

**ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**DIYABETİK RETİNOPATİ HASTALIĞININ VIDEO-OKÜLOGRAFİ SİNYALLERİ**  
**KULLANILARAK SINIFLANDIRILMASI**



**ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**DOKTORA TEZİ**

**CEREN KAYA**

**TEMMUZ 2019**

**ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**DİYABETİK RETİNOPATİ HASTALIĞININ VIDEO-OKÜLOGRAFİ SİNYALLERİ  
KULLANILARAK SINIFLANDIRILMASI**

**ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

**DOKTORA TEZİ**

**Ceren KAYA**

**DANIŞMAN : Dr. Öğr. Üyesi Rukiye UZUN ARSLAN**

**İKİNCİ DANIŞMAN : Dr. Öğr. Üyesi Okan ERKAYMAZ**

**ZONGULDAK**

**Temmuz 2019**

**KABUL:**

Ceren KAYA tarafından hazırlanan “Diyabetik Retinopati Hastalığının Video-Okülografi Sinyalleri Kullanılarak Sınıflandırılması” başlıklı bu çalışma jürimiz tarafından değerlendirilerek Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalında Doktora Tezi olarak oybirliğiyle kabul edilmiştir.  
24/07/2019

**Danışman:** Dr. Öğr. Üyesi Rukiye UZUN ARSLAN

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü

**Üye** : Doç. Dr. Ergin YILMAZ

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü

**Üye** : Doç. Dr. İlker TÜRKER

Karabük Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü

**Üye** : Doç. Dr. Yusuf ALTUN

Düzce Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü

**Üye** : Dr. Öğr. Üyesi Necati BAŞMAN

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü

---

**ONAY:**

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım. ....../....../2019

  
Prof. Dr. Ahmet ÖZARSLAN  
Fen Bilimleri Enstitüsü Müdürü

*“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”*

*Ceren Kaya*  
Ceren KAYA

## ÖZET

Doktora Tezi

### DİYABETİK RETİNOPATİ HASTALIĞININ VIDEO-OKÜLOGRAFİ SİNYALLERİ KULLANILARAK SINIFLANDIRILMASI

Ceren KAYA

Zonguldak Bülent Ecevit Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Rukiye UZUN ARSLAN

İkinci Danışman: Dr. Öğr. Üyesi Okan ERKAYMAZ

Temmuz 2019, 117 sayfa

Diyabetik retinopati, şeker hastalığına bağlı olarak gözde meydana gelen ve körlüğe neden olabilecek ciddi bir hastalıktır. Bu hastalık, günümüzde yaşam koşullarının değişimiyle ortaya çıkan en yaygın hastalıklardan biri olan diyabet nedeniyle hızla yayılmaktadır. Diyabetik retinopati tanısı, retinal fundus görüntülerinin uzmanlar tarafından izlenmesine dayanmaktadır. İzleme sürecinin sadece uzman temelli olması, hastalık teşhisini zorlaştırmakta ve süreci uzatmaktadır. Bu bağlamda, hastalığın erken teşhisi oldukça önem arz etmektedir.

Bu çalışmada literatürden farklı olarak ilk defa, diyabetik retinopati hastalığının Video-Okülografi sinyalleri üzerine fizyolojik etkileri gözlemlenmiş ve diyabetik retinopati hastalığının evrelerini sınıflandırmak için otomatik bir karar destek sistemi önerilmiştir. Bu amaçla, dengeli ve dengesiz dağılımlı olarak sağlıklı ve diyabetik retinopati hastalığı bulunan deneklerden alınan Video-Okülografi sinyallerinden öznelik çıkarımı yapılmıştır. Sinyallere

## ÖZET (devam ediyor)

sırasıyla ayrık dalgacık dönüşümü, Hilbert-Huang dönüşümü uygulanarak dalgacık ve içsel mod fonksiyonları katsayıları elde edilmiş, istatistiksel parametreler yardımıyla öznitelik vektörleri oluşturulmuştur. Öznitelik vektörleri sırasıyla çok katmanlı yapay sinir ağı, radyal tabanlı fonksiyon ağı ve literatürden farklı tasarlanan parçacık sürü optimizasyonu temelli çok katmanlı yapay sinir ağı hibrit modelinin eğitimi için kullanılmıştır. Eğitim sonucunda sağ göz (yatay / dikey) ve sol göz (yatay / dikey) olmak üzere 4 farklı göz konumu için çalışmada kullanılan birbirinden farklı ağ topolojilerinin sınıflandırma performansı analizleri gerçekleştirilmiştir. Ayrıca, önerilen ağ topolojilerinin diyabetik retinopati hastalık evrelerinin erken teşhisine uygulanabilirliği ortaya koyulmuştur.

**Anahtar Kelimeler:** Diyabetik Retinopati, Video-Okülografi Sinyali, Ayrık Dalgacık Dönüşümü, Hilbert-Huang Dönüşümü, Çok Katmanlı Yapay Sinir Ağı, Radyal Tabanlı Fonksiyon Ağı, Parçacık Sürü Optimizasyonu.

**Bilim Kodu:** 608.03.00

## **ABSTRACT**

**Ph. D. Thesis**

### **CLASSIFICATION OF DIABETIC RETINOPATHY DISEASE USING VIDEO- OCULOGRAPHY SIGNALS**

**Ceren KAYA**

**Zonguldak Bülent Ecevit University  
Graduate School of Natural and Applied Sciences  
Department of Electrical and Electronics Engineering**

**Thesis Advisor: Assist. Prof. Dr. Rukiye UZUN ARSLAN**

**Co-Advisor: Assist. Prof. Dr. Okan ERKAYMAZ**

**July 2019, 117 pages**

Diabetic retinopathy is a serious disease that occurs in the eye and can cause blindness due to diabetes. This disease is rapidly spreading due to diabetes, which is one of the most common diseases caused by changes in living conditions. The diagnosis of diabetic retinopathy is based on the observation of retinal fundus images by experts. The fact that the monitoring process is based on experts only makes the diagnosis difficult and prolongs the process. In this context, early diagnosis of the disease is very significant.

In this study, unlike the literature, the physiological effects of diabetic retinopathy on Video-Oculography signals were observed for the first time and an automatic decision support system was proposed to classify the stages of diabetic retinopathy. For this purpose, the features were extracted from Video-Oculography signals obtained from subjects with balanced and imbalanced distribution of healthy and diabetic retinopathy.

## **ABSTRACT (continued)**

Discrete wavelet transform and Hilbert-Huang transform were applied to the signals respectively and coefficients of wavelet and intrinsic mode functions were obtained. Feature vectors were formed with the help of statistical parameters. Feature vectors were used to train multi-layer artificial neural network, radial basis function network and multi-layer artificial neural network hybrid model based on particle swarm optimization designed differently from the literature. As a result of the training, classification performance analysis of different network topologies used in the study were performed for 4 different eye locations that were right eye (horizontal / vertical) and left eye (horizontal / vertical). Furthermore, proposed network topologies have been demonstrated to be applicable for the early diagnosis of diabetic retinopathy stages.

**Keywords:** Diabetic Retinopathy, Video-Oculography Signal, Discrete Wavelet Transform, Hilbert-Huang Transform, Multi-layer Artificial Neural Network, Radial Basis Function Network, Particle Swarm Optimization.

**Science Code:** 608.03.00



## TEŞEKKÜR

Tez çalışmamın planlanmasında, araştırılmasında, yürütülmesinde, oluşumunda ilgi ve desteğini esirgemeyen, engin bilgi ve tecrübelerinden yararlandığım, yönlendirme ve bilgilendirmeleriyle çalışmamı bilimsel temeller ışığında şekillendiren, gelecekteki mesleki hayatımda bana verdiği önemli bilgilerden faydalanacağımı düşündüğüm değerli hocam Sayın Prof. Dr. Mahmut ÖZER'e sonsuz teşekkürlerimi sunarım.

Tez çalışmasına başladığım danışman hocam Prof. Dr. Mahmut ÖZER'in Milli Eğitim Bakanlığı Bakan Yardımcılığı görevine atanmasından dolayı, tez danışmanım olan Dr. Öğr. Üyesi Rukiye UZUN ARSLAN'a yorum ve değerlendirmeleri ile katkıda bulunmasından dolayı çok teşekkür ederim. Çalışma konusunun belirlenmesinde ve çalışmanın hazırlanma sürecinin her aşamasında bilgilerini, tecrübelerini ve değerli zamanını esirgemeyerek bana her fırsatta yardımcı olan İkinci Danışmanım Dr. Öğr. Üyesi Okan ERKAYMAZ'a verdiği katkı ve desteklerinden dolayı teşekkürü bir borç bilirim.

Tez süresi boyunca kullanılan göze ait elektrofizyolojik sinyal kayıtlarını almamda ve tezin tıbbi boyutlarında fikirleri ve yorumları ile katkı sağlayan Sayın Doç. Dr. Orhan AYAR'a teşekkürlerimi sunarım. Tüm eğitim hayatım boyunca benden maddi ve manevi desteklerini esirgemeyen her zaman yanımda olan sevgili aileme teşekkürlerimi bir borç bilirim.

Çalışmamda bana mali destek sağlayan Zonguldak Bülent Ecevit Üniversitesi Bilimsel Araştırma Projeleri Birimi'ne (BAP Proje No: 2015-38701644-01) teşekkür ederim.



## İÇİNDEKİLER

	<u>Sayfa</u>
KABUL .....	ii
ÖZET .....	iii
ABSTRACT .....	v
TEŞEKKÜR .....	vii
İÇİNDEKİLER.....	ix
ŞEKİLLER DİZİNİ.....	xiii
ÇİZELGELER DİZİNİ .....	xvii
SİMGELER VE KISALTMALAR DİZİNİ.....	xix
BÖLÜM 1 GİRİŞ .....	1
BÖLÜM 2 GÖZÜN YAPISI VE GÖRME ELEKTROFİZYOLOJİSİ .....	5
2.1 GÖZÜN ANATOMİK YAPISI.....	5
2.1.1 Kornea.....	6
2.1.2 Göz Merceği.....	6
2.1.3 Göz bebeği .....	6
2.1.4 İris .....	6
2.1.5 Retina .....	6
2.1.6 Optik Sinir.....	6
2.1.7 Göz Akı.....	7
2.2 GÖZ KASLARI .....	7
2.3 GÖRME ELEKTROFİZYOLOJİSİ .....	8
2.3.1 Görsel Uyarılmış Potansiyel .....	9
2.3.2 Elektoretinografi .....	9
2.3.3 Patern Elektoretinografi.....	10
2.3.4 Elektrookülografi .....	11
2.3.5 Video-Okülografi .....	13

## İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
2.4 VOG SİNYAL ÖLÇÜMÜ VE ELEKTROT YERLEŞİMİ .....	13
<b>BÖLÜM 3 DİYABET VE DİYABETİK RETİNOPATİ .....</b>	<b>15</b>
3.1 DİYABET.....	15
3.1.1 Diyabetin Göze Etkisi .....	15
3.2 DİYABETİK RETİNOPATİ.....	16
3.2.1 Diyabetik Retinopati Evreleri .....	16
3.2.2 Diyabetik Retinopati Hastalığının Teşhisinde Kullanılan Görüntüleme Cihazları..	17
3.2.2.1 Fundus Floresein Anjiyografisi .....	17
3.2.2.2 Optik Koherens Tomografi .....	18
3.2.2.3. Göz Ultrasonografisi .....	19
<b>BÖLÜM 4 VOG SİNYAL ÖLÇÜMLERİ VE ÖZNİTELİK ÇIKARIM ALGORİTMALARI.....</b>	<b>21</b>
4.1 VOG SİNYALLERİNİN ALINMASI VE VERİ SETİ OLUŞTURMA .....	21
4.2 ÖZNİTELİK ÇIKARIMI .....	24
4.2.1 Dalgacık Dönüşümü.....	24
4.2.1.1 Ayrık Dalgacık Dönüşümü.....	25
4.2.2 Hilbert -Huang Dönüşümü.....	26
4.2.2.1 Ampirik Mod Ayrışımı.....	26
4.2.2.2 Hilbert Dönüşümü .....	27
<b>BÖLÜM 5 YAPAY ZEKÂ YÖNTEMLERİ VE İSTATİSTİKSEL PERFORMANS ANALİZİ.....</b>	<b>31</b>
5.1 YAPAY SİNİR AĞLARI.....	31
5.1.1 Biyolojik Sinir Ağı ve Nöron.....	31
5.1.2 Yapay Sinir Ağlarında Kullanılan İşlem Birimi .....	32
5.1.3 Yapay Sinir Ağlarının Sınıflandırılması .....	33
5.1.3.1 İleri beslemeli ağ yapısı.....	34

## İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
5.1.3.2 Çok Katmanlı Yapay Sinir Ağı Modeli.....	34
5.1.3.3 Radyal Tabanlı Fonksiyon Ağı .....	35
5.2 C4.5 KARAR AĞACI ALGORİTMASI .....	36
5.3 PARÇACIK SÜRÜ OPTİMİZASYONU .....	37
5.4 PERFORMANS ÖLÇÜTLERİ .....	39
BÖLÜM 6 SİMÜLASYON VE ANALİZ SONUÇLARI .....	43
6.1 AYRIK DALGACIK DÖNÜŞÜMÜ KULLANILARAK DİYABETİK RETİNOPATİ HASTALIĞININ VIDEO-OKÜLOGRAFİ (VOG) SİNYALLERİNE FİZYOLOJİK ETKİLERİNİN BELİRLENMESİ.....	44
6.2 VIDEO-OKÜLOGRAFİ (VOG) SİNYALLERİNDEN DİYABETİK RETİNOPATİ HASTALIĞININ ÇOK KATMANLI YAPAY SİNİR AĞI İLE TAHMİNİ .....	57
6.3 C4.5 KARAR AĞACI TEMELLİ ÖZNİTELİK SEÇİMİ İLE VIDEO-OKÜLOGRAFİ (VOG) SİNYALLERİNDEN DİYABETİK RETİNOPATİ HASTALIĞININ ÇOK KATMANLI YAPAY SİNİR AĞI İLE SINIFLANDIRILMASI.....	63
6.4 VIDEO-OKÜLOGRAFİ (VOG) SİNYALLERİNDEN DİYABETİK RETİNOPATİ HASTALIĞININ TESPİTİNDE ÇOK KATMANLI YAPAY SİNİR AĞI İLE RADYAL TABANLI FONKSİYON AĞININ KARŞILAŞTIRILMASI.....	71
6.5 VIDEO-OKÜLOGRAFİ (VOG) SİNYALLERİNDEN DİYABETİK RETİNOPATİ HASTALIĞININ AYRIK DALGACIK DÖNÜŞÜMÜ VE PARÇACIK SÜRÜ OPTİMİZASYONU TEMELLİ ÇOK KATMANLI YAPAY SİNİR AĞI İLE TESPİTİ .....	75
6.6 VIDEO-OKÜLOGRAFİ (VOG) SİNYALLERİNDEN DİYABETİK RETİNOPATİ HASTALIĞININ HİLBERT - HUANG DÖNÜŞÜMÜ VE PARÇACIK SÜRÜ OPTİMİZASYONU TEMELLİ ÇOK KATMANLI YAPAY SİNİR AĞI İLE TESPİTİ.....	84
BÖLÜM 7 SONUÇ VE ÖNERİLER.....	101
KAYNAKLAR.....	105
ÖZGEÇMİŞ .....	117



