alanındaki her bir nokta için ayrı ayrı mesafe hesabı yapmak yerine, optimizasyon yöntemi kullanılarak dairelere olan mesafesi en az olan nokta çok daha hızlı bir şekilde hesaplanmıştır.


Sistemin optimizasyon tabanlı çalışan test aşaması Şekil 4.5’de adım adım anlatılmıştır. Yine ilk önce diğer yöntemlerdeki gibi yüz ve göz alanları Haar tekniği ile belirlenmiştir (E_L ve E_R). Sonraki adımda ise kaba kuvvet araması tabanlı rastgele

nokta yöntemindeki şekilde göz alanında rastgele n tane nokta seçilerek bu noktalar için Şekil 3.2’de anlatıldığı gibi dört ölçekli görüntü parçaları oluşturulmuştur ($P_L^1, P_L^2, P_L^3, \dots, P_L^m$ ve $P_R^1, P_R^2, P_R^3, \dots, P_R^m$). Sistemin eğitimi tek gözlü olarak gerçekleştirildiği için, görüntü parçaları oluşturulurken arama yapılan göz sağ göz ise görüntü parçası yatay hizada tersine çevrilmiştir. Bir sonraki adımda elde edilen n adet görüntü parçası için etiket bilgileri, eğitilmiş olan model üzerinde sorgulanarak tahmin edilmiştir ($s_L^1, s_L^2, s_L^3, \dots, s_L^m$ ve $s_R^1, s_R^2, s_R^3, \dots, s_R^m$). Son olarak elde edilen etiket bilgilerinin oluşturduğu dairelere (Şekil 4.4) olan mesafesi en yakın olan nokta optimizasyon algoritması ile hesaplanmıştır.

Optimizasyon algoritması olarak Nelder Mead simplex algoritması [87] kullanılmıştır. Bu algoritma n değişkenli bir fonksiyonun en aza indirilmesi için kullanılmaktadır. Algoritmaya göre en aza indirme işlemi genel simplex’in $(n + 1)$ tepe noktalarındaki fonksiyon değerlerinin karşılaştırılmasına ve ardından en yüksek değerli tepe noktasının başka bir nokta ile yer değiştirilmesine bağlıdır. Algoritma kendisini yerel manzaraya göre ayarlamakta ve nihayetinde minimum noktaya ulaşmaktadır. Yöntemin etkili ve hesaplama açısından kompakt olduğu yapılan çalışmada gösterilmiştir. Nelder Mead Simplex algoritması kullanılarak en aza indirilen fonksiyon Denklem 4.3’de verilmiştir.

$$x, y \leftarrow \underset{x, y}{\operatorname{argmin}} \sum_{i=1}^n \left| \sqrt{(x - c_{x_i})^2 + (y - c_{y_i})^2} - r_i \right| \quad (4.3)$$

x ve y değerlerinin oluşturduğu nokta optimizasyon algoritması sayesinde en aza indirgeme işlemi ile elde edilecek olan noktadır. En aza indirgeme işlemi, göz alanında yer alan tüm noktalar için, rastgele seçilen noktaların oluşturduğu dairelere olan mesafe değerlerine göre gerçekleştirilmiştir. Formülde n göz bölgesinden rastgele seçilmiş olan nokta sayısını, i göz bölgesinden rastgele seçilen noktaların indeksini, c_{x_i} ve c_{y_i} ilgili rastgele noktanın konumunu (Şekil 4.4’deki dairelerin merkezi) ve r_i ise rastgele nokta için tahmin edilen göz bebeği merkezine olan uzaklığı (Şekil 4.4’deki dairelerin yarıçapı) ifade etmektedir. x ve y değerleri ise tahmin edilen göz bebeği merkezini göstermektedir.



Şekil 4.5: Sistemin optimizasyon tabanlı rastgele nokta yöntemi ile çalışan test aşaması.

4.4. İki Aşamalı Optimizasyon Tabanlı Rastgele Nokta Yöntemi


Tek aşamadan oluşan optimizasyon tabanlı yöntemdeki başarının daha da iyileştirilebilmesi için iki aşamalı bir yöntem daha geliştirilmiştir. Bu sayede ilk aşamada bulunan göz bebeği merkezleri, ikinci aşama aracılığı ile iyileştirilmiş ve sistemin başarı oranı artırılmıştır.

4.4.1. Birinci Aşama

Şekil 4.6’de yer alan sistemin iki aşamalı test aşamasının ilk aşamasının ilk adımında, sisteme girdi olarak alınan görüntü üzerinde yine ilk önce Haar yöntemi ile yüz ve göz bölgeleri dikdörtgen biçimde elde edilmiştir. Şekil üzerindeki E_L ve E_R alanları dikdörtgen şeklinde bulunan göz bölgelerini göstermektedir.

Göz alanından rastgele noktalar alınarak göz bebeği merkezinin tespit edilmesi hız açısından fayda sağlasa da, seçilen rastgele noktaların gözün belli bir bölgesinde yoğunlaşması da mümkün olabilmektedir. Bu durum sistemin doğruluğunu azaltmaktadır. Bu nedenle bu probleme çözüm olarak göz alanından doğrudan rastgele nokta seçmek yerine alan ilk önce 9 eşit bölgeye ayrılmış ve sonrasında elde edilen her bir bölgeden rastgele bir nokta seçilerek işlemlere devam edilmiştir.


Rastgele seçilen bu noktaların her biri için sistemin eğitim aşamasında elde edildiği şekilde (Şekil 3.2) dört ölçekli görüntü parçaları elde edilmiştir ($P_L^1, P_L^2, P_L^3, \dots, P_L^m$ ve $P_R^1, P_R^2, P_R^3, \dots, P_R^m$). Bu görüntü parçaları elde edilirken ilgili göz eğer sağ göz ise görüntü parçası yatay ekseninde tersi yönüne çevrilerek testin tek gözden elde edilmiş görüntüler ile yapılması sağlanmıştır. Sonrasında ise elde edilen bu görüntü parçaları eğitilmiş olan modele sorularak 0 ile 25 aralığında etiket bilgileri elde edilmiştir. Elde edilen bu etiket bilgileri yarıçapı etiket kadar olan ve idealde göz bebeği merkezi ile teğet geçmesi beklenen daireler oluşturmuştur (Şekil 4.4). Nihai olarak elde edilen bu 9 daireye en yakın olan nokta Nelder Mead Simplex algoritması kullanılarak Denklem 4.3’de yer alan fonksiyonun en aza indirilmesi ile hesaplanmıştır. Nelder Mead Simplex algoritması kullanılarak 9 daireye en yakın olan nokta bulunduktan sonra ikinci aşamaya geçilmiştir.



Şekil 4.6: Sistemin iki aşamalı optimizasyon tabanlı rastgele nokta yöntemi ile çalışan test aşamasının birinci aşaması.

4.4.2. İkinci Aşama

Bu aşamada ilk önce ilk aşamada bulunan merkez noktaların 3 piksel yukarısındaki nokta, 3 piksel sağındaki nokta, 3 piksel aşağısındaki nokta ve 3 piksel solundaki noktalar alınarak yeniden Şekil 3.2'deki algoritmaya göre dört ölçekli görüntü parçaları elde edilmiştir. Bu şekilde sol gözden 4 ve sağ gözden 4 olmak üzere 8 farklı dört ölçekli görüntü parçası elde edilmiştir. Ardından elde edilen bu görüntü parçaları eğitilmiş olan modele sorularak 0-25 aralığındaki etiket bilgileri tahmin edilmiştir. Tahmin edilen bu etiket bilgileri ilk adımda olduğu gibi yarıçapı etiket kadar olan ve idealde göz bebeği merkezi ile teğet geçmesi beklenen daireler oluşturmuştur. En son adımda ise elde edilen bu dairelere en yakın olan nokta yine Nelder Mead Simplex algoritması sayesinde Denklem 4.3'de yer alan fonksiyonun en aza indirilmesi ile elde edilmiştir. En aza indirgeme yöntemi ile elde edilen bu noktalar nihai göz bebeği merkezi olarak kabul edilmiştir. Sistemin iki aşamalı optimizasyon tabanlı test aşamasının ikinci aşaması Şekil 4.7'de anlatılmıştır.



Şekil 4.7: Sistemin iki aşamalı optimizasyon tabanlı rastgele nokta yöntemi ile çalışan test aşamasının ikinci aşaması.

5. DENEYLER

Sistemin deneyleri esnasında literatürde göz bebeği merkezinin kestirimi ile ilgili çalışmalarda sıkça kullanılan BioID görüntü veri kümesi [88] kullanılmıştır. Bu veri kümesi çeşitli zorlu durumları içeren görüntülere sahiptir. Veri kümesinde değişik konumlarda ve zamanlarda çekilmiş 1500’ün üzerinde görüntü yer almaktadır. Bu görüntüler gri tonlu olarak sunulmuştur. Veri kümesinde yer alan genişliği 384 ve yüksekliği ise 286 pikselden oluşan bu görüntüler, çözünürlüklerinin düşük olması sebebi ile üzerlerinde deneylerin koşulmasını zorlaştırmıştır. Bazı görüntüler üzerinde çeşitli yansımalar olmasından dolayı anlaşılması güç halde, bazıları kaydedildiği ortamın ışığı gereği görünürlüğü düşük durumda ve bazıları ise çok uzak bir noktadan kaydedilmiş olması sebebiyle anlaşılması çok güç göz bebekleri içermektedir. Görüntüler hem kadın hem erkek denekler üzerinden elde edilmiştir. Deneklerin bazıları gözlük kullanırken bazıları ise kullanmamaktadır. BioID görüntü veri kümesi, tüm bu yönleri ile göz bebeği merkezi tespit sistemleri için oldukça zorlayıcı bir veri kümesidir.

Sistemin BioID veri kümesi kullanılarak gerçekleştirilen test aşamalarında, veri kümesinde yer alan 24 farklı kişi 8 ayrı gruba ayrılmıştır. Elde edilen her bir grup kalan 7 grup ile eğitilmiş olan model üzerinde test edilmiştir. Böylece 7 gruba ait her bir 21 kişi, kalan 1 gruptaki 3 kişi ile test edilerek test aşamasında yer alan kişilere ait görüntülerin eğitim aşamasında yer almaması sağlanmıştır. Bu şekilde sistemin gürbüzlüğü literatürde yer alan alternatif yöntemlere göre daha doğru şekilde hesaplanmıştır. Literatürde yer alan öğrenme tabanlı alternatif yöntemler veri kümelerini nasıl ayırdıklarına dair detaylı bilgi vermemişlerdir. Sistemin doğruluk oranı literatürde göz bebeği merkezi tespiti yapan çalışmalar tarafından yaygın bir şekilde kullanılan normalize edilmiş hata bilgisi ile belirlenmiştir. Normalize edilmiş hata bilgisi Jesorsky vd. [89] tarafından kullanılan formül ile hesaplanmıştır. 0 ile 1 arasında değişen değerler üreten bu formül sonucunda elde edilen değer 0’a yakın olması, sistemin başarılı sonuçlar ürettiğini göstermektedir. Kullanılan normalize edilmiş hata değerini hesaplayan formül Denklem 5.1’de verilmiştir.

$$e \leq \frac{\max(e_L, e_R)}{d}$$

$$e_L = \sqrt{(g_{Lx} - p_{Lx})^2 - (g_{Ly} - p_{Ly})^2}$$

$$e_R = \sqrt{(g_{Rx} - p_{Rx})^2 - (g_{Ry} - p_{Ry})^2}$$

$$d = \sqrt{(g_{Lx} - g_{Rx})^2 - (g_{Ly} - g_{Ry})^2}$$
(5.1)

Burada e_L ve e_R sol ve sağ göz için sistemin tahmininde bulunduğu göz bebeği merkezi ile gerçekte olan göz bebeği merkezi arasındaki Öklid mesafelerdir. g_{Lx} ve g_{Ly} gerçekteki sol göz bebeği merkezi konumunu, p_{Lx} ve p_{Ly} sistemin tahmin ettiği sol göz bebeği merkezi konumunu, g_{Rx} ve g_{Ry} gerçekteki sağ göz bebeği merkezi konumunu ve son olarak p_{Rx} ve p_{Ry} sistemin tahmin ettiği sağ göz bebeği merkezi konumunu ifade etmektedir. d değeri ise gerçekte olan sol ve sağ göz bebeği merkezlerinin arasındaki Öklid mesafedir. Formülde yer alan e_L , e_R ve d değerleri BioID veri kümesinden alınmış örnek bir görüntü üzerinde Şekil 5.1’de gösterilmiştir. Şekil üzerinde artı işareti gerçekteki göz bebeği merkezlerini gösterirken, çarpı işareti sistemin tahmin ettiği göz bebeği merkezlerini göstermektedir.



Şekil 5.1: Hata ölçüm metriği değerlerinin görselleştirilmesi.


Formül sonucunda elde edilen değer, tahmin edilen göz bebeği merkezlerinin yüz üzerinde hangi bölgeye denk geldiği hakkında aşağı yukarı bir bilgi vermektedir. Hesaplanan hata değerinin $e \leq 0.05$ olması tespit edilen göz bebeği merkezinin göz bebeğinin içerisinde, $e \leq 0.1$ olması tespit edilen göz bebeği merkezinin göz iris tabakasının içerisinde ve $e \leq 0.25$ olması ise tespit edilen göz bebeği merkezinin göz alanının içinde olduğunu göstermektedir.