## ŞEKİLLER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Şekil 2.1 Gözün anatomik yapısı.....	5
Şekil 2.2 Göz kasları .....	7
Şekil 2.3 Göz kasları kontrolündeki göz hareketleri .....	8
Şekil 2.4 VEP sinyali .....	9
Şekil 2.5 ERG sinyali .....	10
Şekil 2.6 PERG sinyali .....	11
Şekil 2.7 Göz hareketine dayalı EOG kaydı .....	12
Şekil 2.8 Sağlıklı bireyden alınan VOG sinyalleri.....	13
Şekil 2.9 Elektrot yerleşimi.....	14
Şekil 3.1 Retina görüntüsü a) Sağlıklı b) Diyabetik retinopati .....	16
Şekil 3.2 Dijital fundus görüntüleme cihazı.....	18
Şekil 3.3 OKT cihazı.....	18
Şekil 3.4 USG cihazı.....	19
Şekil 4.1 MetroVision MonPack One Elektrookülografi cihazı.....	21
Şekil 4.2 Sağlıklı VOG sinyali a) Sol göz yatay konum b) Sol göz dikey konum.....	23
Şekil 4.3 Dalgacık dönüşümünün ölçek-zaman değişimi .....	24
Şekil 4.4 Ayırık dalgacık dönüşümü ile sinyal alt bant ayrışımı.....	25
Şekil 4.5 a) Coiflet dalgacık b) Daubechies dalgacık c) Meyer dalgacık d) Symlet dalgacık e) Morlet dalgacık f) Mexican hat dalgacık.....	26
Şekil 5.1 Biyolojik nöron hücresi.....	32
Şekil 5.2 İşlem birimi yapısı .....	32
Şekil 5.3 ÇKYSA modeli .....	34
Şekil 5.4 ÇKYSA modeli yapısı .....	35
Şekil 5.5 RTFA ağ yapısı .....	36
Şekil 5.6 Parçacık sürü optimizasyonu algoritması akış diyagramı.....	38
Şekil 6.1 Sol göz yatay konuma ait sağlıklı, EEDR ve GEDR denek gruplarından alınan VOG sinyalleri.....	45
Şekil 6.2 Sağ göz yatay konuma ait sağlıklı, EEDR ve GEDR denek gruplarından alınan VOG sinyalleri.....	46
Şekil 6.3 Sol göz dikey konuma ait sağlıklı, EEDR ve GEDR denek gruplarından alınan VOG sinyalleri.....	47
Şekil 6.4 Sağ göz dikey konuma ait sağlıklı, EEDR ve GEDR denek gruplarından alınan VOG sinyalleri.....	48
Şekil 6.5 Sol göz yatay konum için VOG sinyalleri ve ADD katsayıları a) Sağlıklı denek grubu b) EEDR denek grubu c) GEDR denek grubu.....	50

## ŞEKİLLER DİZİNİ (devam ediyor)

<u>No</u>	<u>Sayfa</u>
Şekil 6.6 Sağ göz yatay konum için VOG sinyalleri ve ADD katsayıları a) Sağlıklı denek grubu b) EEDR denek grubu c) GEDR denek grubu. ....	52
Şekil 6.7 Sol göz dikey konum için VOG sinyalleri ve ADD katsayıları a) Sağlıklı denek grubu b) EEDR denek grubu c) GEDR denek grubu. ....	54
Şekil 6.8 Sağ göz dikey konum için VOG sinyalleri ve ADD katsayıları a) Sağlıklı denek grubu b) EEDR denek grubu c) GEDR denek grubu. ....	56
Şekil 6.9 Ara katman nöron sayısının ortalama karesel hataya etkisi. ....	58
Şekil 6.10 Veri seti %80-%20 için elde edilen karmaşıklık matrisi sonuçları a) Sağ göz yatay konum b) Sol göz yatay konum c) Sağ göz dikey konum d) Sol göz dikey konum. ....	62
Şekil 6.11 Ara katman nöron sayısının ortalama karesel hataya etkisi. ....	64
Şekil 6.12 Sağ göz dikey konum için oluşturulan C4.5 karar ağacı. ....	65
Şekil 6.13 Sol göz dikey konum için oluşturulan C4.5 karar ağacı. ....	65
Şekil 6.14 Sağ göz yatay konum için oluşturulan C4.5 karar ağacı. ....	66
Şekil 6.15 Sol göz yatay konum için oluşturulan C4.5 karar ağacı. ....	66
Şekil 6.16 Veri seti %80-%20 için elde edilen karmaşıklık matrisi sonuçları a) Sağ göz dikey konum b) Sol göz dikey konum c) Sağ göz yatay konum d) Sol göz yatay konum. ....	70
Şekil 6.17 Ara katman nöron sayısının ortalama karesel hataya etkisi. ....	72
Şekil 6.18 Veri seti %80-%20 için elde edilen karmaşıklık matrisi sonuçları a) Sağ göz yatay konum b) Sol göz yatay konum c) Sağ göz dikey konum d) Sol göz dikey konum. ....	75
Şekil 6.19 Sağlıklı denek grubu için VOG sinyali ve ADD katsayıları a) Sol göz yatay konum b) Sol göz dikey konum c) Sağ göz yatay konum d) Sağ göz dikey konum. ....	78
Şekil 6.20 EEDR denek grubu için VOG sinyali ve ADD katsayıları a) Sol göz yatay konum b) Sol göz dikey konum c) Sağ göz yatay konum d) Sağ göz dikey konum. ....	80
Şekil 6.21 GEDR denek grubu için VOG sinyali ve ADD katsayıları a) Sol göz yatay konum b) Sol göz dikey konum c) Sağ göz yatay konum d) Sağ göz dikey konum. ....	82
Şekil 6.22 Sağlıklı denek grubu için sol göz yatay konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal. ....	85
Şekil 6.23 Sağlıklı denek grubu için sol göz dikey konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal. ....	86
Şekil 6.24 Sağlıklı denek grubu için sağ göz yatay konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal. ....	87
Şekil 6.25 Sağlıklı denek grubu için sağ göz dikey konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal. ....	88



## ŞEKİLLER DİZİNİ (devam ediyor)

<u>No</u>	<u>Sayfa</u>
Şekil 6.26 EEDR denek grubu için sol göz yatay konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal. ....	90
Şekil 6.27 EEDR denek grubu için sol göz dikey konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal. ....	91
Şekil 6.28 EEDR Denek Grubu için sağ göz yatay konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal. ....	92
Şekil 6.29 EEDR denek grubu için sağ göz dikey konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal. ....	93
Şekil 6.30 GEDR Denek Grubu için sol göz yatay konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal. ....	94
Şekil 6.31 GEDR denek grubu için sol göz dikey konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal. ....	95
Şekil 6.32 GEDR denek grubu için sağ göz yatay konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal. ....	96
Şekil 6.33 GEDR denek grubu için sağ göz dikey konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal. ....	97



## ÇİZELGELER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Çizelge 4.1 MetroVision MonPack One Elektrokülografi cihazı teknik özellikleri.....	22
Çizelge 6.1 VOG sinyal verilerinin sol yatay göz konumu için istatistiksel öznitelikleri.....	57
Çizelge 6.2 Sağ göz dikey konum için veri seti farklı oranlarda bölündüğündeki hata analizi.....	58
Çizelge 6.3 Sol göz dikey konum için veri seti farklı oranlarda bölündüğündeki hata analizi.....	58
Çizelge 6.4 Sağ göz yatay konum için veri seti farklı oranlarda bölündüğündeki hata analizi.....	59
Çizelge 6.5 Sol göz yatay konum için veri seti farklı oranlarda bölündüğündeki hata analizi.....	59
Çizelge 6.6 Sağ göz dikey konum için veri seti farklı oranlarda bölündüğündeki istatistiksel analiz.....	59
Çizelge 6.7 Sol göz dikey konum için veri seti farklı oranlarda bölündüğündeki istatistiksel analiz.....	60
Çizelge 6.8 Sağ göz yatay konum için veri seti farklı oranlarda bölündüğündeki istatistiksel analiz.....	60
Çizelge 6.9 Sol göz yatay konum için veri seti farklı oranlarda bölündüğündeki istatistiksel analiz.....	60
Çizelge 6.10 VOG sinyal verilerinin sol yatay göz konumu için istatistiksel öznitelikleri.....	63
Çizelge 6.11 C4.5 karar ağacı ile öznitelik seçimi.....	67
Çizelge 6.12 ADD & ÇKYSA ve C4.5 & ÇKYSA modellerinin istatistiksel analizleri.....	67
Çizelge 6.13 ADD & ÇKYSA modeli hata analizi.....	68
Çizelge 6.14 C4.5 & ÇKYSA modeli hata analizi.....	68
Çizelge 6.15 ÇKYSA modeli hata analizi.....	72
Çizelge 6.16 RTFA modeli hata analizi.....	72
Çizelge 6.17 ÇKYSA ve RTFA modellerinin istatistiksel analizleri.....	73
Çizelge 6.18 ADD - ÇKYSAPSO modelinin istatistiksel analizi.....	83
Çizelge 6.19 Sol yatay göz konumu için HHD - ÇKYSAPSO modelinin istatistiksel analizi.....	98
Çizelge 6.20 Sağ yatay göz konumu için HHD - ÇKYSAPSO modelinin istatistiksel analizi.....	99
Çizelge 6.21 Sol dikey göz konumu için HHD - ÇKYSAPSO modelinin istatistiksel analizi.....	99
Çizelge 6.22 Sağ dikey göz konumu için HHD - ÇKYSAPSO modelinin istatistiksel analizi.....	100



## SİMGELER VE KISALTMALAR DİZİNİ

### SİMGELER

$x[n]$	: Orijinal Sinyal
$D$	: Detay Katsayısı
$A$	: Yaklaşım Katsayısı
$g[n]$	: Yüksek Geçiren Filtre
$h[n]$	: Alçak Geçiren Filtre
$\text{İMF}_i(t)$	: İçsel Mod Fonksiyonu
$x(t)$	: Orijinal Sinyal
$r_n(t)$	: Artık Sinyal
$n$	: Algoritma Adım Sayısı
$y(t)$	: $x(t)$ Fonksiyonunun HD Uygulanmış Hali
$a(t)$	: Anlık Genlik Fonksiyonu
$\Theta(t)$	: Anlık Faz Fonksiyonu
$w(t)$	: Anlık Açısız Frekans
$f(t)$	: Anlık Frekans
$x_i$	: Nöron Girişi
$w_i$	: Ağırlıklar
$b$	: Eşik Değer
$y$	: Nöron Çıkışı
$z$	: Ağ Çıkışı
$y$	: Çok Katmanlı Yapay Sinir Ağı Modeli Toplam Fonksiyonu
$\alpha$	: Öğrenme Katsayısı
$b_\zeta$	: Beklenen Çıkış
$h_\zeta$	: Hesaplanan Çıkış
$x_m$	: Ağın Girişi
$w_n$	: Ağırlıklar
$j$	: Gizli Katman Nöron Sayısı
$H_n$	: $n$ . Nöron Merkezi

## SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

$\sigma_n$	: n. Dağılım Parametresi
Y	: Ağın Çıkışı
$V_i$	: Hız Vektörü
$t_i$	: Eşik Değer
$X_i$	: Pozisyon Vektörü
c	: Parçacık Uygunluk Değeri
$p_{eni}$	: Mevcut Jenerasyondaki Yerel Kişisel En İyi
$g_{eni}$	: Mevcut Jenerasyondaki Yerel En İyiler İçerisinden Küresel En İyi
N	: Örnek Sayısı

### KISALTMALAR

<b>ADD</b>	: Ayrık Dalgacık Dönüşümü
<b>AMA</b>	: Amprik Mod Ayrışımı
<b>coif</b>	: Coiflet
<b>ÇKYSA</b>	: Çok Katmanlı Yapay Sinir Ağı
<b>db</b>	: Daubechies
<b>dB</b>	: Desibel
<b>DD</b>	: Dalgacık Dönüşümü
<b>DN</b>	: Doğru Negatif
<b>DP</b>	: Doğru Pozitif
<b>DR</b>	: Diyabetik Retinopati
<b>EEDR</b>	: Erken Evre Diyabetik Retinopati
<b>EOG</b>	: Elektrokülografi
<b>ERG</b>	: Elektoretinografi
<b>FFA</b>	: Fundus Fluorescein Anjiyografi
<b>GEDR</b>	: Geç Evre Diyabetik Retinopati
<b>HD</b>	: Hilbert Dönüşümü
<b>HHD</b>	: Hilbert-Huang Dönüşümü
<b>Hz</b>	: Hertz
<b>İMF</b>	: İçsel Mod Fonksiyonu
<b>LVQ</b>	: Öğrenmeli Vektör Kuantalama

## SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

<b>M</b>	: Mega
<b><math>\mu</math>V</b>	: Mikrovolt
<b>mm</b>	: Milimetre
<b>ms</b>	: Milisaniye
<b>mV</b>	: Milivolt
<b>nm</b>	: Nanometre
<b>OKN</b>	: Optokinetik Nistagmus
<b>OKT</b>	: Optik Koherens Tomografi
<b>PERG</b>	: Patern Elektroretinografi
<b>PSO</b>	: Parçacık Sürü Optimizasyonu
<b>R</b>	: Regresyon Katsayısı
<b>R<sup>2</sup></b>	: Belirlilik Katsayısı
<b>RTFA</b>	: Radyal Tabanlı Fonksiyon Ağı
<b>USG</b>	: Göz Ultrasonografisi
<b>VEP</b>	: Görsel Uyarılmış Potansiyel
<b>VOG</b>	: Video-Okülografi
<b>YN</b>	: Yanlış Negatif
<b>YP</b>	: Yanlış Pozitif
<b>YSA</b>	: Yapay Sinir Ağları





## BÖLÜM 1

### GİRİŞ

Organlar hakkında fizyolojik bilgiler içeren biyosinyaller, organ durumunun gözlemlenmesi sürecinde uzmanlara net bulgular sunmaktadır. Beş temel duyu organı insan hayatının devamlılığı açısından büyük öneme sahiptir. Bu nedenle, organlardan alınan sinyaller tıp ve mühendislik alanında sıklıkla kullanılmaktadır [1]. Göz, nesnelere gelen optik ışınları kırarak ters görüntü oluşturmaktadır ve oluşturulan görüntüyü görme sinirlerini uyararak beyine iletmektedir. Optik süreç içerisinde gözde meydana gelen elektrofizyolojik sinyaller; Görsel Uyarılmış Potansiyel (VEP), Elektrookülografi (EOG), Video-Okülografi (VOG) ve Elektoretinografi (ERG) testleri ile ölçülmektedir [2]. Bu testlerle elde edilen sinyallerin hastalık teşhislerinde uzmanlar için önemli bulgular sunmasından dolayı, göz hastalıklarının göz sinyalleri üzerine etkisi popüler bir araştırma alanı olmuştur.

Dünya Sağlık Örgütü'nün yayınladığı bilgilere göre diyabet kanserden sonra çağımızın en tehlikeli hastalığı olarak görülmektedir [3]. Bu bağlamda diyabetin erken teşhisi ve insan vücuduna etkileri önemli bir konudur. Diyabet özellikle gözde önemli duyu kayıplarına neden olmakta ve hastayı körlüğe kadar götürebilmektedir. Son yıllarda yapılan çalışmalarda diyabetik retinopatinin (DR), diyabet kaynaklı göz hastalığının, insan hayatını önemli ölçüde etkilediği ortaya konulmuştur [4-6]. DR, diyabetin retinadaki kan damarlarına zarar vermesi nedeniyle oluşmaktadır. DR'nin, erken evre diyabetik retinopati (EEDR) ve geç evre diyabetik retinopati (GEDR) olarak adlandırılan iki adet evresi bulunmaktadır. EEDR'de retinadaki kan damarlarında sıvı kaçağı görülürken; GEDR'de ise retinada yeni kan damarları oluşmaktadır [7].

DR'nin teşhisi genellikle klinik ortamda yapılmaktadır. DR teşhisi konulan kişilerde, hastalığın komplikasyonları nedeniyle görme yetisi azalmaktadır. EEDR'de retina yapısında meydana gelen değişimler rutin oküler incelemeler sırasında tespit edilebilmektedir. Ancak bu durum GEDR'de mümkün olmamaktadır [8]. Tıpta DR kaynaklı hastalıkların teşhisinde optik koherens tomografi (OKT), fundus fluorescein anjiyografi (FFA) ve göz ultrasonografisi (USG)

cihazları kullanılmaktadır. OKT cihazı ile diyabetik maküler ödem, vitreomaküler traksiyon ve epiretinal membranlar gibi maküler hastalıklar tespit edilmektedir. FFA cihazı iskemi, mikroanevrizmalar, arter veya ven tıkanması gibi retina vasküler değişiklikleri saptamak için; USG cihazı ise retina yırtılması, göz içi kanaması, göze yabancı cisim batması, tümör ve ameliyatlarda kullanılacak uygun göz merceğinin belirlenmesi durumlarında kullanılmaktadır [9]. Kullanılan bu farklı tıbbi testler yalnızca hastalık komplikasyonları meydana geldiğinde bilgi sağlamaktadır. Bu nedenle, diyabetik retinopatinin erken teşhisi önem arz etmektedir.