Sistemin deneyleri dört farklı test aşaması için BioID veri kümesi üzerinde ayrı ayrı koşulmuştur. İlk önce ağırlıklı ortalama yöntemi için sabit, lineer ve üstel olan etiket-katsayı ilişkisi büyüme şekillerinin başarıya olan etkisi, ağ güvenilirlik değeri de hesaba katılarak ölçülmüştür. Bu parametrelerle gerçekleştirilen deneylere ait sonuçlar Tablo 5.1’de verilmiştir.

Tablo 5.1: Ağırlıklı ortalama yönteminin farklı parametrelerle gerçekleştirilen deney sonuçlarının karşılaştırılması.


Ağırlıklı Ortalama Yöntemi	$e \leq 0.05$	$e \leq 0.1$	$e \leq 0.25$
Sabit	%91,2	%99,9	%100
Sabit + Ağ Güvenilirliği	%93,8	%99,9	%100
Lineer	%97,8	%100	%100
Lineer + Ağ Güvenilirliği	%97,9	%99,9	%100
Üstel	%98,2	%99,9	%100
Üstel + Ağ Güvenilirliği	%98,6	%99,9	%100

Deney sonuçlarının farklı $0.05 \leq e \leq 0.15$ değerleri ile görsel olarak kıyaslanması ise Şekil 5.2’de verilmiştir. Gerçekleştirilen deney sonuçlarına göre sistem ağ güvenilirlik bilgisini kullandığında daha yüksek başarı oranları elde etmektedir. Ağırlıklı ortalama yöntemi için en başarılı parametre üstel etiket-katsayı değişiminin ağ güvenilirlik bilgisi ile birlikte kullanılması sonucunda elde edilmiştir. En başarısız sonuç ise sabit etiket-katsayı değişiminin ağ güvenilirlik bilgisi kullanılmaması ile elde edilmiştir. Ağırlıklı ortalama yönteminin diğer üç test yöntemi ile yapıldığı karşılaştırmalarda en başarılı olan parametrelerle elde edilen deney sonuçları (üstel + ağ güvenilirliği) kullanılmıştır.



Şekil 5.2: Ağırlıklı ortalama yönteminin farklı parametrelerle gerçekleştirilen deney sonuçlarının karşılaştırılması.


Dört ayrı test yönteminin birbiri ile sağlıklı olarak karşılaştırılabilmesi için ilk önce kaba kuvvet araması tabanlı rastgele nokta yöntemi ve optimizasyon tabanlı rastgele nokta yöntemi için n değişkeninin alacağı değere karar verilmiştir. Sistem bu iki test aşaması için $3 \leq n \leq 20$ aralığındaki tüm n değerleri için çalıştırılmıştır. Deneyler sırasında çalıştırılan yöntemler sırası ile önce yüz ve göz alanı tespiti, sonrasında görüntü önışleme, daha sonra eğitilmiş model üzerinde etiket tahmini ve son olarak da dairelere olan mesafe hesabını yaparak nihai göz bebeği merkezine ulaşmaktadır. Göz alan tespiti tüm yöntemlerde ortak adım olduğu için karşılaştırma verilerine eklenmemiştir.



Şekil 5.3: Kaba kuvvet araması ve optimizasyon tabanlı rastgele nokta yöntemleri için her bir adımda n değişkenine göre ortalama geçen süreler.

Şekil 5.3’de, kaba kuvvet araması ve optimizasyon tabanlı çalışan rastgele nokta yöntemlerinin farklı n değerleri üzerinde gerçekleştirilmiş deneyler sonucunda, test aşamasının her bir adımında geçen ortalama süreler gösterilmiştir. Görüntü önileme ve etiket tahmin adımları ortak olmasından dolayı iki yöntem için sonuçları ayrı ayrı eklenmemiştir. Mesafe hesabının optimizasyon algoritması sayesinde çok daha hızlı yapılabildiği şekil üzerinde açıkça görülmektedir. İki test yöntemi arasındaki çalışma hızı farkı artan n değerlerine göre üstel bir biçimde artmaktadır.

$3 \leq n \leq 20$ aralığında çalıştırılan optimizasyon tabanlı rastgele nokta yöntemi için $e \leq 0.05$, $e \leq 0.1$ ve $e \leq 0.25$ değerlerinde elde edilen başarı oranları Şekil 5.4’de gösterilmiştir. Bu başarı oranları kaba kuvvet araması tabanlı rastgele nokta yönteminde de çok benzer olduğu için şekilde sonuçları eklenmemiştir.



Şekil 5.4: Optimizasyon tabanlı rastgele nokta yöntemi için değişen n değerlerinde elde edilen başarı oranları.

Şekil 5.3'den anlaşılacağı gibi göz alanından alınan rastgele nokta sayısı (n) arttıkça sistem üzerinde yavaşlamalar olmaktadır. Başarı oranı ise Şekil 5.4'e göre n 'in belli bir seviyeye kadar artması ile artmakta ancak sonrasında benzer seyretmektedir. Bu bilgiler ışığında, bu iki yöntemin diğer yöntemlerle (ağırlıklı ortalama ve iki aşamalı optimizasyon tabanlı rastgele nokta) daha sağlıklı karşılaştırılabilmeleri için $n = 9$ alınarak deneyler gerçekleştirilmiştir. $n = 9$ seçilmesinin ilk sebebi bu iki yöntemin $n = 9$ için optimal bir başarı oranı ve çalışma hızı elde etmeleridir. Diğer nedeni ise iki aşamalı optimizasyon tabanlı rastgele nokta yönteminde gözün 9 eşit parçaya bölünerek aynı sayıda rastgele nokta elde edilmesidir.


Sistemin verilen bir görüntü üzerindeki ortalama göz bebeği merkezlerini bulma zamanının dört farklı algoritma için karşılaştırması Tablo 5.2'de verilmiştir. Sonuçlarda yer alan ortalama geçen zaman dört adımda (göz alanı tespiti, görüntü ön işleme, etiket tahmini ve mesafe hesabı) ölçülen zamanların toplamının ortalamasıdır. Haar yöntemi ile yapılan göz alanı tespiti bir görüntü için ortalama 18,8 milisaniye sürmüştür. Sonuçlara göre en yavaş çalışan yöntem ağırlıklı ortalama

yöntemi ve en hızlı çalışan yöntem optimizasyon tabanlı rastgele nokta yöntemi olarak çıkmıştır.

Tablo 5.2: Dört farklı test yönteminin çalışma zamanına göre karşılaştırılması.