Literatürde, retinal fundus görüntülerini kullanarak görüntü işleme ve yapay zekâ yöntemleri ile DR hastalık evresinin tespitine dayalı birçok farklı çalışma bulunmaktadır [10-15]. Priya ve Aruna [10], fundus görüntülerini kullanarak DR'nin evrelerini (EEDR, GEDR) sınıflandırmak için olasılıksal sinir ağı, bayes sınıflandırıcısı ve destek vektör makinesi yöntemlerinin başarımlarını karşılaştırmışlardır. Kullanılan iki farklı veri seti için en yüksek sınıflandırma başarımları (%95,38 ve %97,60) destek vektör makinesi yöntemi ile bulunmuştur. Rajput ve arkadaşları [11], beş farklı veri setine ayırık dalgacık dönüşümünü uygulayarak sağlıklı ve EEDR retinal fundus görüntülerinin özneliklerini çıkarmışlardır. Elde edilen öznelikler, k-ortalama kümeleme algoritması ile sınıflandırılarak ortalama %95 başarımla elde etmişlerdir. Noronha ve arkadaşları [12], sağlıklı ve DR fundus görüntülerinden ayırık dalgacık dönüşümüyle elde edilen öznelikleri, %99,17'lik başarımla destek vektör makinesi yöntemiyle sınıflandırmışlardır. Acharya ve arkadaşları [13], sağlıklı ve DR fundus görüntülerinden istatistiksel olarak çıkardıkları öznelikleri kullanarak destek vektör makinesi yöntemi ile %85,9 sınıflandırma performansı elde etmişlerdir. Solkar ve Das [14], sağlıklı ve DR fundus görüntülerini içeren veri setlerini kullanarak farklı istatistiksel öznelikler çıkarmışlardır. Çıkarılan öznelikleri sınıflandırmak için olasılıksal sinir ağı ve destek vektör makinesi yöntemlerini kullanmışlardır. Olasılıksal sinir ağı yönteminde %100, destek vektör makinesi yönteminde ise %77,77 sınıflandırma başarımları elde etmişlerdir. Pratt ve arkadaşları [15], fundus görüntülerinden DR evrelerini sınıflandırmak için öznelik çıkarımı gerektirmeyen konvolüsyonel sinir ağı yöntemini kullanarak %95 başarımla elde etmişlerdir.

Son yıllarda, VOG popüler bir video tabanlı invaziv olmayan ölçüm yöntemi haline gelmiştir. Bu yöntem göz kaslarında meydana gelen elektriksel aktiviteler hakkında bilgi vermektedir. VOG sinyalleri genellikle göz hareketlerine dayalı donanımların tasarımında kullanılmaktadır [16]. Bu bağlamda, Clarke ve arkadaşları [17] göz bebeği ve diğer göz özelliklerini tanımlamak için metal oksit yarı iletken görüntü sensörlerine dayalı bir göz izleme modeli geliştirmişlerdir.

Geliştirilen model, karmaşık görüntü işleme algoritması gerektirmezken, bakışların durumuna göre performansı değişkenlik göstermektedir. Chen ve arkadaşları [18], sağlıklı bir gönüllünün göz bebeği konumunu başarılı bir şekilde belirleyen Wi-Fi tabanlı bir VOG izleme sistemi geliştirmişlerdir. Kim ve arkadaşları [19], göz hareketlerini üç boyutta (yatay / dikey / dairesel) ölçebilen ve göz bebeği yarıçapını hesaplayabilen gerçek zamanlı bir VOG sistemi tasarlamışlardır. Hanuska ve arkadaşları [20], VOG sinyallerini kullanarak sağlıklı ve Parkinson hastalığı olan kişilerin göz hareketlerini Pearson korelasyon analizi ile incelemişlerdir. Yapılan analizlerle, parkinson hastalığı olan kişilerin göz hareketlerindeki yakınsama ve iraksama gecikmesinin sağlıklı kişilere kıyasla belirgin oranda arttığını ortaya koymuşlardır.

Bu tez çalışmasında, DR hastalığının VOG sinyalleri üzerine etkisi incelenmiş ve bu sinyaller yardımıyla hastalık evreleri erken teşhis edilmeye çalışılmıştır. Bu bağlamda, VOG sinyalleri kullanılarak DR sınıflandırılması yapılmış ve model olarak farklı yapay zekâ yöntemleri kullanılmıştır [21-25]. Hastalığın evresinin tahmini için ayrık dalgacık ve Hilbert-Huang dönüşümü yöntemleri öznitelik çıkarma aşamasında kullanılmıştır. Bunun yanı sıra çalışmada, geliştirilen modelin performansını artırmak için yapay zekâ yöntemleri haricinde parçacık sürü optimizasyonuna (PSO) dayalı bir hibrit model tasarlanmış ve modelin performansı geleneksel sınıflandırıcılarla istatistiksel açıdan karşılaştırılmıştır.

Tez genel olarak yedi bölümden oluşmuştur. İlk bölüm giriş kısmıdır. Bu bölümde, tezin amacı ve ayrıntılı literatür araştırması sunulmuştur. Bölüm 2’de gözün anatomik yapısı VOG sinyalinin ölçümü, Bölüm 3’te diyabetin göze etkisi ve diyabetik retinopati hastalığı hakkında genel bilgiler verilmiştir. Bölüm 4’te VOG sinyallerine uygulanan öznitelik çıkarım algoritmaları sunulmuştur. Bölüm 5’te çalışmada kullanılan çok katmanlı yapay sinir ağı (ÇKYSA) ve PSO yöntemleri hakkında temel bilgiler verilmiştir. Bölüm 6’da, VOG sinyallerinden farklı algoritmalarla çıkarılan öznitelikleri kullanarak, geleneksel yapay zekâ modellerinin ve PSO dayalı hibrit model tasarımının DR hastalığının erken teşhisine uygulanabilirliği incelenmiştir. Son bölümde, Bölüm 7, elde edilen sonuçlar ve ileride bu konu üzerine yapılabilecek çalışmalara dair öneriler sunulmuştur.




## BÖLÜM 2

### GÖZÜN YAPISI VE GÖRME ELEKTROFİZYOLOJİSİ

#### 2.1 GÖZÜN ANATOMİK YAPISI

Beş temel duyu organlarından biri olan göz, bilginin algılanmasını gerçekleştiren en önemli organdır. Hareketleri üzerinde bulunan altı adet kas tarafından gerçekleştirilen gözün beyin ile bağlantısı optik sinirler tarafından sağlanır [26]. Küre biçimindeki göz yuvarlağının en dışında bulunan beyaz ve lifsel yapıdaki göz akı (sklera) ön tarafta bombeleşerek, saydamlaşır ve korneayı oluşturur. Göz yuvarlağının iç yüzeyinin 2/3'ünü kaplayan retina (ağ tabaka) ışığa duyarlı tabakadır. Retina ile göz akı arasında pigmentli damar tabakası yer almaktadır. Bu tabakanın öne doğru uzantısı siliyer cisim ve irisi oluşturmaktadır. Şekil 2.1'de gözün anatomik yapısı verilmiştir. Göze gelen ışık, öncelikle korneaya sonra göz akı içinde ilerleyerek irisin ortasındaki dairesel aralıktan göz merceğine (lense) girmektedir. Göz merceğinden geçen ışık damar tabakadaki makula merkezi (fovea) üzerine düşmektedir [27].



Şekil 2.1 Gözün anatomik yapısı [28].

### **2.1.1 Kornea**

Göz yuvarlağının en dış kısmında bulunan kornea, yaklaşık 0,5 mm kalınlığında ve 12 mm çapındadır. Göze gelen ışınların en fazla kırıldığı ve odaklama işlevinin gerçekleştiği saydam bir yapıdır [28-29].

### **2.1.2 Göz Merceği**

Göz bebeğinin arka tarafında yer alan göz merceği (lens), kasılarak ya da gevşeyerek odaklamada ince ayar yapmayı sağlamaktadır [26].

### **2.1.3 Göz bebeği**

Işığın retinaya düşmesini sağlayan göz bebeği irisin ortasındaki siyah daireye benzeyen deliktir. Göz bebeğinin siyah gözükmesi, gelen ışınların gözdeki dokular tarafından soğrulması ya da yansıyan ışın saçılmalarının göz bebeğinden dışarı çıkamamasından kaynaklanmaktadır [28].

### **2.1.4 İris**

Göze rengini (mavi, yeşil, kahverengi, ela) veren tabaka olan iris, içerdiği kaslar sayesinde göz bebeğinin büyüklüğünü ayarlayarak göze giren ışık miktarını belirlemektedir [26].

### **2.1.5 Retina**

Kornea ve göz merceği tarafından üzerine düşen görüntüleri elektriksel sinyallere çeviren retina (ağ tabaka), göz yuvarlağının arkasında yer alan damarlı bir tabakadır [28].

### **2.1.6 Optik Sinir**


Optik sinir, retina tarafından elektriksel sinyallere dönüştürülen görüntülerin beyine iletilmesini sağlamaktadır. Optik sinirlerin yaklaşık 1,2 milyon sinir lifi içerdiği bilinmektedir [29].

### 2.1.7 Göz Akı

Önde kornea, arkada optik sinir arasında yer alan göz akı (sklera); gözün dışarıdan beyaz görünen kısmıdır. Görevi gözün şeklini oluşturmak ve etrafında yer alan kaslar sayesinde göz bebeğinin istenen yöne çevrilmesini sağlamaktır [28].

## 2.2 GÖZ KASLARI

Göz; yatay, dikey ve dairesel olmak üzere üç eksende hareket etmektedir. Göz hareketleri, göz yuvarlağının etrafındaki altı adet göz kasının birlikte kasılıp gevşemesi ile meydana gelmektedir [30]. Şekil 2.2 ve Şekil 2.3'te sırasıyla göz kasları ve bu kasların kontrolündeki göz hareketleri verilmiştir. İnsan vücudunda en hızlı kasılan kas grupları arasında olmasına rağmen yorulmaya karşı dirençli de olan göz kasları yüksek aktiviteye sahiptir [31].



Şekil 2.2 Göz kasları [32].



**Şekil 2.3** Göz kasları kontrolündeki göz hareketleri [33].

## 2.3 GÖRME ELEKTROFİZYOLOJİSİ

Dış dünyadaki ışık ve nesnelerin görüntüleri retinadaki fotoreseptör hücreler tarafından sürekli algılanmaktadır. Işığın etkisi ile fotoreseptör hücrelerden ayrılan biyokimyasal maddeler, retinadaki elektriksel sinyallerde değişikliğe neden olur. Bu elektriksel sinyaller optik sinire, oradan da beyindeki görme merkezine gönderilir [34].

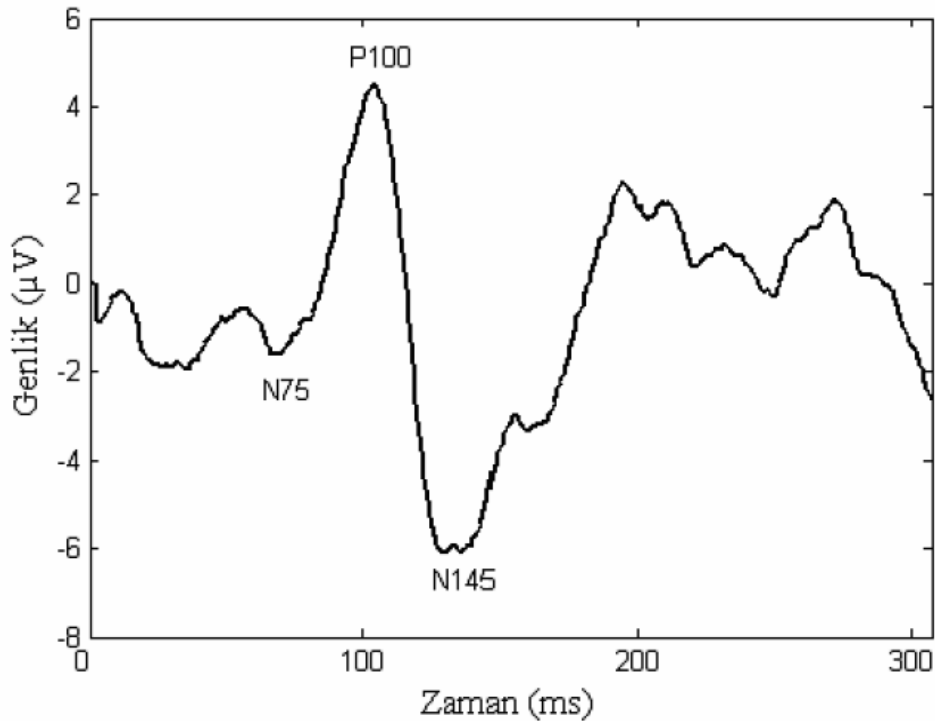
Sağlıklı bir göze ait görme keskinliği, kontrast görme, renkli görme, görme alanı, karanlık adaptasyon, binoküler görme, derinlik hissi gibi birçok özelliğin belirlenen fizyolojik sınırlarda olması gerekmektedir [35]. 1848 yılında Reymond kornea ile retina arasında 6 mV'luk bir elektriksel potansiyel farkı olduğunu göstermiştir [36]. 1865'te ışık etkisi ile retinada oluşan elektriksel potansiyelindeki değişimlerden bahsedilmiştir [37].

İnsan üzerindeki ilk elektroretinografi (ERG) kaydı 1877'de gerçekleştirilmiştir [38]. 1908'de ve 1933'te yapılan çalışmalarda genellikle ERG sinyalini oluşturan a, b, c ve d dalgaları üzerine yoğunlaşmıştır [39]. Gözde, görme fonksiyonunu sağlayan sinir dokusu her an için elektriksel olarak aktiftir ve bu aktivite uyarımlarla değişmektedir [40]. Uygun elektrotlar yerleştirmek suretiyle gözün elektriksel aktivitesini kaydetmek mümkündür. Bu bağlamda, tıp alanında birçok farklı elektrofizyolojik test (VEP, ERG, EOG ve VOG) kullanılmaktadır [41].



### 2.3.1 Görsel Uyarılmış Potansiyel

Görsel uyarılmış potansiyel (VEP), görme yollarının retinadan beyindeki görme merkezine kadar olan kısmının incelenmesinde kullanılan bir yöntemdir. Görsel uyarı kaynağı olarak aralıklı parlayan flaş ya da bir ekranda kayan siyah beyaz dama tahtası şeklindeki uyarılar kullanılmaktadır [42]. Kayıtlar baş bölgesinde özel noktalara yerleştirilen elektrotlar ile yapılmaktadır. Böylelikle, görsel uyarının optik sinirini geçerek beyindeki görme merkezine giderken geçtiği anatomik bölgelere göre dalgalar kaydedilmektedir. Tipik bir VEP sinyali Şekil 2.4'te verilmiştir. VEP, görme yollarının iletim kalitesini ortaya koyarak, kişide bir patolojinin olup olmadığı hakkında uzman hekime bilgiler sunmaktadır [43].




Şekil 2.4 VEP sinyali [44].

### 2.3.2 Elektroretinografi

Elektroretinografi (ERG), retinanın uygun şiddetteki ışık ile uyarılması sonucu oluşan elektriksel sinyal kaydır. Işığın sebep olduğu sodyum ve potasyum iyon hareketlerinin sonucunda bu sinyal ortaya çıkmaktadır [45]. Aydınlık ve karanlık ortamlarda beyaz ve renkli ışıklarla gözün farklı şiddetlerde uyarılması ile retinada ortaya çıkan biyoelektrik sinyalleri,


kornea üzerine veya korneanın çok yakınına yerleştirilen hassas elektrotlar yardımı ile kaydedilmektedir [46]. Tipik bir ERG sinyali iki dalgadan (a ve b dalgalarından) oluşmaktadır (Şekil 2.5). Başlangıçtaki negatif "a" dalgası, fotoreseptör tabakasında ortaya çıkmaktadır. "a" dalgasını takip eden pozitif "b" dalgası ise bipolar hücrelerden elde edilmektedir. Elde edilen dalgaların şekillerinin ve genliklerinin uzman hekimler tarafından değerlendirilmesiyle, klinik olarak ayırt edilmesi zor olan bir hastalığın tanısı veya teşhisi konulmuş bir hastalığın evresinin belirlenmesi mümkün olmaktadır [47].



Şekil 2.5 ERG sinyali [44].

### 2.3.3 Patern Elektoretinografi


Patern Elektoretinografi (PERG), dama tahtası ya da çubuklar şeklindeki bir desen uyarıya karşı retinada meydana gelen değişimlerin kaydedilmesidir. Dama tahtası şeklinde aydınlık ve karanlık alanların değişimi, ganglion hücrelerinin uyarılmasını sağlamaktadır [48]. Tipik bir PERG sinyali üç dalgadan oluşmaktadır (Şekil 2.6). İlk dalga (N35), 35. milisaniyede oluşan küçük negatif dalgadır. İkinci dalga (P50), 50. milisaniyede oluşan büyük pozitif bir dalgadır. 100. milisaniyede oluşan üçüncü dalga (N95) ise büyük negatif bir dalgadır [49].



Şekil 2.6 PERG sinyali [44].

### 2.3.4 Elektrokülografi

Elektrokülografi (EOG), negatif elektrik yüküne sahip kornea ile pozitif yük taşıyan retina arasındaki dinlenme potansiyelini ölçen elektrofizyolojik bir yöntemdir [50]. Bu yöntem, göz küresinin bir batarya gibi davranması gerçeğine dayanarak göz hareketlerinin incelenebilir bir sinyal haline getirilebilmesini sağlar. Böylece, gözün iç ve dış köşelerine yerleştirilen elektrotlar sayesinde kornea ve retina arasındaki dinlenme potansiyeli ölçülebilir [51]. Gözler dinlenme halindeyken (ileriye bakarken) elektrotlar aynı potansiyelindedir ve dolayısıyla elektrotlar arasında bir potansiyel fark oluşmaz. Gözün sağa/sola doğru olan hareketi elektrotlar arasında bir potansiyel farka neden olur, hareketin yönüne bağlı olarak bir elektrot diğer elektrotta göre daha pozitif/negatiftir (Şekil 2.7) [52].



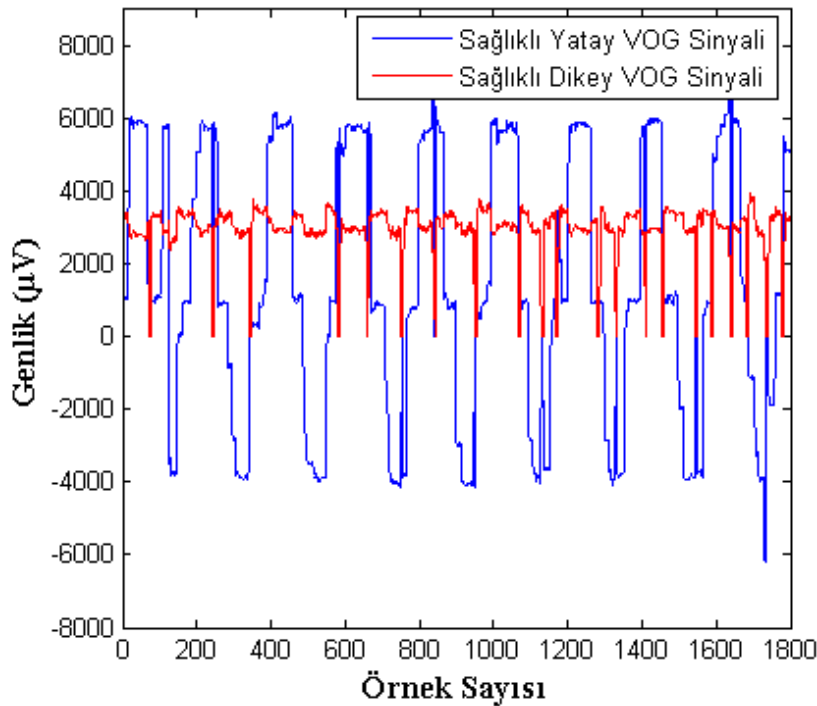
**Şekil 2.7** Göz hareketine dayalı EOG kaydı [53].

EOG'nin göz hareketlerini algılamada avantajları ve dezavantajları mevcuttur. En büyük dezavantajı kornea ve retina arasındaki potansiyelin sabit olmadığı durumlarda yavaş bir şekilde değişmesidir. Bunun yanı sıra, göz kaslarında meydana gelen sorunlar ve yöntemin doğrusal olmayışdır. Avantajları ise hastaya olan bağlantının azlığı nedeniyle hastayı rahatsız etmemesidir. Bununla birlikte, yöntemin tam karanlıkta ve hastanın gözünün kapalı olduğu durumlarda da uygulanabilir olmasıdır [51-52].

EOG diğer elektrofizyolojik testlerle (ERG, PERG ve VEP) birlikte kullanılarak göz hastalıklarının teşhisine yardımcı olmaktadır. Örneğin; EOG sinyali PERG ve VEP sinyalleri ile birlikte kullanıldığında optik sinir göz hastalığının, PERG sinyalleri ile birlikte kullanıldığında maküla hastalığının, ERG sinyalleri ile birlikte kullanıldığında ise fotoreseptör hücrelerinde oluşan hastalıkların belirlenmesinde rol oynamaktadır [54].

### 2.3.5 Video-Okülografi


Video-Okülografi (VOG), küçük kameralarla donatılmış cihaz vasıtasıyla her bir göze ait hareketleri yatay ve dikey pozisyon bileşenlerine göre ölçen video tabanlı bir yöntemdir [55]. Göz hareketlerine bağlı olarak değişen VOG sinyalleri, yakın kızıl ötesi sensör tarafından kaydedilen göz görüntülerinin işlenmesiyle elde edilmektedir [56]. Şekil 2.8’de sağlıklı bir bireyin sol yatay ve dikey göz konumlarından alınan VOG sinyalleri verilmiştir. Bu yöntemle; fiksasyon, gözün kısa ve hızlı hareketi, göz takibi ve optokinetik nistagmus (OKN) sırasında meydana gelen birçok farklı göz hareketi kaydedilebilmektedir.



Şekil 2.8 Sağlıklı bireyden alınan VOG sinyalleri.

### 2.4 VOG SİNYAL ÖLÇÜMÜ VE ELEKTROT YERLEŞİMİ

İnsan vücudunun direnci kişiye göre farklılık göstermektedir. Bu nedenle elektrotlarla yapılan ölçümlerde kaliteli ve net ölçüm yapabilmek amacıyla deri yüzeyindeki direnç azaltılmaktadır [57]. Bu amaç doğrultusunda ölçüm yapılırken elektrot jelleri kullanılmaktadır. Bu tez çalışmasında yatay ve dikey göz konumlarından VOG sinyallerini alabilmek amacıyla, elektrotlar iki kaşın ortasına konumlandırılmıştır (Şekil 2.9).



**Şekil 2.9** Elektrot yerleşimi.

VOG sinyallerinin ölçülmesinde; elektrotların yerleşimi, göz çıkıklıkları, ortamdaki ışık şiddeti, göz hareketlerinin hızı, hastanın yaşı/cinsiyeti gibi birçok faktör etkili olmaktadır. Elde edilen sinyallerin analizinde bu faktörlerin göz önünde bulundurulması gerekmektedir [58].

Tıp alanında kullanılan dijital kayıt sistemleri; analog sinyallerin sayısal sinyallere dönüştürülerek bilgisayar ortamına aktarılmasını, sinyallerin monitörize edilmesini, verilerin saklanmasını ve verilerin analiz edilmesini sağlamaktadır [59]. Yapılan tez çalışmasında, portatif bir dijital kayıt sistemi olan MetroVision MonPack One Elektrokülografi cihazı kullanılmıştır. Bu cihaz yatay ve dikey göz konumlarının eş zamanlı ölçümüne olanak sağlayan 2 kanallı bir veri toplama sistemini kapsamaktadır.

## BÖLÜM 3

### DİYABET VE DİYABETİK RETİNOPATİ

#### 3.1 DİYABET

Şeker hastalığı (diyabet), pankreas bezinden salgılanan insülin hormonunun vücutta yeterli oranda bulunmaması veya görevini yapamaması nedeniyle kan şekerinin yükselmesi olarak tanımlanmaktadır [60].


Diyabet vücutta glikoz metabolizmasının bozulması sonucu ortaya çıkan bir hastalıktır. Glikozu vücut tarafından kullanılabilir hale getirmeye yarayan insülin hormonu, pankreasta bulunan beta hücrelerinin tahribatı sonucunda daha az salgılanmaya başlar. İnsülinin hücrelerde kullanımı bozulduğundan kanda dolaşan glikoz hücrelerde kullanılamaz duruma gelir. Hücreler glikoz emilimini yapamaz ve kanda glikoz seviyesi yükselir [60-61]. Bunun sonucunda vücut damarlarında bozukluklar başlar. Başta göz, böbrekler, kalp ve damar sistemi olmak üzere birçok organda hasarlar meydana gelir. Tıpta tanımlanan iki tip diyabet çeşidi (insüline bağımlı (tip 1) ve insüline bağımlı olmayan (tip 2)) vardır. Diyabetin organlardaki hasarı, kandaki glikoz seviyelerinin kontrolüne ve diyabetin görülme süresine bağlıdır [61-62].

##### 3.1.1 Diyabetin Göze Etkisi

Diyabet hastalarında; katarakt, glokom, retina tutulumu, diyabetik retinopati gibi birçok hastalık meydana gelmektedir. Bu hastalarda görme kaybının oluşma ihtimali sağlıklı bireylere göre 25 kat daha fazladır. Diyabetik hastalarda göz hasarı oluşma ihtimali, 10 yıllık diyabetiklerde %20, 30 yıllık diyabetiklerde %80 civarındadır. Fakat günümüzde hastalığın teşhis ve tedavisindeki gelişmeler ile birlikte görmeyi ciddi şekilde etkileyen hasarlara daha düşük oranlarda rastlanmaktadır [63-64].

### 3.2 DİYABETİK RETİNOPATİ

Diyabete bağlı olarak meydana gelen göz hastalıkları içerisinde en sık görülen diyabetik retinopati (DR)'dir. DR, insanlarda meydana gelen ciddi görme kayıplarının (körlük) başında yer almaktadır. Bunun nedeni, hastalığın ışığı algılayan retina tabakasında yaptığı hasar sonucu damarlarda meydana gelen değişikliklerden kaynaklanmaktadır [65]. Şekil 3.1a ve Şekil 3.1b'de sırasıyla sağlıklı ve DR retina görüntüleri verilmiştir.



Şekil 3.1 Retina görüntüsü a) Sağlıklı b) Diyabetik retinopati [66].

DR, gelişmiş ülkelerde çoğunlukla 20-64 yaş arası kişilerde görülmektedir. Hastalığın gelişimi hastanın yaşına ve hastalığın süresine bağlıdır. 20. yüzyılda yapılan araştırmalarda tip 1 diyabette %99, tip 2 diyabette ise %60 oranında değişik derecelerde diyabetik retinopati hastalığına rastlanılmıştır [67-68].

#### 3.2.1 Diyabetik Retinopati Evreleri

DR'nin başlangıç aşamasında retinadaki küçük damarlarda değişiklikler meydana gelir. Bu değişiklikler nedeniyle retinada kanamalar başlar, damarlar sızması gereken maddeleri damar dışına sızdırır ve bu sızıntı retina katmanlarında sıvı toplanmasına (ödem) yol açar [68]. DR'nin ileri aşamasında ise retinadaki küçük damarlarda tıkanıklıklar meydana gelir. Bu tıkanıklıklar dokulara gerekli oksijenin ve besinin götürülmesini engeller. Sonuç olarak retinada



yeni damarlar ortaya çıkar, ancak oluşan yeni damarlar anormal yapıda olduğundan kolayca kanar, şiddetli göz içi kanamalarına ve dolayısıyla görme kaybına yol açar [69].

DR, temel olarak erken evre diyabetik retinopati (EEDR) ve geç evre diyabetik retinopati (GEDR) olmak üzere iki grupta sınıflandırılır. EEDR’de hasar oluşmuş göz damarlarından kan ve sıvı sızmasıyla retinada ödem oluşur. Buna bağlı olarak retinanın beslenmesi bozulur ve tedavi edilmezse hastalık yavaş yavaş ilerler [70]. Söz konusu sıvı ve kan sızmaları periferik retinada oluyorsa kişi bu ilerlemenin farkına varmaz iken; görme merkezinde oluyorsa kişinin görme yetisi azalır. Bu noktada tedavinin zamanlaması çok önemlidir. Çünkü tedavi kaybolan görmeyi geri getiremez [71].

GEDR hastalığının sahip olduğu ileri evredir. Doku beslenmesi çok bozulunca yeni damar oluşumları meydana gelir. Bu yeni damar oluşumları çok incedir, kendi kendine göz içi kanaması yapabilir. Kanamanın çok yoğun olması retina tabakasında bozulmalara neden olmaktadır. GEDR tedavi edilmediğinde görme kaybı kaçınılmazdır. Bu nedenle tedavisi önemlidir [70-71].

### **3.2.2 Diyabetik Retinopati Hastalığının Teşhisinde Kullanılan Görüntüleme Cihazları**

Tıpta diyabetik retinopati hastalığının teşhisinde sıklıkla Fundus Floresin Anjiyografisi (FFA), Optik Koherens Tomografi (OKT) ve Göz Ultrasonografisi (USG) cihazları kullanılmaktadır.

#### **3.2.2.1 Fundus Floresin Anjiyografisi**


Retina damar yapısının değerlendirilmesinde ve retina muayenesinde uzman hekimler tarafından yaygın olarak Fundus Floresin Anjiyografisi (FFA) kullanılmaktadır. FFA, mavi ışık altında sarı ve turuncu renk veren floresin maddesinin, el ya da koldaki toplardamar vasıtasıyla kişiye verilmesi sonucunda fundus (göz dibi) görüntülerinin çekilmesi işlemidir [72]. Kana karışan floresin maddesi yaklaşık bir dakikalık sürede vücutta bulunan tüm dokuları boyamaktadır. Herhangi bir göz seçilerek 15 dakika boyunca yüksek çözünürlüklü dijital fotoğraf makinesiyle sürekli olarak çekimler yapılmaktadır. Bu sayede, elde edilen retina görüntüleri incelenerek hastalıklar hakkında detaylı bilgilere ulaşmak mümkündür [73]. Tipik bir dijital fundus görüntüleme cihazı Şekil 3.2’de verilmiştir.



Şekil 3.2 Dijital fundus görüntüleme cihazı [74].

### 3.2.2.2 Optik Koherens Tomografi

Optik Koherens Tomografi (OKT), kızılötesine yakın bir dalga boyu (840 nm) olan bir lazer yardımıyla yüksek çözünürlükte retina katmanları ya da kesitleri elde edilmesini sağlayan bir görüntüleme cihazıdır (Şekil 3.3) [75]. OKT cihazının çalışma prensibi, retina yapılarının ışığı geri yansıtma özelliğine dayalıdır. Bu cihazla göze herhangi bir temas olmadan retina görüntüsü elde edilmektedir [76].



Şekil 3.3 OKT cihazı [77].