Yöntem	Ortalama Geçen Zaman (milisaniye)	FPS
Ağırlıklı Ortalama	522,8	1,9
Kaba Kuvvet Araması Tabanlı Rastgele Nokta $n = 9$	149,4	6,7
Optimizasyon Tabanlı Rastgele Nokta $n = 9$	82,3	12,1
İki Aşamalı Optimizasyon Tabanlı Rastgele Nokta	118,0	8,4

Yalnızca mesafe hesabı yapılan yöntemlerin dört adımdan her biri için bir görüntü üzerindeki ortalama çalışma süreleri Şekil 5.5’de gösterilmiştir. Şekil üzerinden kaba kuvvet araması tabanlı çalışan rastgele nokta yönteminin mesafe hesabı için harcadığı zamanın neredeyse toplam geçen zamanın yarısı kadar olduğu görülmektedir. Optimizasyon algoritması kullanılan yöntemde ise mesafe hesabı için ortalama geçen zaman toplam ortalama geçen zamanın yalnızca altıda biri kadardır.




Şekil 5.5: Mesafe hesabı yapılan test yöntemlerinin her bir adımında ortalama geçen zamanın karşılaştırılması.

Dört farklı test yönteminin başarı oranları açısından karşılaştırması ise Tablo 5.3’de verilmiştir. Sonuçların farklı $0.05 \leq e \leq 0.15$ değerlerine göre karşılaştırmaları Şekil 5.6’de yer almaktadır. Elde edilen deney sonuçlarına göre $e \leq 0.05$ için en başarılı olan yöntem ağırlıklı ortalama ve $e \leq 0.1$ için en başarılı olan yöntem iki aşamalı optimizasyon tabanlı rastgele nokta olurken, $e \leq 0.25$ için tüm test yöntemleri ile aynı başarı oranlarını elde etmiştir.

Tablo 5.3: Sistemin farklı test yöntemlerinin doğruluk oranına göre karşılaştırılması.

Yöntem	$e \leq 0.05$	$e \leq 0.1$	$e \leq 0.25$
Ağırlıklı Ortalama (Üstel + Ağ Güvenilirliği)	%98,6	%99,9	%100
Kaba Kuvvet Araması Tabanlı Rastgele Nokta $n = 9$	%96,4	%99,9	%100
Optimizasyon Tabanlı Rastgele Nokta $n = 9$	%95,9	%99,9	%100
İki Aşamalı Optimizasyon Tabanlı Rastgele Nokta	%98,5	%100	%100



Şekil 5.6: Sistemin farklı test yöntemlerinin doğruluk oranına göre karşılaştırılması.

Sistemin en başarılı sonuçlar üreten test yöntemleri olan ağırlıklı ortalama yöntemi (üstel + ağ güvenilirliği) ve iki aşamalı optimizasyon tabanlı rastgele nokta yöntemi ile yapılan deney sonuçlarının literatürdeki BioID veri kümesini kullanan model tabanlı çalışmalarla karşılaştırılması Tablo 5.4’de, öznitelik tabanlı çalışmalarla karşılaştırılması Tablo 5.5’de ve hibrit çalışmalarla karşılaştırılması Tablo 5.6’de yer almaktadır. Elde edilen sonuçlara göre, önerilen yöntemler literatürdeki hem model tabanlı, hem öznitelik tabanlı hem de hibrit olan alternatif çalışmalardan çok daha üstün bir performans göstermiştir. $e \leq 0.05$ değeri için en yüksek başarıyı ağırlıklı ortalama yöntemi (üstel + ağ güvenilirliği) ve $e \leq 0.1$ için en yüksek başarıyı iki aşamalı optimizasyon tabanlı rastgele nokta yöntemi elde etmiştir. $e \leq 0.25$ için başarı oranları her iki yöntemde de aynı çıkmıştır.

Tablo 5.4: BioID veri kümesi üzerinde gerçekleştirilen deneylere ait sonuçların literatürdeki model tabanlı yöntemlerle karşılaştırılması.

Yöntem	$e \leq 0.05$	$e \leq 0.1$	$e \leq 0.25$
Önerilen İki Aşamalı Optimizasyon Tabanlı Rastgele Nokta Yöntemi	%98,5	%100	%100
Önerilen Ağırlıklı Ortalama Yöntemi (Üstel + Ağ Güvenilirliği) [32]	%98.6	%99.9	%100
Markus vd. $p = 31$ [35]	%89.9	%97.1	%99.7
Araujo vd. [42]	%88.3	%92.7	%98.9
Karakoc vd. [43]	%97.5	%99.6	%99.9
Gou vd. [45]	%91.2	%99.4	%99.8
Campadelli vd. [46]	%80.7	%93.2	%99.3
Niu vd. [48]	-	%93.0	-
Kim vd. [51]	-	%96.4	%98.8
Chen vd. 2015 [52]	%88.8	%95.2	%98.9
Amos vd. [57]	%84.1	%90.2	%96.1
Li vd. [58]	%85.6	%95.9	%99.5
Behnke vd. [61]	%37.0	%86.0	%98.0

Tablo 5.5: BioID veri kümesi üzerinde gerçekleştirilen deneylere ait sonuçların literatürdeki öznitelik tabanlı yöntemlerle karşılaştırılması.

Yöntem	$e \leq 0.05$	$e \leq 0.1$	$e \leq 0.25$
Önerilen İki Aşamalı Optimizasyon Tabanlı Rastgele Nokta Yöntemi	%98,5	%100	%100
Önerilen Ağırlıklı Ortalama Yöntemi (Üstel + Ağ Güvenilirliği) [32]	%98.6	%99.9	%100
Timm vd. [37]	%82.5	%93.4	%98.0
Asadifard vd. [62]	%47.0	%86.0	%96.0
Leo vd. 2013 [63]	%78.0	%86.0	%90.0
Leo vd. 2014 [64]	%80.6	%87.3	%94.0
George vd. [66]	%85.1	%94.3	-
Asteriadis vd. [68]	-	%81.7	%97.4
Bai vd. [71]	%37.0	%64.0	%96.0
Zhang vd. [72]	%85.7	%93.7	%99.2
Jesorsky vd. [89]	%38.0	%78.8	%91.8

Tablo 5.6: BioID veri kümesi üzerinde gerçekleştirilen deneylere ait sonuçların literatürdeki hibrit yöntemlerle karşılaştırılması.

Yöntem	$e \leq 0.05$	$e \leq 0.1$	$e \leq 0.25$
Önerilen İki Aşamalı Optimizasyon Tabanlı Rastgele Nokta Yöntemi	%98,5	%100	%100
Önerilen Ağırlıklı Ortalama Yöntemi (Üstel + Ağ Güvenilirliği) [32]	%98.6	%99.9	%100
Valenti vd. [38]	%86.1	%91.7	%97.9
Kroon vd. FLD yöntemi [74]	%65.0	%78.6	%98.8
Chen vd. 2014 [76]	%87.3	%94.9	%99.2
Levinshtein vd. [77]	%95.3	%99.6	%100
Türkan vd. [79]	-	%73.7	%99.5
Ren vd. [82]	%77.1	%92.2	%98.9


Li vd. [58] tarafından paylaşılan literatürdeki BioID veri kümesini kullanan çalışmaların hem başarı hem de çalışma zamanı açısından karşılaştırmaları Tablo

5.7’da verilmiştir. Çalışma hızı işletim sisteminde doğrudan bağlı olarak değişen bir değer olduğu için önerilen yöntemin çalışma hızı bu tabloya dahil edilmemiştir.