### 3.2.2.3. Göz Ultrasonografisi

Göz içi yapılarının ve retinanın incelenmesi amacıyla kullanılan göz ultrasonografisi (USG), ses dalgalarının dokularda farklı hızlarda ilerleme prensibine göre çalışan bir görüntüleme cihazıdır (Şekil 3.4). Ultrason probunun kişinin göz kapaklarına dokundurulması ile cihazdan ses dalgaları gönderilmekte ve kişiden çeşitli yatay kesitler alınarak uzman hekimler tarafından değerlendirilmektedir [78]. Görüntülemeye X-ışınları kullanılmadığından USG cihazı radyasyon içermezken; FFA ve OKT cihazları kadar retina hakkında detaylı bilgiler vermemektedir [79].



Şekil 3.4 USG cihazı [80].



## BÖLÜM 4

### VOG SİNYAL ÖLÇÜMLERİ VE ÖZNİTELİK ÇIKARIM ALGORİTMALARI

#### 4.1 VOG SİNYALLERİNİN ALINMASI VE VERİ SETİ OLUŞTURMA

“Zonguldak Bülent Ecevit Üniversitesi Klinik Araştırmalar Etik Kurulu”nun ve “Zonguldak Bülent Ecevit Üniversitesi İnsan Araştırmaları Etik Kurulu”nun izinleri doğrultusunda gönüllü bireylerden VOG sinyalleri MetroVision MonPack One Elektrookülografi cihazı kullanılarak alınmıştır. Belirtilen ölçüm cihazı kalibrasyon ve gürültü korelasyonu düşük olduğu için tercih edilmiştir. Şekil 4.1’de kullanılan cihaz görüntüsü verilmiştir. Cihaza ait teknik bilgiler Çizelge 4.1’de belirtilmiştir.




Şekil 4.1 MetroVision MonPack One Elektrookülografi cihazı.

**Çizelge 4.1** MetroVision MonPack One Elektrookülografi cihazı teknik özellikleri.


<b>Kanal Sayısı:</b>	2-5 kanal
<b>Giriş Gürültü Voltajı:</b>	$< 0.5 \mu V_{pp}$
<b>Giriş Empedansı:</b>	$> 200 \text{ Mohm}$
<b>Ortak Mod Bastırma Oranı:</b>	$> 115 \text{ dB}$
<b>Dalga Boyu:</b>	Mavi, yeşil, kırmızı ve kombinasyonları
<b>Dinamik Aralık:</b>	$3 \times 10^{-6} - 10 \text{ cd.s.m}^{-2}$
<b>Uyartım Süresi:</b>	$> 2 \text{ ms}$
<b>Filtreler:</b>	Alçak geçiren filtre (230Hz), Yüksek geçiren filtre (0.1Hz)
<b>Örnekleme Frekansı:</b>	200Hz (VOG), 680Hz (EOG)
<b>Çözünürlük:</b>	$1.5 \mu V$ (EOG), 0.1 derece (VOG)
<b>Maksimum Kayıt Süresi:</b>	72 s (EOG ve VOG)
<b>Seri Arayüz Tipi:</b>	USB
<b>Protokol:</b>	ISCEV
<b>Sertifikalar:</b>	ISO 13485, CE

Bu cihazla VOG sinyallerinin ölçümü alınırken öncelikle karanlık oda oluşturulmuştur. Böylelikle ışık kaynaklı gürültünün VOG sinyallerini etkilemesi engellenmiştir. Sinyal ölçümü alınmadan önce her denegin gözbebekleri dilate edildikten sonra, karanlık oda adaptasyonu gerçekleştirilmiştir. Sonrasında deneklerin aydınlık adaptasyonda cihazın ekranında yanıp sönen kırmızı renkteki kareleri düzenli şekilde takip etmesi istenmiştir. Yatay ve dikey göz hareketleri için bu adımlar her denek için ayrı ayrı tekrarlanmıştır.

Bu tez çalışmasında, yaşları 19-70 arasında değişen 100 denekten (34'ü sağlıklı, 32'si erken evre diyabetik retinopati ve 34'ü geç evre diyabetik retinopati hastalığı olan birey) 200 Hz örnekleme oranı kullanarak birer dakikalık VOG sinyalleri alınmıştır. Deneklerin diyabetik retinopati göz hastalığı tanıları uzman doktorlar tarafından konulmuştur. Sağlıklı bir bireye ait sol yatay ve dikey göz konumlarında elde edilen VOG sinyalleri Şekil 4.2'de gösterilmiştir.



(a)



(b)

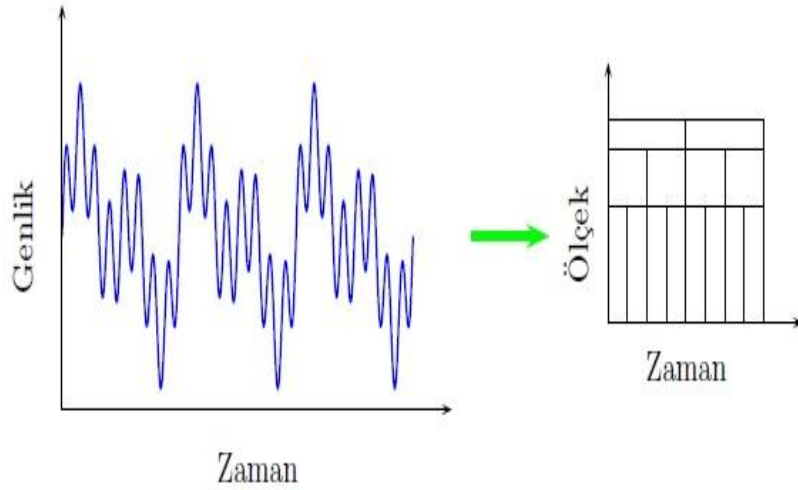
Şekil 4.2 Sağlıklı VOG sinyali a) Sol göz yatay konum b) Sol göz dikey konum.

## 4.2 ÖZİNİTELİK ÇIKARIMI

Metrovision MonPack One cihazıyla 100 deneğin sağ ve sol gözlerinden alınan VOG sinyallerini değerlendirmek için ilk aşamada sinyallerin öznelikleri çıkartılmıştır. Öznelik çıkarım sürecinde ayırık dalgacık dönüşümü ve Hilbert-Huang dönüşümü yöntemleri kullanılmıştır.

### 4.2.1 Dalgacık Dönüşümü

Fourier dönüşümünün frekans analizi konusunda hem önemli hem de etkili bir yöntem olduğu ortaya koyulmuştur. Ancak bu yöntemin kullanıldığı uygulamalarda frekans analizinin yeterli olmadığı tespit edilerek, frekans analizinden ölçek analizine geçiş yapılmıştır [81]. Ölçek analizi temelli dalgacık dönüşümü (DD), frekans tabanlı Fourier dönüşümünün durağan olmayan sinyallerdeki eksiklerini gidermek için geliştirilmiş farklı bir dönüşüm yöntemidir [82]. Bu analiz yöntemi gürültüye karşı daha az hassasiyet göstermektedir. DD'de, tüm sinyale ilişkin frekans-zaman bilgisi korunur [83]. Şekil 4.3'te dalgacık dönüşümünün ölçek-zaman değişimi gösterilmiştir.

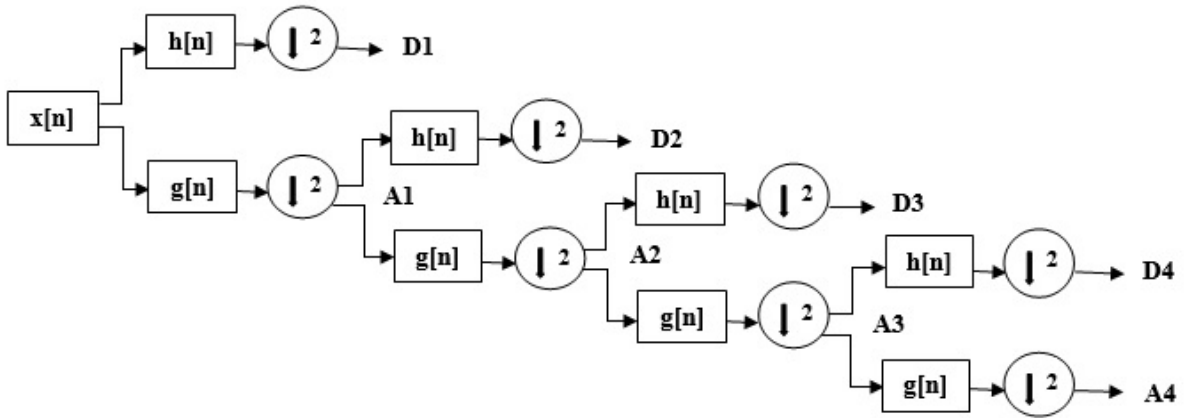


Şekil 4.3 Dalgacık dönüşümünün ölçek-zaman değişimi [82].



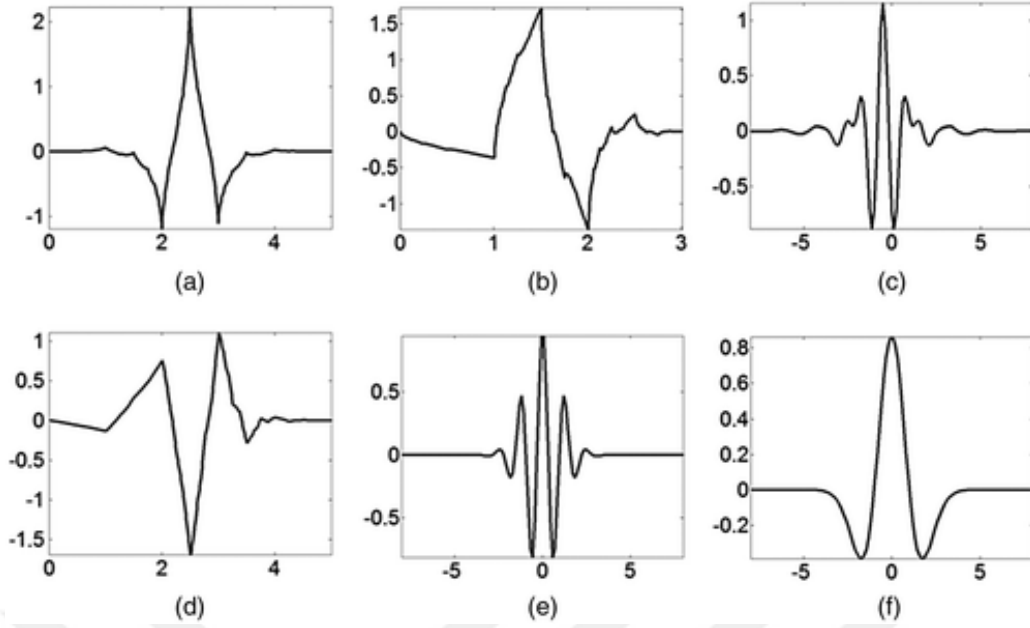
### 4.2.1.1 Ayrık Dalgacık Dönüşümü

Dalgacık dönüşümünün bir çeşidi olan ayrık dalgacık dönüşümünde (ADD) ana dalgacıklar mesafeye göre ötelenir ve genişletilir [84]. ADD'yi elde etmek için ayrık işarete iterasyon yoluyla alçak geçiren ile yüksek geçiren filtreler uygulanır. Bu dönüşümde öteleme ve ölçeklerin ikili kuvvetleri alınarak yüksek frekans bileşenlerinden detay katsayıları, düşük frekans kısmından ise yaklaşım katsayıları elde edilir [85]. Şekil 4.4'te 4 seviyeli bir ayrık dalgacık dönüşümüne ait sinyal alt bant ayrışımı gösterilmiştir. Alt bant ayrışımında orijinal sinyal ( $x[n]$ ); detay (D1- D4) ve yaklaşım (A1-A4) katsayılarını elde etmek için sırasıyla bir yüksek geçiren filtreden ( $g[n]$ ) ve bir alçak geçiren filtreden ( $h[n]$ ) geçirilmektedir.



Şekil 4.4 Ayrık dalgacık dönüşümü ile sinyal alt bant ayrışımı [85].

Dalgacık dönüşümünde en önemli hususlardan biri ana dalgacık fonksiyonunun seçimidir. Literatürde kullanılan birçok farklı ana dalgacık türü vardır [86]. Şekil 4.5'te en sık kullanılan ana dalgacık fonksiyonları (Coiflet, Daubechies, Meyer, Symlets, Morlet ve Mexican hat) gösterilmiştir.



**Şekil 4.5** a) Coiflet dalgacık b) Daubechies dalgacık c) Meyer dalgacık d) Symlet dalgacık e) Morlet dalgacık f) Mexican hat dalgacık [86].

Bu çalışmada; sağlıklı, erken evre diyabetik retinopati (EEDR) ve geç evre diyabetik retinopati (GEDR) denek gruplarından alınan VOG sinyallerinden ADD yöntemi ile detay ve yaklaşım katsayıları elde edilmiştir. ADD yönteminde literatürde sıklıkla kullanılan 4. seviye Daubechies (db4) ve Coiflet (coif4) ana dalgacıkları kullanılmıştır [87].

#### 4.2.2 Hilbert -Huang Dönüşümü

Hilbert – Huang dönüşümü (HHD), doğrusal ve durağan olmayan süreçlerin zaman-frekans-enerji analizlerinde kullanılan uyarlamalı bir yöntemdir [88]. HHD, iki aşamalı bir analiz yöntemidir. İlk olarak Ampirik Mod Ayrışımı (AMA) ile sürece ilişkin sinyale ait her biri frekans modülasyonlu birer işaret olan içsel mod fonksiyonları (İMF) çıkartılmaktadır. Daha sonra, elde edilen her bir İMF'den Hilbert Dönüşümü (HD) ile zaman-frekans alanında anlık frekans ve genlik değerleri elde edilmektedir [89].

##### 4.2.2.1 Ampirik Mod Ayrışımı

Ampirik Mod Ayrışımı (AMA) rasgele bir işaretin, kendine ait farklı frekanslardaki öz mod salınımlarından oluştuğu varsayımına dayanarak sinyalden ayrı salınımlar üreten bir

algoritmaya sahiptir. Üretilen her salınım, işaretin yerel uç noktalarından elde edilen yerel ortalamalarına göre simetriktir. Her bir farklı salınım İMF ile gösterilmektedir [88]. İMF'nin iki temel koşulu sağlaması gerekir. Bunlardan ilki; tüm sinyalde yerel uç değerlerin ve sinyalin sıfırdan geçişlerinin sayısı ya aynı ya da farkları 1'e eşit olmalıdır. Diğeri ise; herhangi bir t anında, yerel maksimumların ve yerel minimumların birleştirilmesiyle elde edilen sinyalin üst ve alt zarfının ortalama değeri sıfır olmalıdır [89].

AMA işleminde, yerel maksimumlar tarafından belirlenen üst zarf ile yerel minimumlar tarafından belirlenen alt zarfın ortalaması alınarak yerel ortalama değeri hesaplanır [90]. Hesaplanan ortalama değeri asıl sinyalden çıkarılarak elde edilen yeni sinyalin İMF koşulunu sağlayıp sağlamadığı yeniden kontrol edilir. Eğer sağlamıyorsa tekrar yerel maksimum ve yerel minimum değerleri kullanılarak yeni bir yerel ortalama değeri hesaplanır. Bu işlem elde edilen sinyal İMF koşulunu sağlayıncaya kadar devam ettirilir [90-91]. Daha sonra, bu sinyal asıl sinyalden çıkarılarak artık sinyal elde edilir. İMF oluşturma işlemleri artık sinyal içinde yapılır ve tüm sinyal için monotonik bir fonksiyon elde edilir. Sinyal monotonik bir fonksiyon olduğunda ya da sinyalde yalnızca bir adet yerel uç değeri olduğunda bu sinyalden İMF koşulunun kontrolü mümkün değildir. Bu durumda AMA işlemine son verilir [88]. AMA işleminden sonra elde edilen  $IMF_i(t)$  içsel mod fonksiyonu aşağıdaki gibi ifade edilir.

$$x(t) = \sum_{i=1}^n IMF_i(t) + r_n(t) \quad (4.1)$$

Burada  $x(t)$  orijinal sinyali,  $r_n(t)$  artık sinyali,  $n$  ise algoritmadaki adım sayısını göstermektedir.