Tablo 5.7: Literatürdeki BioID veri kümesini kullanan çalışmaların hem başarı hem de çalışma zamanı açısından karşılaştırılması.

Yöntem	$e \leq 0.05$	$e \leq 0.1$	$e \leq 0.25$	Zaman (ms)
Markus vd. $p = 31$ [35]	%89.9	%97.1	%99.7	44
Timm vd. [37]	%82.5	%93.4	%98.0	
Valenti vd. [38]	%86.1	%91.7	%97.9	34
Araujo vd. [42]	%88.3	%92.7	%98.9	83
Gou vd. [45]	%91.2	%99.4	%99.8	67
Amos vd. [57]	%84.1	%90.2	%96.1	500
Li vd. [58]	%85.6	%95.9	%99.5	13
Asadifard vd. [62]	%47.0	%86.0	%96.0	45
Leo vd. 2013 [63]	%78.0	%86.0	%90.0	330
Leo vd. 2014 [64]	%80.6	%87.3	%94.0	330
Jesorsky vd. [89]	%38.0	%78.8	%91.8	33


İki aşamalı optimizasyon tabanlı rastgele nokta yöntemi kullanılarak elde edilen bazı pozitif deney sonuçları Şekil 5.7, Şekil 5.8, Şekil 5.9, Şekil 5.10 ve Şekil 5.11’de verilmiştir. Negatif olarak elde edilen sonuçlar ise Şekil 5.12 ve Şekil 5.13’de verilmiştir. Sonuçların sol tarafında yer alan görüntüde tam doğru göz bebeği merkezi ve sistemin elde ettiği göz bebeği merkezi sol ve sağ göz için ayrı ayrı işaretlenmiştir. Görüntüler üzerinde beyaz renkli artı işaretleri tam doğruyu gösterirken kırmızı renkli çarpı işaretleri ise sistemin tahmin ettiği göz bebeği merkezlerini göstermektedir. Sağdaki görüntüde ise modelden elde edilen skor görüntüsü yer almaktadır. Bu skor görüntüsü modelin tüm göz alanında çalışması ile elde edilen görüntüdür. Her ne kadar test aşamalarında göz alanının tamamında model çalışmamış olsa da, sonuç görüntülerine daha sağlıklı yorum yapılabilmesi için deney sonuçlarına skor görüntüleri de eklenmiştir. Skor görüntülerindeki etiket dağılımları deney sonucunun alt kısmında sıcaklık haritası şeklinde verilmiştir. Mavi ile kırmızı renkler arasında değişen bu dağılım, kırmızıya doğru gidildikçe göz bebeği merkezine yaklaşılmakta ve maviye doğru gidildikçe göz bebeği merkezinden uzaklaşılmakta olduğunu göstermektedir.




Şekil 5.7: A kişisine ait pozitif bir deney sonucu.




Şekil 5.8: B kişisine ait pozitif bir deney sonucu.




Şekil 5.9: C kişisine ait pozitif bir deney sonucu.




Şekil 5.10: D kişisine ait pozitif bir deney sonucu.



Şekil 5.11: E kişisine ait pozitif bir deney sonucu.



Şekil 5.12: F kişisine ait negatif bir deney sonucu.



Şekil 5.13: G kişisine ait negatif bir deney sonucu.

6. SONUÇLAR

Göz bebeği merkezinin tespiti günlük yaşantıda pek çok uygulama alanı olması sebebiyle günümüzde oldukça popüler bir çalışma konusudur. Her ne kadar literatürde yer alan veya ticari olarak geliştirilen göz bebeği merkezi tespit sistemleri mevcut ise de, bu tür sistemler yüksek başarı oranı elde edebilmeleri için çoğu zaman özel bir donanıma ihtiyaç duyarlar veya kalibrasyon aşaması gerektirirler. Bu özel donanımlar kafaya giyilebilen ekipmanlar, göze takılan çeşitli özelleşmiş gözlükler veya kızılötesi görüntü alabilen kameralar olabilmektedir. Dolayısıyla, özel donanımlara veya kalibrasyon aşamalarına ihtiyaç duyulmadan göz bebeği merkezini yalnızca görünüm tabanlı olarak tespit edebilmek önemli ve üzerinde çokça çalışılan bir konu haline gelmiştir.

Bu çalışmada, hiçbir özel donanıma ihtiyaç duyulmadan yalnızca görünüm tabanlı olarak yapay sinir ağı sonuçlarının oylanması ile göz bebeği merkezi tespiti gerçekleştirilmiştir. Sistem KSA modelini kullanarak göz bölgesinden elde edilmiş dört farklı ölçekli olarak oluşturulan görüntü parçaları sayesinde eğitilmiştir. Test aşamasında ise dört farklı yöntem uygulanmıştır. İlki olan ağırlıklı ortalama yönteminde, göz bölgesinden kayan pencere yöntemiyle elde edilen aday görüntü parçaları üzerinde farklı etiket-katsayı değişimleri ile (sabit, lineer ve üstel) ağırlık güvenirlik değerleri de kullanılarak ağırlıklı ortalama hesabı yapılması sonucunda göz bebeği merkezi tahmini yapılmıştır. İkinci yöntemde ise göz alanından belli sayıda rastgele nokta seçilerek elde edilen aday görüntü parçaları sayesinde idealde göz bebeği merkezi ile kesişmesi beklenen daireler elde edilmiş ve göz alanında uygulanan kaba kuvvet araması sayesinde göz bebeği merkezi tahmin edilmiştir. Diğer bir yöntemde ise yine göz alanından rastgele olarak seçilen noktalar ile ideal durumda göz bebeği merkezi ile teğet geçmesi beklenen daireler elde edilmiş ve sonrasında bu dairelere en yakın olan nokta optimizasyon algoritması aracılığıyla hesaplanmıştır. Sonuncu yöntemde ise iki aşamalı bir optimizasyon yöntemi uygulanmış ve rastgele noktalar seçilirken biraz daha akıllı karar verilmiştir. Bu yöntemde ilk önce göz bölgesi 9 eşit parçaya ayrılmış ve sonrasında her bir parçadan bir tane rastgele nokta seçilerek merkez nokta tespit edilmiştir. İkinci aşamada ise ilk aşamada bulunan merkez nokta iyileştirilmiştir.