#### 4.2.2.2 Hilbert Dönüşümü

Doğrusal olmayan ve durağan olmayan sinyallerin en önemli özelliklerinden biri, tek bir salınım süresinde anlık frekans değerlerini gösteren içsel dalga frekans modülasyonuna sahip olmasıdır. Bu tip sinyallerin karakteristiğini en anlaşılır şekilde anlık frekans değerleri verir. En temel anlık frekans değeri belirleyicisi Hilbert Dönüşümü (HD)'dür [89-91]. Gerçek değerli bir  $x(t)$  fonksiyonunun HD'si,

$$y(t) = H[x(t)] = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (4.2)$$

ile ifade edilir. Burada  $y(t)$ ;  $x(t)$  fonksiyonunun HD uygulanmış halidir.  $x(t)$  fonksiyonunun analitik olarak aşağıdaki gibi gösterilmektedir:

$$z(t) = x(t) + jy(t) = a(t)e^{j\theta(t)} \quad (4.3)$$

$$a(t) = \sqrt{x^2(t) + y^2(t)} \quad (4.4)$$

$$\theta(t) = \arctan \left[ \frac{y(t)}{x(t)} \right] \quad (4.5)$$

Burada  $a(t)$  anlık genlik ve  $\theta(t)$  faz fonksiyonlarıdır [91]. Bu fonksiyona ait anlık açısal frekans ( $w(t)$ ) ve anlık frekans bilgisi ( $f(t)$ );

$$w(t) = \frac{d\theta(t)}{dt} \quad (4.6)$$

$$f(t) = \frac{1}{2\pi} * \frac{d\theta(t)}{dt} \quad (4.7)$$

ile ifade edilir.  $x(t)$  işaretinden AMA işlemiyle elde edilen her bir İMF'nin HD'si alınması durumunda  $x(t)$ ;

$$x(t) = \Re \left\{ \sum_{i=1}^n a_i(t) e^{jw_i(t)t} \right\} \quad (4.8)$$

eşitliğiyle analitik olarak ifade edilir. Burada  $i$ ;  $x(t)$  işaretine AMA işlemi uygulandığında elde edilen İMF sayısını göstermektedir [89-91].

Bu çalışmada; sağlıklı, EEDR ve GEDR denek gruplarından alınan VOG sinyallerine HHD yöntemi uygulanmıştır. Denek gruplarından elde edilen sinyal veri seti arasındaki farklılıklar net bir şekilde yüksek dereceli içsel mod fonksiyonlarında (İMF) elde edildiğinden, uygulanan HHD yönteminin ilk 4 içsel mod fonksiyonu (İMF1-İMF4) öznitelik vektörleri olarak kullanılmıştır [92].





## BÖLÜM 5

### YAPAY ZEKÂ YÖNTEMLERİ VE İSTATİSTİKSEL PERFORMANS ANALİZİ


Bu bölümde çalışma kapsamında kullanılan yapay zekâ yöntemleri ve performans ölçütleri ayrıntılı bir şekilde anlatılmıştır.

#### 5.1 YAPAY SİNİR AĞLARI

Karmaşık nöron (sinir hücresi) bağlantılarına sahip insan beyninin davranışının açıklanması bilim adamları için önemli bir araştırma alanı olmuştur. Günümüzde nöron hücresinin basit modelinin ortaya konulmasıyla geliştirilen yapay sinir ağları (YSA) modeli mühendislik, tıp gibi pek çok araştırma alanında önemli bir araç olarak kullanılmaya başlanmıştır. YSA modeli, beynin paralel işlem ve genelleme yeteneklerini temel almaktadır [93-94].

##### 5.1.1 Biyolojik Sinir Ağı ve Nöron

Biyolojik sinir ağ yapısı, 10 milyardan fazla nöronun birbiri ile bağlantısından oluşmaktadır. Nöronlar sinaps adı verilen özel yapılar ile birbiriyle bağlantı kurmaktadır. Ağ içerisindeki bir nöron soma, akson ve dentrit olarak adlandırılan yapılardan meydana gelmektedir [95-96]. Soma; hücre çekirdeği, çekirdekçik ve stoplazmik sıvıdan oluşmaktadır. Dentritler, lifli yapıları ile diğer hücrelerin dentritleriyle bağ oluşturabilmekte ve diğer nöronlardan gelen elektriksel bilgiyi somaya iletmektedir. Akson ise somadan gelen elektriksel bilgiyi akson uçları yardımıyla diğer hücrelere taşımaktadır [97-98]. Biyolojik nöron hücre yapısı Şekil 5.1'de gösterilmiştir.




Şekil 5.1 Biyolojik nöron hücresi [99].

### 5.1.2 Yapay Sinir Ağlarında Kullanılan İşlem Birimi

İnsan beyni deneyimleri sayesinde genelleme yapabilme yeteneğine sahip bir kontrol organıdır. İnsan beyninin bu özelliğinden yola çıkılarak matematiksel olarak yapay sinir ağları (YSA) geliştirilmiştir. YSA yapısal olarak nöronlar (işlem birimi) ve işlem birimleri arasında kurulan bağlantılardan oluşmaktadır [100]. İşlem birimindeki nöronlar arasındaki bağlantı şekillerine göre farklı ağ topolojileri elde edilmektedir. Ağ topolojisindeki nöronların davranışları, farklı öğrenme algoritmaları kullanılarak matematiksel olarak tanımlanmaktadır [101].

İşlem birimi, biyolojik nöron hücresinin davranışına benzer şekilde, kendine gelen bir ya da daha fazla girdiyi toplayan, eşik değerine göre bilginin iletimine karar veren paralel işlem elemanıdır (Şekil 5.2) [102].



Şekil 5.2 İşlem birimi yapısı [103].

İşlem birimi dışarıdan veya birden fazla işlem biriminden  $x_1, x_2, \dots, x_i$  şeklinde girişler almaktadır. Bu girişlerin nörona olan etkileri bağlantı ağırlıklarına ( $w_1, w_2, \dots, w_i$ ) göre değişmekte ve belirli bir eşik değerine kadar bastırılmaktadır. Yani işlem biriminde herhangi



bir çıkış üretilmeden önce aşılması gereken bir eşik değeri bulunmaktadır. Eşik değeri, biyolojik sinir hücrelerinde olduğu gibi 1 olarak tanımlanmakta ve rastgele tanımlanan bir ağırlıkta (b) işlem birimine etki etmektedir. İşlem birimi kendisine gelen bütün girdileri toplam fonksiyonu yardımı ile birleştirmektedir [103-104]. Toplam fonksiyonu matematiksel olarak aşağıdaki gibi ifade edilmektedir:

$$y = \left[ \sum_{n=1}^i x_n w_n \right] + b \quad (5.1)$$

İşlem biriminin net çıkışı ise aktivasyon fonksiyonuna bağlı olarak aşağıdaki gibi tanımlanmaktadır:

$$z = f(y) \quad (5.2)$$


YSA'da işlem birimleri paralel işlem yapabilecek şekilde gruplar oluşturabilmektedir. Bu grupsal yapılar katman denilen paralel işlem düzenlerini oluşturmaktadır [105]. Dış dünyadan girdi alan grup yapısına giriş, dış dünyaya bilgi çıkışı sağlayacak grup yapısına ise çıkış katmanı ismi verilmektedir. Giriş ile çıkış katmanları arasında yakınsama sürecini gerçekleştirecek olan grup yapısı ise ara katman olarak tanımlanmaktadır [106-107].

### 5.1.3 Yapay Sinir Ağlarının Sınıflandırılması

Karmaşık bir yapıya sahip olan YSA, yapısında bulunan nöronların birbiriyle yaptıkları bağlantı şekillerine göre ileri ve geri beslemeli ağlar olarak ikiye ayrılmaktadır. İleri beslemeli ağlarda, nöronlar girişten çıkışa doğru düzenli katmanlar şeklinde olup, her bir katman sadece kendinden sonraki katmana bağlanmaktadır. Geri beslemeli ağ yapısında ise katmanlar arasında düzenli bir bağlantı olmadığından dolayı bir katmanın sadece kendinden sonrakiyle değil, kendinden önceki katmanla veya kendi katmanında bulunan herhangi bir nöronla bağlantısı olabilmektedir. Yapılan bu çalışmada ileri beslemeli ağ yapısı kullanılmıştır.

### 5.1.3.1 İleri beslemeli ağ yapısı

İleri beslemeli ağ yapısı; katmansal olarak gruplandırılan işlem birimlerinin giriş katmanından başlayarak ara katman ve çıkış katmanına ileri yönde bağlandığı bir ağ yapısıdır. Bu ağ yapısında bilgi; giriş katmanından çıkış katmanına doğru ağın beklenen çıkışına yakınsanması için işlem birimleri tarafından işlenerek aktarılmaktadır. Bilginin çıkış katmanından dış dünyaya aktarımı beklenen çıkıştan hata hesabı yapılarak kontrol edilmektedir [109]. İleri beslemeli ağlara örnek olarak, çok katmanlı yapay sinir ağı (ÇKYSA), MADALINE ve öğrenmeli vektör kuantalama (LVQ) ağları verilebilir. Bunlardan en yaygın kullanılan ÇKYSA modeli Şekil 5.3'te gösterilmiştir.



Şekil 5.3 ÇKYSA modeli [110].


### 5.1.3.2 Çok Katmanlı Yapay Sinir Ağı Modeli

Rosenblatt tarafından önerilen çok katmanlı yapay sinir ağ modeli (ÇKYSA), doğrusal olarak ayrıştırılabilen örüntü uzayını sınıflandırabilmek amacıyla önerilen bir algoritmadır [110]. Model matematiksel olarak, eşik değeri ( $b$ ) ve girdilerin ( $x_1, x_2, \dots, x_i$ ) ağırlıklarla ( $w_1, w_2, \dots, w_i$ ) ölçeklendirildiği bir topolojiye sahiptir (Şekil 5.4). Eşik değere ( $b$ ) göre ağırlıklandırılmış girdiler değerlendirilerek bir toplam fonksiyonu ( $f$ ) elde edilmektedir [111-112]. Ağ modeline ait toplam fonksiyon,

$$f = \left( \sum_{n=1}^i x_n w_n \right) + b \quad (5.3)$$

ile ifade edilmektedir.  $f$  fonksiyonu hesaplandıktan sonra nöron, aktivasyon fonksiyonu ile bilgiyi iletmektedir. ÇKYSA modeline ait aktivasyon işlemi aşağıdaki gibi tanımlanmaktadır:

$$\text{Çıkışlar} = \begin{cases} 1, & \text{Eğer } f \geq 0 \\ 0, & \text{Eğer } f < 0 \end{cases} \quad (5.4)$$



Şekil 5.4 ÇKYSA modeli yapısı [103].

ÇKYSA modeli çevrim dışı öğrenme algoritmasına sahiptir. Modelde veri seti, eğitim ve test için rastgele ayrılmaktadır. Modelin çıkışının beklenen çıkışa eşit olmaması durumunda öğrenme sürecindeki ağırlıklar aşağıdaki eşitliğe göre yeniden ayarlanmaktadır [112]:


$$w(n+1) = w(n) + \alpha * (b_{\zeta}(n) - h_{\zeta}(n)) * x(n) \quad (5.5)$$

Burada  $b_{\zeta}$  beklenen çıkış,  $h_{\zeta}$  hesaplanan çıkış ve  $n$  iteratif olarak öğrenme sürecindeki ağırlık hesap adımını ifade etmektedir.  $\alpha$  ise momentum katsayısı olup, değeri  $[0,1]$  aralığında değişmektedir.

### 5.1.3.3 Radyal Tabanlı Fonksiyon Ağı

Radyal Tabanlı Fonksiyon ağı (RTFA) yapısı; genel ÇKYSA modeline benzer şekilde giriş katmanı, gizli katman ve çıktı katmanı olmak üzere üç katmandan oluşmaktadır (Şekil 5.5). ÇKYSA modeline göre daha hızlı çalışan RTFA'da, giriş katmanından gizli katmana geçişte

radyal tabanlı aktivasyon fonksiyonları ve doğrusal olmayan kümeleme algoritması kullanılmaktadır. Gizli katman ile çıkış katmanı arasındaki bağlantılar sayesinde ağın eğitimi gerçekleştirilmektedir [113].



Şekil 5.5 RTFA ağ yapısı [114].

Bu ağa ait çıkış katmanının matematiksel ifadesi,

$$Y = \sum_{m=1}^i \sum_{n=1}^j w_n \exp\left(-\frac{\|x_m - H_n\|^2}{2\sigma_n^2}\right) \quad (5.6)$$

ile ifade edilmektedir. Burada  $x_m$  giriş,  $w_n$  ağırlıklar,  $j$  gizli katmandaki nöron sayısı,  $H_n$   $n$ 'inci nöron merkezi,  $\sigma_n$   $n$ . dağılım parametresi ve  $Y$  ağın çıkışıdır. Ağın çıkışı ( $Y$ ), gizli katman çıkışlarının  $w_n$  ağırlıklarıyla çarpılması sonucunda elde edilmektedir [113].

## 5.2 C4.5 KARAR AĞACI ALGORİTMASI

C4.5 karar ağacı algoritması, sayısal değerlere sahip bir karar ağacı oluşturmak için Quinlan tarafından 1996 yılında geliştirilmiştir [115]. Bu algoritmada sayısal değerler kategorik değerler haline dönüştürülmekte ve en büyük bilgi kazancını sağlayacak bir eşik değeri

belirlenmektedir. Eşik değeri belirlemek için tüm değerler sıralanarak ikiye bölünmekte ve bir orta nokta hesaplanmaktadır [116].

C4.5 karar ağacı algoritması temel olarak aşağıdaki basamaklardan oluşmaktadır [117]:

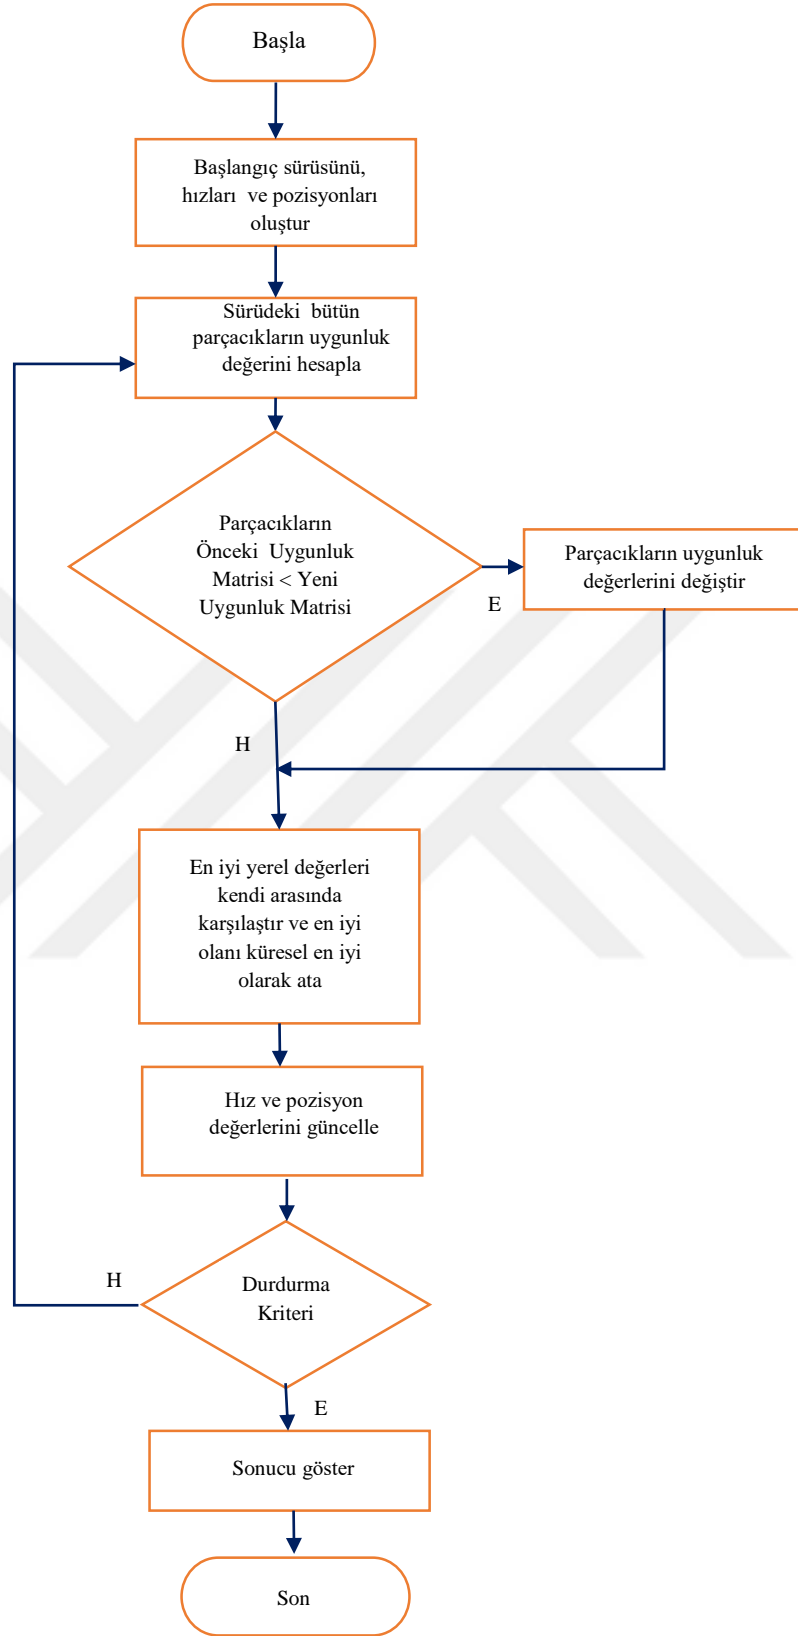
1. Her adımda bütün özellikler kontrol edilir.
2. Her özelliğin normalize edilmiş bilgi kazancı hesaplanır.
3. En iyi bilgi kazanımını veren özellik karar ağacında karar olarak taşınır.
4. Ardından bu yeni karar düğümünün altında bir alt liste oluşturularak alt karar ağacı inşa edilir.

### 5.3 PARÇACIK SÜRÜ OPTİMİZASYONU

Parçacık Sürü Optimizasyonu (PSO), kuş sürülerinin davranışlarından esinlenilerek ortaya çıkarılmış popülasyon tabanlı bir optimizasyon yöntemidir. Temel olarak sürü zekâsına dayanan bir algoritmadır [118]. PSO'nun klasik optimizasyon tekniklerinden en önemli farklılığı türev bilgisine ihtiyaç duymamasıdır. Bu özellik birçok problemin çözümü için gerekli olan karmaşık işlem yükünün hafifletilmesini sağlamaktadır. PSO; fonksiyon optimizasyonu, bulanık sistem kontrolü, yapay sinir ağı eğitimi gibi birçok alanda başarıyla uygulanabilmektedir [119].

PSO algoritmasında; sürüdeki her bir kuş parçacık, parçacıklardan oluşan popülasyon da sürü olarak adlandırılmaktadır. PSO, temel olarak sürüde bulunan bireylerin pozisyonunun, sürünün en iyi pozisyona sahip olan bireyine yaklaştırılmasına dayanmaktadır. Bu yaklaşma hızı rasgele gelişen bir durum olup, çoğu zaman sürü içinde bulunan bireyler yeni hareketlerinde bir önceki konumdan daha iyi konuma gelmekte ve bu süreç hedefe ulaşıncaya kadar devam etmektedir [120-121].

PSO'nun genel akış diyagramı Şekil 5.6'da verilmiştir. Algoritma işletilmeye başlamadan önce bir sürü oluşturularak, hız ve pozisyon gibi başlangıç değerlerine göre sürünün lideri atanmaktadır.



**Şekil 5.6** Parçacık sürü optimizasyonu algoritması akış diyagramı.

PSO algoritmasının temel basamakları aşağıdaki gibi tanımlanmaktadır [122]:

1. Rasgele üretilen başlangıç pozisyonları ( $x_{i1}, x_{i2}, \dots, x_{iD}$ ) ve hızları ( $v_{i1}, v_{i2}, \dots, v_{iD}$ ) ile başlangıç sürüsü oluşturulur.
2. Sürü içerisindeki tüm parçacıkların (i) uygunluk değerleri ( $c_1, c_2$ ) hesaplanır.
3. Her bir parçacık için mevcut jenerasyondan yerel kişisel en iyi ( $p_{eniyi}$ ) bulunur. Sürü içerisinde en iyilerin sayısı (k) parçacık sayısı kadardır.
4. Mevcut jenerasyondaki yerel en iyiler içerisinde küresel en iyi ( $g_{eniyi}$ ) seçilir.
5. Pozisyon ve hızlar yenilenir.

PSO algoritmasında; parçacığın her pozisyonundaki değişim miktarını gösteren hız ve pozisyon vektörleri sırasıyla,

$$V_i = [v_{i1}, v_{i2}, \dots, v_{iD}] \quad (5.8)$$

$$X_i = [x_{i1}, x_{i2}, \dots, x_{iD}] \quad (5.9)$$

eşitlikleri ile ifade edilir. Algoritmada parçacıklar hız ve pozisyonlarını sırasıyla aşağıdaki eşitliklere göre güncellenmektedir:

$$V_i^{k+1} = V_i^k + c_1 \text{rand}_1^k (p_{eniyi}^k - x_i^k) + c_2 \text{rand}_2^k (g_{eniyi}^k - x_i^k) \quad (5.10)$$

$$X_i^{k+1} = X_i^k + V_i^{k+1} \quad (5.11)$$

## 5.4 PERFORMANS ÖLÇÜTLERİ

Eğitim ve test verilerinin sınıflandırma başarımını etkilediği bilindiğinden, veri setlerinden eğitim ve test veri setlerinin belirlenmesi önem arz etmektedir [123]. Literatürdeki çalışmalarda veri setleri, “hold-out”, “k-fold” ve “leave-one-out” çapraz doğrulama yöntemleri ile test ve eğitim veri setlerine ayrılmaktadır [124]. Yapılan çalışmada, veri setinin eğitim ve test olmak üzere iki kısma ayrıldığı yöntem olan hold-out çapraz doğrulama yöntemi kullanılmıştır. Bu

yöntemde; eğitim veri setiyle modelin öğrenmesi sağlanmakta ve test veri setiyle ise öğrenmenin ne kadar gerçekleştiği kontrol edilerek model performansı elde edilmektedir. Modelin performansı, doğru pozitif (DP), doğru negatif (DN), yanlış pozitif (YP) ve yanlış negatif (YN) değerleri ile tespit edilmektedir [125]. Örnek pozitifse ve pozitif olarak sınıflandırılmışsa sonuç DP olarak; negatif olarak sınıflandırılırsa YN olarak belirlenmektedir. Örnek negatifse ve negatif olarak sınıflandırılmışsa sonuç DN olarak; pozitif olarak sınıflandırılırsa YP olarak değerlendirilmektedir [126]. Bu değerlere göre tahminlerin doğruluğunu gösteren karmaşıklık matrisi oluşturulmaktadır.

Sınıflandırıcıların başarımlarında kullanılan performans ölçütleri;

$$\text{Doğruluk (\%)} = 100 * \frac{DP + DN}{DP + DN + YP + YN} \quad (5.12)$$

$$\text{Duyarlılık (\%)} = 100 * \frac{DP}{DP + YN} \quad (5.13)$$

$$\text{Hassasiyet (\%)} = 100 * \frac{DP}{DP + YP} \quad (5.14)$$

$$\text{Özgüllük (\%)} = 100 * \frac{DN}{DN + YP} \quad (5.15)$$

$$F - \text{Skor} = 2 * \frac{\text{Duyarlılık} * \text{Hassasiyet}}{\text{Duyarlılık} + \text{Hassasiyet}} \quad (5.16)$$

eşitliklerine göre hesaplanmaktadır. Bunun yanı sıra yapay zekâ problemlerinde, model sonuçlarının analizinde birçok istatistiksel performans ölçüm kriterleri kullanılmaktadır [127]. Yapılan bu tez çalışmasında, tahmin edilen ile gerçek çıkışlar arasındaki oransal yakınlığı hesaplayabilmek amacıyla ortalama karesel hata, ortalama mutlak hata, ortalama karekök hata ve belirlilik katsayısı ( $R^2$ ) değerleri aşağıdaki verilen eşitliklere göre hesaplanmıştır:



$$\text{Ortalama Karesel Hata} = \frac{1}{N} \sum_{i=1}^N (h_{\zeta_i} - b_{\zeta_i})^2 \quad (5.17)$$

$$\text{Ortalama Mutlak Hata} = \frac{1}{N} \sum_{i=1}^N |h_{\zeta_i} - b_{\zeta_i}| \quad (5.18)$$

$$\text{Ortalama Karekök Hata} = \sqrt{\text{Ortalama Karesel Hata}} \quad (5.19)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (h_{\zeta_i} - b_{\zeta_i})^2}{\sum_{i=1}^N b_{\zeta_i}^2} \quad (5.20)$$

Burada N örnek sayısını,  $h_{\zeta_i}$  ve  $b_{\zeta_i}$  ise sırasıyla hesaplanan ve beklenen ağ çıkışını göstermektedir.



## BÖLÜM 6

### SİMÜLASYON VE ANALİZ SONUÇLARI

Bu tez çalışması kapsamında; sağlıklı ve diyabetik retinopati (DR) hastalığına sahip kişilerden elde edilen Video-Okülografi (VOG) sinyalleri kullanılarak, geleneksel yapay zekâ modellerinin (çok katmanlı yapay sinir ağı, radyal tabanlı fonksiyon ağı) ve PSO temelli bir hibrit modelinin göz hastalığının teşhisinde uygulanabilirliği ile söz konusu modellerin performans analizleri araştırılmıştır. Bu amaç doğrultusunda veri setini oluşturmak için MetroVision MonPackOne cihazında mevcut 200 Hz'lik iç takip kamerası kullanılarak sağlıklı ve DR hastalığı bulunan deneklerden farklı zamanlarda Video-Okülografi (VOG) sinyalleri alınmıştır. VOG sinyallerinden öznitelik çıkarımında ayrık dalgacık dönüşümü (ADD) ve Hilbert – Huang dönüşümü (HHD) kullanılmıştır. ADD yönteminde yaklaşım ve detay katsayısı olarak sırasıyla 4. Seviye (A4) ve 1. Seviye (D1) - 4. seviye (D4) arasındaki katsayılar göz önünde bulundurulmuştur. HHD'de ise içsel mod fonksiyonları (İMF) ve artık sinyaller dikkate alınmıştır. Çıkarılan öznitelikler DR hastalığının sınıflandırmasında kullanılmıştır. Sinyal işleme, öznitelik çıkarımı, sınıflandırma işlemleri ve analizleri MATLAB (R2013) yazılım paketi kullanılarak gerçekleştirilmiştir.


Çalışmada kullanılan her bir yöntemin farklı veri setleri kullanılarak DR hastalığının teşhisinde uygulanabilirliği irdelenmiştir. Bu amaç doğrultusunda ilk olarak, ADD yöntemiyle DR hastalığının VOG sinyallerine fizyolojik etkileri incelenmiştir. Daha sonra, ADD yöntemiyle VOG sinyallerinden çıkarılan istatistiksel öznitelikler çok katmanlı yapay sinir ağı (ÇKYSA) modelinde kullanılarak DR hastalığının tahmini araştırılmıştır. Sonrasında ADD yöntemi ile çıkarılan istatistiksel özniteliklerden C4.5 karar ağacı algoritması kullanılarak yeni öznitelikler seçilmiştir. Seçilen bu öznitelikler ile ADD yöntemine göre belirlenen istatistiksel öznitelikler iki farklı ÇKYSA modeline uygulanarak, modellerin performansları karşılaştırılmıştır.

Daha sonra DR hastalığının teşhisi amacıyla ADD yöntemiyle belirlenen özneliklerin ÇKYSA ile radyal tabanlı fonksiyon ağı (RTFA) modellerinde kullanılması durumunda elde edilen performanslar kıyaslanmıştır. Son olarak; ADD ve HHD yöntemleriyle öznelik çıkarımı yapılarak, iki farklı parçacık sürü optimizasyonu algoritması (PSO) temelli hibrit ÇKYSA modeli tasarlanmış ve modellerin DR hastalığının teşhisindeki sınıflandırma başarımı incelenmiştir.

## **6.1 AYRIK DALGACIK DÖNÜŞÜMÜ KULLANILARAK DİYABETİK RETİNOPATİ HASTALIĞININ VIDEO-OKÜLOGRAFİ (VOG) SİNYALLERİNE FİZYOLOJİK ETKİLERİNİN BELİRLENMESİ**


DR hastalığının VOG sinyalleri üzerindeki fizyolojik etkisinin araştırılması için sinyallerin frekans ve zaman bölgesindeki bileşen analizlerinin yapılarak, sinyaller arasındaki farklılıkların belirlenmesi gerekmektedir. Bu bağlamda çalışmada ilk olarak, ADD yöntemi kullanılarak VOG sinyallerinin analizi yapılmıştır.

Veri seti; yaşları 19-70 arasında değişen 17'si sağlıklı, 16'sı erken evre diyabetik retinopati (EEDR) ve 17'si geç evre diyabetik retinopati (GEDR) hastalığına sahip olan 50 gönüllü denekten alınan VOG sinyallerinden oluşmaktadır. Şekil 6.1, Şekil 6.2, Şekil 6.3 ve Şekil 6.4'te sırasıyla sağlıklı, EEDR ve GEDR denek gruplarının sol göz yatay/dikey ve sağ göz yatay/dikey konumlarından elde edilen VOG sinyallerinin ortalamaları gösterilmiştir.



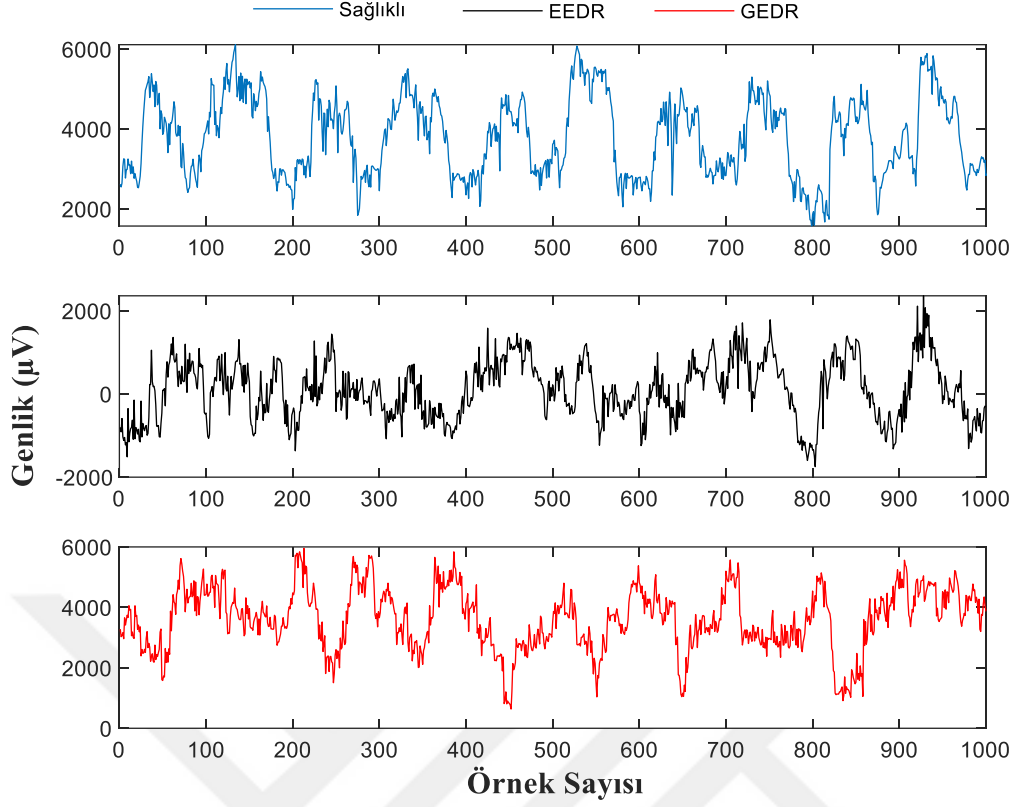
**Şekil 6.1** Sol göz yatay konuma ait sağlıklı, EEDR ve GEDR denek gruplarından alınan VOG sinyalleri.