Sistem ağırlıklı ortama yöntemi ile yaklaşık 1.9 FPS hızında çalışırken, optimizasyon tabanlı rastgele nokta yöntemi sayesinde bu hız yaklaşık 12.1 FPS'e kadar yükselmiştir. Dört farklı test aşaması doğruluk açısından kıyaslandığında en yüksek başarı oranını ağırlıklı ortalama (üstel etiket-katsayı değişiminin ağ güvenilirlik bilgisi ile birlikte kullanılması durumunda) yöntemi elde etmiştir. BioID veri kümesi üzerinde gerçekleştirilen deney sonuçları, sistemin son zamanlarda bu alanda yayınlanan diğer yöntemlere göre başarı oranı açısından çok daha yüksek bir performans sergilediğini göstermektedir.

Göz bebeği merkezi tespitinin hastalık teşhisi, insan-makine arayüzlerinin iyileştirilmesi, dikkat takibi, uyku tespiti gibi pek çok önemli alanda uygulamaları mevcuttur. Bu sebeple göz bebeği merkezi tespiti alanında yapılan çalışmalar oldukça önemlidir ve giderek çoğalmaktadır. Bu tez çalışması sayesinde literatürde daha önce kullanılmamış ve yüksek başarı oranları elde edebilen yeni yöntemler önerilmiştir. Gelecek çalışmalarda bu sistemden elde edilen göz bebeği merkez noktaları kullanılarak gözün bakış açısının tespit edilmesi hedeflenmektedir. Göz bakış açısının tespit edilmesi yine göz bebeği merkezi ile benzer şekilde oldukça önemli kullanım alanlarına sahip olan bir başka çalışma konusudur. Göz bebeği merkezi tespiti yapan sistemler, bu tür sistemlerin daha doğru çalışmasına büyük ölçüde olanak sağlamaktadır.

KAYNAKLAR

- [1] Duchowski A. T., (2002), "A breadth-first survey of eye-tracking applications", Behavior Research Methods, Instruments, & Computers, 34 (4), 455-470.
- [2] Zhu Z., Fujimura K., Ji Q., (2002), "Real-Time Eye Detection and Tracking Under Various Light Conditions", Proceedings of the 2002 symposium on Eye tracking research & applications.
- [3] Krafska K., Khosla A., Kellnhofer P., Kannan H., (2016), "Eye Tracking for Everyone", IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
- [4] Böhme M., Meyer A., Martinetz T., Barth E., (2006), "Remote Eye Tracking: State of the Art and Directions for Future Development", Proceedings of the 2nd COGAIN, Turin, Italy.
- [5] Duchowski A., (2007), "Eye tracking methodology: Theory and practice", Springer.
- [6] Jacob R., Karn K., (2003), "Eye Tracking in Human-Computer Interaction and Usability Research: Ready to Deliver the Promises", The Mind's Eye, Amsterdam, North-Holland, 573-605.
- [7] Majaranta P., Bulling A., (2014), "Eye Tracking and Eye-Based Human-Computer Interaction", Advances in Physiological Computing, London, Springer, 33-65.
- [8] Karthikeyan S., Jagadeesh V., Shenoy R., Ecksteinz M., Manjunath B. S., (2013), "From Where and How to What We See", IEEE International Conference on Computer Vision (ICCV).
- [9] Ghinea G., Djeraba C., Gulliver S., Coyne K. P., (2007), "Introduction to Special Issue on Eye-tracking Applications in Multimedia Systems", ACM Transactions on Multimedia Computing Communications and Applications.
- [10] Borji A., Itti L., (2013), "State-of-the-art in visual attention modeling", IEEE Transactions on Pattern Analysis and Machine Intelligence (TPAMI).
- [11] Smith P., Shah M., Lobo N. V., (2003), "Determining Driver Visual Attention With One Camera", IEEE Transactions on Intelligent Transportation Systems, 4 (4), 205-218.

- [12] Doshi A., Trivedi M. M., (2009), "On the roles of eye gaze and head dynamics in predicting driver's intent to change lanes", *IEEE Transactions on Intelligent Transportation Systems*, 10 (3), 453-462.
- [13] U.S. Department of Transportation, (2016), "Traffic Safety Facts 2016: A Compilation of Motor Vehicle Crash Data from the Fatality Analysis Reporting System and the General Estimates System", National Highway Traffic Safety Administration DOT HS 812 554.
- [14] Bhaskar T. N., Keat F. T., Ranganath S., Venkatesh Y. V., (2003), "Blink detection and eye tracking for eye localization", *Conference on Convergent Technologies for Asia-Pacific Region (TENCON)*, Bangalore, India.
- [15] Holzman P. S., Proctor L. R., Levy D. L., Yasillo N. J., Meltzer H. Y., Hurt S. W., (1974), "Eye-Tracking Dysfunctions in Schizophrenic Patients and Their Relatives", *Arch Gen Psychiatry*, 31, 143-151.
- [16] Mateo J. C., Agustin J. S., Hansen J. P., (2008), "Gaze beats mouse: hands-free selection by combining gaze and emg", *Extended Abstracts on Human Factors in Computing Systems*, Florence, Italy.
- [17] Campadelli P., Lanzarotti R., Lipori G., (2007), "Eye localization: a survey", 18, 234.
- [18] Bates R., Istance H., Oosthuizen L., Majaranta P., (2005), "Survey of De-Facto Standards in Eye Tracking", *Communication by Gaze Interaction (COGAIN)*.
- [19] Li D., Babcock J. S., Parkhurst D., (2006), "OpenEyes: A low-cost head-mounted eye-tracking solution", *Proceedings of the Eye Tracking Research & Application Symposium*, San Diego, California, USA.
- [20] Ohno T., Mukawa N., (2004), "A free-head, simple calibration, gaze tracking system that enables gaze-based interaction", *ETRA*.
- [21] Valenti R., Yucel Z., Gevers T., (2009), "Robustifying Eye Center Localization by Head Pose Cues", *IEEE Conference on Computer Vision and Pattern Recognition*, Miami, FL, USA.
- [22] Valenti R., Sebe N., Gevers T., (2011), "Combining Head Pose and Eye Location Information for Gaze Estimation", *IEEE Transactions on Image Processing*, 21 (2), 802-815.
- [23] Web 1, (2019), <https://www.tobii.com/>, (Erişim Tarihi: 17/09/2019).
- [24] Hansen D. W., Ji Q., (2009), "In the eye of the beholder: A survey of models for eyes and gaze", *IEEE transactions on pattern analysis and machine intelligence*, 32 (3), 478-500.

- [25] Zhang X., Sugano Y., Fritz M., Bulling A., (2015), "Appearance-based gaze estimation in the wild", IEEE Conference on Computer Vision and Pattern Recognition, Boston, MA, USA.
- [26] Mora K. F., Monay F., Odobez J.-M., (2014), "EYEDIAP: a database for the development and evaluation of gaze estimation algorithms from RGB and RGB-D cameras", Proceedings of the Symposium on Eye Tracking Research and Applications, Safety Harbor, Florida, USA.
- [27] Sugano Y., Matsushita Y., Sato Y., (2014), "Learning-by-Synthesis for Appearance-Based 3D Gaze Estimation", IEEE Conference on Computer Vision and Pattern Recognition, Columbus, OH, USA.
- [28] Alnajar F., Gevers T., Valenti R., Ghebreab S., (2013), "Calibration-Free Gaze Estimation Using Human Gaze Patterns", Proceedings of the IEEE international conference on computer vision, 137-144.
- [29] Lu F., Sugano Y., Okabe T., Sato Y., (2011), "Inferring human gaze from appearance via adaptive linear regression", International Conference on Computer Vision, Barcelona, Spain.
- [30] Hansen D. W., Hansen J. P., Nielsen M., Johansen A. S., Stegmann M. B., (2002), "Eye typing using Markov and active appearance models", Sixth IEEE Workshop on Applications of Computer Vision (WACV), 132-163.
- [31] Aloysius N., Geetha M., (2017), "A review on deep convolutional neural networks", International Conference on Communication and Signal Processing (ICCSP), Chennai, India.
- [32] Karakoc N. S., Karahan S., Akgul Y. S., (2017), "Deep learning based estimation of the eye pupil center by using image patch classification", 25th Signal Processing and Communications Applications Conference (SIU), Antalya, Turkey.
- [33] Krizhevsky A., Sutskever I., Hinton G. E., (2012), "ImageNet Classification with Deep Convolutional Neural Networks", Neural Information Processing Systems, 25.
- [34] Wang P., Jib Q., (2007), "Multi-view face and eye detection using discriminant features", Computer Vision and Image Understanding.
- [35] Markuš N., Frljak M., Pandžića I. S., Ahlbergb J., Forchheimerb R., (2014), "Eye pupil localization with an ensemble of randomized trees", Pattern Recognition, 47 (2), 578-587.
- [36] Gou C., Wu Y., Wang K., Wang F.-Y., Ji Q., (2016), "Learning-by-Synthesis for Accurate Eye Detection", 23rd International Conference on Pattern Recognition (ICPR), Cancún, México.

- [37] Timm F., Barth E., (2011), "Accurate Eye Centre Localisation by Means of Gradients", Proceedings of the Sixth International Conference on Computer Vision Theory and Applications, Portugal.
- [38] Valenti R., Gevers T., (2012), "Accurate Eye Center Location through Invariant Isocentric Patterns", IEEE Transactions on Pattern Analysis and Machine Intelligence.
- [39] Campadelli P., Lanzarotti R., Lipori G., (2006), "Precise Eye Localization through a General-to-specific Model Definition", Proceedings of the British Machine Vision Conference, Edinburgh, UK.
- [40] Hamouz M., Kittler J., Kämäräinen J.-K., Paalanen P., Kälviäinen H., Matas J., (2005), "Feature-based affine-invariant localization of faces", IEEE Transactions on Pattern Analysis and Machine Intelligence, 27 (9), 1490-1495.
- [41] Shotton J., Fitzgibbon A., Cook M., Sharp T., Finocchio M., Moore R., Kipman A., Blake A., (2011), "Real-time human pose recognition in parts from single depth images", CVPR, Colorado Springs, CO, USA.
- [42] Araujo G. M., Ribeiro F. M., Silva E. A., Goldenstein S. K., (2014), "Fast eye localization without a face model using inner product detectors", IEEE International Conference on Image Processing (ICIP), Paris, France.
- [43] Karakoc N. S., Karahan S., Akgul Y. S., (2015), "Regressor Based Estimation of the Eye Pupil Center", German Conference on Pattern Recognition, Aachen, Germany.
- [44] Dalal N., Triggs B., (2005), "Histograms of oriented gradients for human detection", IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), San Diego, CA, USA.
- [45] Gou C., Wu Y., Wang K., Wang K., Wang F.-Y., Ji Q., (2017), "A joint cascaded framework for simultaneous eye detection and eye state estimation", Pattern Recognition.
- [46] Campadelli P., Lanzarotti R., Lipori G., (2009), "Precise eye and mouth localization", International Journal of Pattern Recognition and Artificial Intelligence, 23 (3), 359-377.
- [47] Freund Y., Schapire R. E., (1997), "A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting", Journal of Computer and System Sciences, 55 (1), 119-139.
- [48] Niu Z., Shan S., Yan S., Chen X., Gao W., (2006), "2D Cascaded AdaBoost for Eye Localization", 18th International Conference on Pattern Recognition (ICPR'06), Hong Kong, China.

- [49] Everingham M., Zisserman A., (2006), "Regression and Classification Approaches to Eye Localization in Face Images", 7th International Conference on Automatic Face and Gesture Recognition, Southampton, UK.
- [50] Viola P., Jones M. J., (2004), "Robust Real-Time Face Detection", International Journal of Computer Vision, 57 (2), 137-154.
- [51] Kim S., Chung S.-T., Jung S., Oh D., Kim J., Cho S., (2007), "Multi-Scale Gabor Feature Based Eye Localization", Proceedings of World Academy of Science.
- [52] Chen S., Liu C., (2015), "Eye detection using discriminatory Haar features and a new efficient SVM", Image and Vision Computing, 33, 68-77.
- [53] Liu C., (2003), "A Bayesian discriminating features method for face detection", IEEE Transactions on Pattern Analysis and Machine Intelligence, 25 (6), 125-740.
- [54] Xie D., Zhang L., Bai L., (2017), "Deep Learning in Visual Computing and Signal Processing", Applied Computational Intelligence and Soft Computing, 2017, 1-13.
- [55] Chinsatit W., Saitoh T., (2017), "CNN-Based Pupil Center Detection for Wearable Gaze", Applied Computational Intelligence and Soft Computing, 2017.
- [56] Fuhl W., Santini T., Kasneci G., Kasneci E., (2016), "PupilNet: Convolutional Neural Networks for Robust Pupil Detection", Computer Vision and Pattern Recognition, abs/1601.04902.
- [57] Amos B., Ludwiczuk B., Satyanarayanan M., (2016), "OpenFace: A general-purpose face recognition library with mobile applications", CMU School of Computer Science.
- [58] Li B., Fu H., (2018), "Real Time Eye Detector with Cascaded Convolutional Neural Networks", Applied Computational Intelligence and Soft Computing.
- [59] Saha D., Ferdoushi M., Emrose M. T., Das S., Hasan S. M., Khan A. I., Shahnaz C., (2008), "Deep Learning-Based Eye Gaze Controlled Robotic Car", IEEE Region 10 Humanitarian Technology Conference (R10-HTC), Malambe, Sri Lanka.
- [60] Eivazi S., Santini T., Keshavarzi A., Kübler T. C., Mazzei A., (2019), "Improving Real-Time CNN-Based Pupil Detection Through Domain-Specific Data Augmentation", 11th ACM Symposium.
- [61] Behnke S., (2002), "Learning Face Localization Using Hierarchical Recurrent Networks", International Conference on Artificial Neural Networks, Madrid, Spain.

- [62] Asadifard M., Shanbezadeh J., (2010), "Automatic adaptive center of pupil detection using face detection and cdf analysis", Proceedings of the international multiconference of engineers and computer scientists, Hong Kong.
- [63] Leo M., Cazzato D., De Marco T., Distanto C., (2013), "Unsupervised approach for the accurate localization of the pupils in near-frontal facial images", Journal of Electronic Imaging, 22 (3), 033033.
- [64] Leo M., Cazzato D., De Marco T., Distanto C., (2014), "Unsupervised eye pupil localization through differential geometry and local self-similarity matching", PloS one, 9 (8), e102829.
- [65] Skodras E., Fakotakis N., (2012), "An Accurate Eye Center Localization Method for Low Resolution Color Imagery", IEEE 24th International Conference on Tools with Artificial Intelligence, Athens, Greece.
- [66] George A., Routray A., (2016), "A Fast and Accurate Algorithm for Eye Localization for Gaze Tracking in Low Resolution Images", IET Computer Vision, 10 (7), 660-669.
- [67] Fischler M. A., Bolles R. C., (1981), "Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography", Communications of the ACM, 24 (6), 381-395.
- [68] Asteriadis S., Nikolaidis N., Hajdu A., Pitas I., (2006), "An Eye Detection Algorithm Using Pixel to Edge Information", Proceedings of the 2nd International Symposium on Control, Communication and Signal Processing, Marrakech, Morocco.
- [69] Canny J., (1987), "A Computational Approach to Edge Detection", Readings in Computer Vision, Elsevier, 184-203.
- [70] Santini T., Fuhl W., Kasneci E., (2018), "PuRe: Robust pupil detection for real-time pervasive eye tracking", Computer Vision and Image Understanding, 170, 40-50.
- [71] Bai L., Shen L., Wang Y., (2006), "A Novel Eye Location Algorithm based on Radial Symmetry Transform", 18th International Conference on Pattern Recognition (ICPR), Hong Kong, China.
- [72] Zhang W., Smith M. L., Smith L. N., Farooq A., (2016), "Eye center localization and gaze gesture recognition for human-computer interaction", Journal of the Optical Society of America, 33 (3), 314-325.
- [73] Lowe D. G., (2004), "Distinctive Image Features from Scale-Invariant Keypoints," International Journal of Computer Vision, 60 (2), 91-110.
- [74] Kroon B., Hanjalic A., Maas S. M., (2008), "Eye localization for face matching: Is it always useful and under what conditions?", Proceedings of the 2008

international conference on Content-based image and video retrieval, Niagara Falls, Canada.

- [75] Duda R. O., Hart P. E., Stork D. G., (2000), "Pattern Classification", Wiley-Interscience Publication.
- [76] Chen S., Liu C., (2014), "Clustering-based discriminant analysis for eye detection", IEEE Transactions on Image Processing, 23 (4), 1629-1638.
- [77] Levinshtein A., Phung E., Aarabi P., (2017), "Hybrid eye center localization using cascaded regression and robust circle fitting", IEEE Global Conference on Signal and Information Processing (GlobalSIP), Montreal, QC, Canada.
- [78] Li B., Fu H., Wen D., Lo W., "Etracker: A Mobile Gaze-Tracking System with Near-Eye Display Based on a Combined Gaze-Tracking Algorithm", Sensors, 18 (5), 1626, 2018.
- [79] Turkan M., Pardas M., Çetin A. E., (2007), "Human eye localization using edge projections", 2nd International Conference on Computer Vision Theory and Applications, Proceedings (VISAPP), Barcelona, Spain.
- [80] Zhou Z.-H., Geng X., (2004), "Projection functions for eye detection", Pattern Recognition, 37 (5), 1049-1056.
- [81] Cristinacce D., Cootes T. F., Scott I. M., (2004), "A Multi-Stage Approach to Facial Feature Detection", Proceedings of the 15th BMVC, England.
- [82] Ren Y., Wang S., Hou B., Ma J., (2014), "A Novel Eye Localization Method With Rotation Invariance", IEEE Transactions on Image Processing, 23 (1), 226-239.
- [83] Abadi M., Agarwal A., Barham P., Brevdo E., Chen Z., Citro C., Corrado G. S., Davis A., Dean J., Devin M., Ghemawat S., Goodfellow I., Harp A., Irving G., Isard M., Jia Y., Jozefowicz R., Kaiser L., Kudlur M., Levenberg J., Mane D., Monga R., Moore S., Murray D., Olah C., Schuster M., Shlens J., Steiner B., Sutskever I., Talwar K., Tucker P., Vanhoucke V., Vasudevan V., Viegas F., Vinyals O., Warden P., Wattenberg M., Wicke M., Yu Y., Zheng X., (2015), "TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems", Software available from tensorflow.org.
- [84] Deng J., Dong W., Socher R., Li L.-J., Li K., Fei-Fei L., (2009), "ImageNet: A large-scale hierarchical image database", IEEE conference on computer vision and pattern recognition, 248-255.
- [85] Russakovsky O., Deng J., Su H., Krause J., Satheesh S., Ma S., Huang Z., Karpathy A., Khosla A., Bernstein M., Berg A. C., Fei-Fei L., (2015), "ImageNet Large Scale Visual Recognition Challenge", International Journal of Computer Vision (IJCV), 115 (3), 211-252.

- [86] Glumov N. I., Kolomiyetz E. I., Sergeev V. V., (1995), "Detection of objects on the image using a sliding window mode", Optics & Laser Technology, 27 (4), 241-249.
- [87] Nelder J. A., Mead R., (1965), "A simplex method for function minimization", The computer journal, 7 (4), 308-313.
- [88] Web 2, (2019), <https://www.bioid.com/facedb/>, (Eriřim Tarihi: 17/09/2019).
- [89] Jesorsky O., Kirchberg K. J., Frischholz R. W., (2001), "Robust Face Detection Using the Hausdorff Distance", International Conference on Audio- and Video-Based Biometric Person Authentication, Berlin.

ÖZGEÇMİŞ

Necmeddin Said KARAKOÇ 1993 yılında İzmir'in Konak ilçesinde dünyaya geldi. İlk, orta ve lise öğrenimini İstanbul'da tamamladı. 2010 yılında başladığı Gebze Teknik Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü'ndeki lisans eğitiminden 2015 yılında mezun oldu. Ardından 2016 yılında Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine başladı. 2014 yılında başladığı iş hayatına halen yazılım geliştirici olarak devam etmektedir.

EKLER

Ek A: Tez Çalışması Kapsamında Yapılan Yayınlar

Karakoc N. S., Karahan S., Akgul Y. S., (2017), "Deep learning based estimation of the eye pupil center by using image patch classification", 25th Signal Processing and Communications Applications Conference (SIU), Antalya, Turkey.