Şekilden de görüldüğü gibi sol göz yatay konum göz hareketlerinde; EEDR sağlıklı denek grubuna göre sinyal genliğini yaklaşık 2 kat artırmakta (0,3 mV) ve gürültü oranını artırarak sinyali negatif bölgeye kaydırmaktadır. GEDR, sağlıklı denek grubuna nazaran sinyal genliğini biraz yükseltmekte veya eşit algılamakta, ayrıca sinyali negatif bölgeye kaydırarak sinyal karakteristiğini tamamen değiştirmektedir (bilgi farklılaşmaktadır).




**Şekil 6.2** Sağ göz yatay konuma ait sağlıklı, EEDR ve GEDR denek gruplarından alınan VOG sinyalleri.

Sağ göz yatay konum göz hareketleri incelendiğinde (Şekil 6.2); EEDR denek grubu için elde edilen sinyalin genliği sağlıklı gruba kıyasla yaklaşık 1,5 kat (0,2 mV) artmakta ve sinyalin karakteristiği değişmektedir. GEDR denek grubu için elde edilen sinyalin genliği sağlıklı grubunkine eşit olmasına rağmen, karakteristiği sağlıklı gruptan tamamen farklıdır.



**Şekil 6.3** Sol göz dikey konuma ait sağlıklı, EEDR ve GEDR denek gruplarından alınan VOG sinyalleri.

Şekil 6.3 incelendiğinde sol göz dikey konum göz hareketleri için; EEDR sağlıklı denek grubuna göre VOG sinyal genliğini 0,1 mV azaltmakta ve gürültünün artmasıyla sinyal karakteristiğini büyük oranda değiştirerek sinyali negatif bölgeye kaydırmaktadır. GEDR ise, sağlıklı denek grubuna göre sinyalin genliğini biraz yükseltmekte veya eşit algılamakta ve sinyal pozitif bölgede kalsa da karakteristiğini tamamen değiştirmektedir.

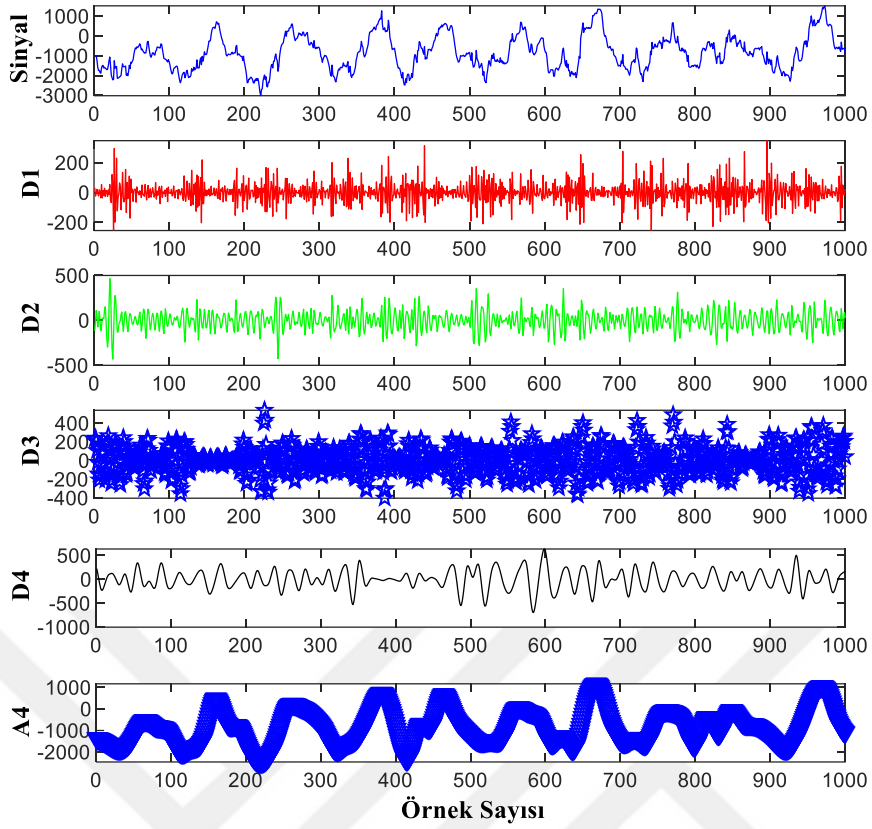


**Şekil 6.4** Sağ göz dikey konuma ait sağlıklı, EEDR ve GEDR denek gruplarından alınan VOG sinyalleri.

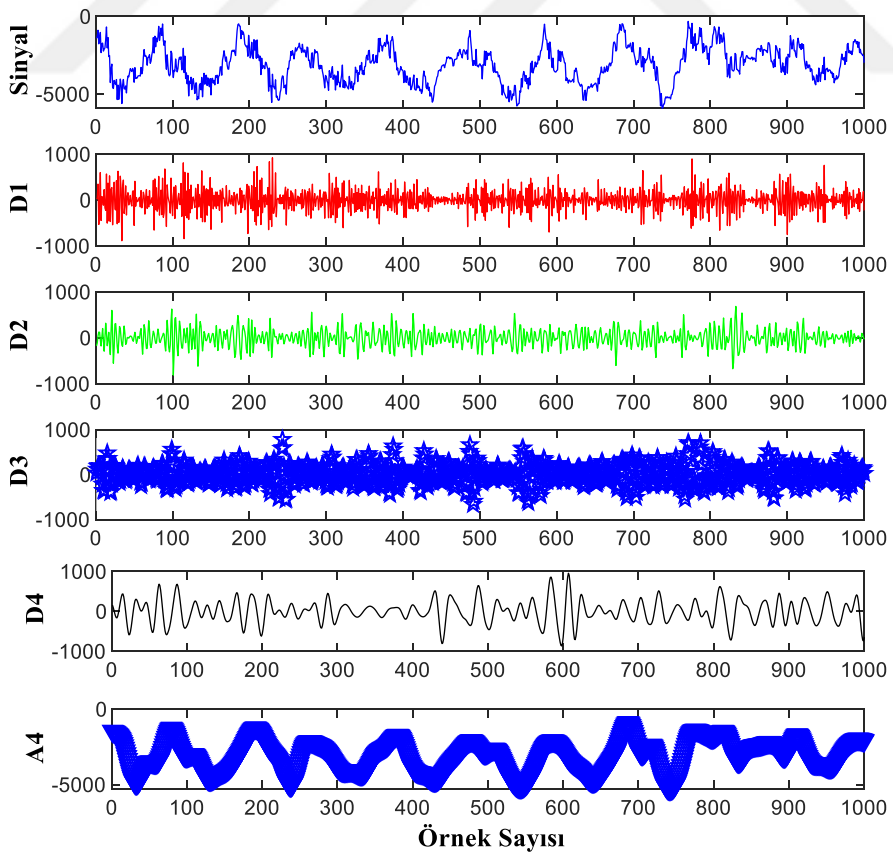
Şekil 6.4'ten görüldüğü gibi sağ göz dikey konum göz hareketlerinde; sinyal genliği sağlıklı, EEDR ve GEDR denek grupları için eşittir. Ancak DR hastalığının ilerlemesine göre VOG sinyallerinin gürültü oranlarının artmasına bağlı olarak sinyallerin karakteristiği bozulmaktadır.

Sağlıklı, EEDR ve GEDR denek gruplarının 4 farklı göz konumlarından alınan VOG sinyalleri arasındaki farklılıklar ortaya koyulduktan sonra, söz konusu sinyallerden ayırık dalgacık dönüşümü (ADD) kullanılarak öznelik çıkarımı yapılmıştır. Bunun için ADD' de ana dalgacık tipi olarak Daubechies4 (db4) seçilerek, 4. seviye yaklaşım (A4) ve detay (D1-D4) katsayıları elde edilmiştir. Buna göre farklı göz konumlarından elde edilen VOG sinyallerine ait ADD katsayıları sırasıyla Şekil 6.5, Şekil 6.6, Şekil 6.7 ve Şekil 6.8'de gösterilmiştir.

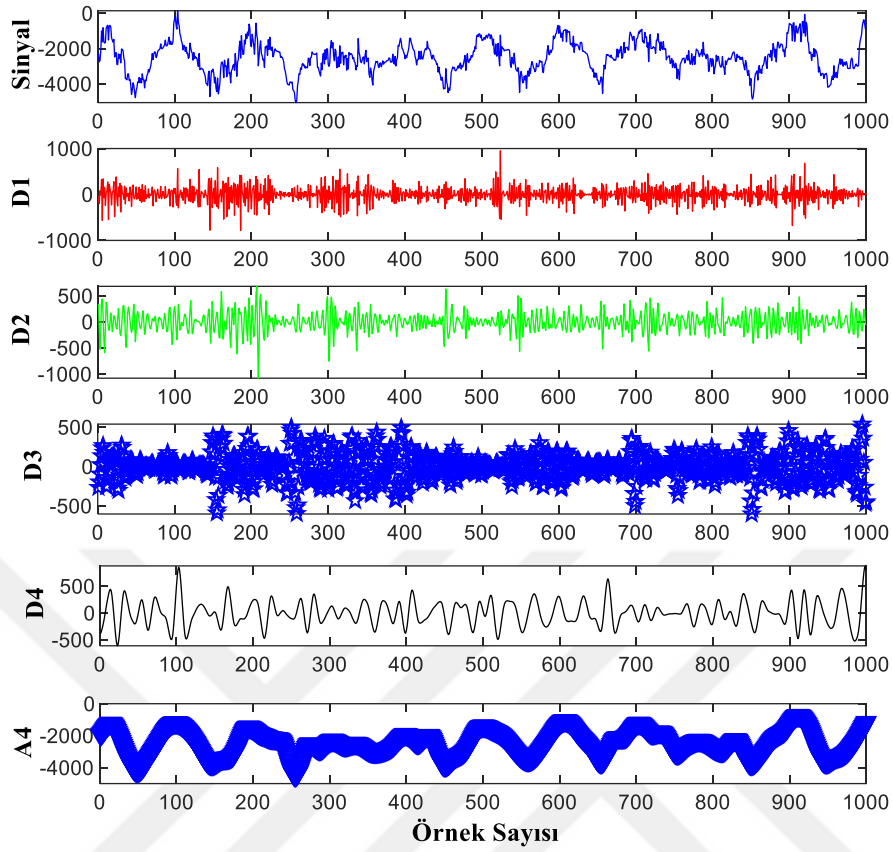




(a)



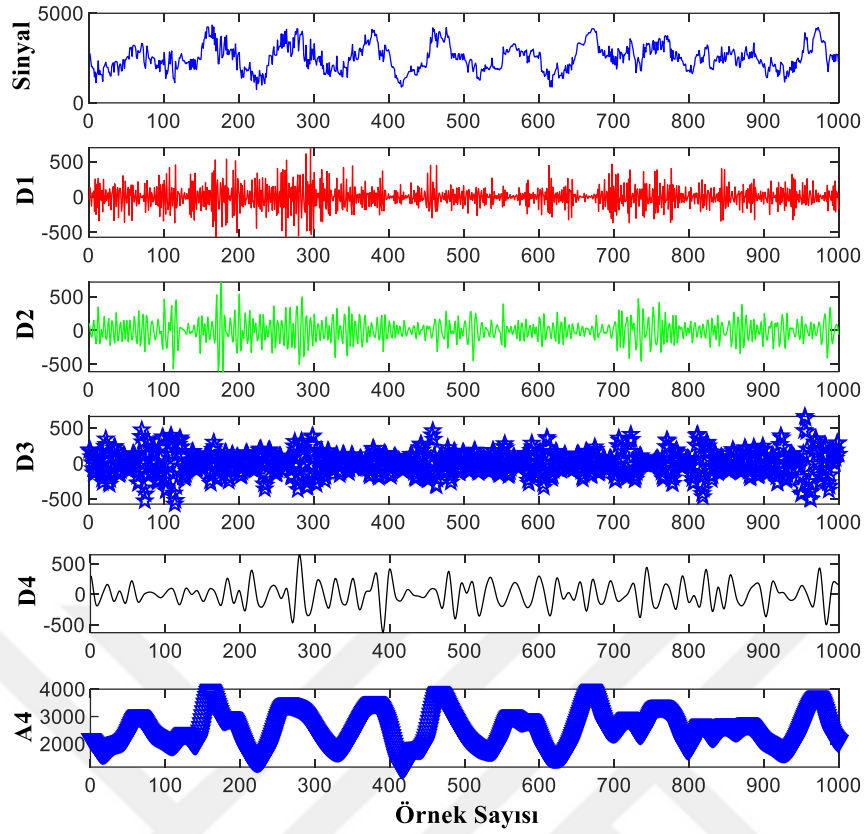
(b)



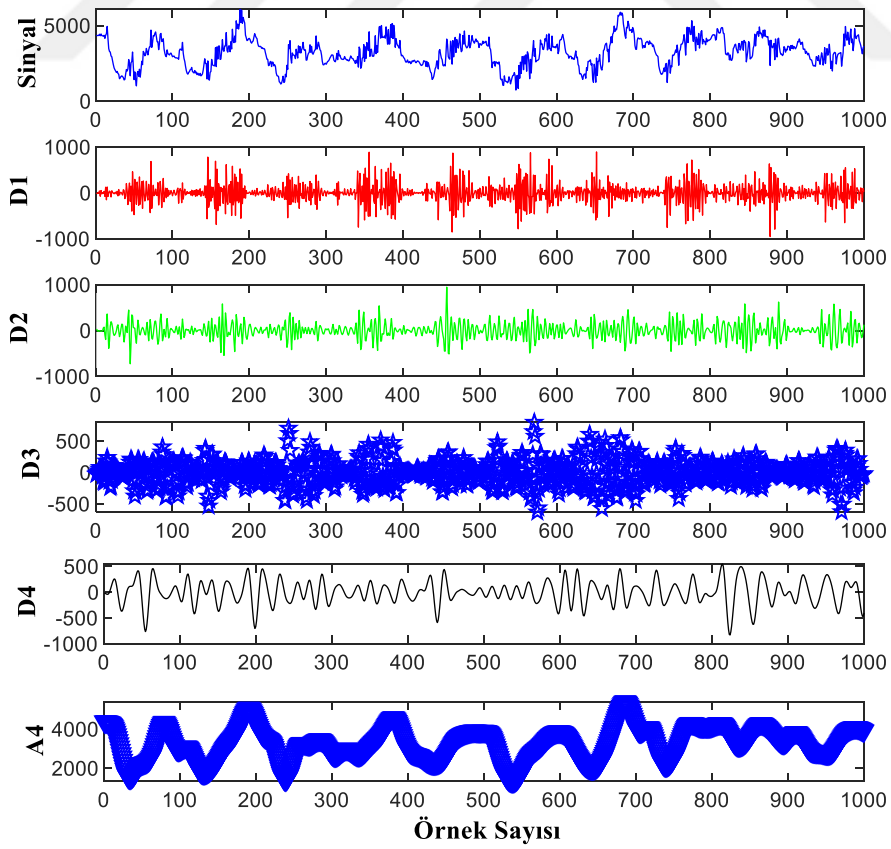
(c)

**Şekil 6.5** Sol göz yatay konum için VOG sinyalleri ve ADD katsayıları a) Sağlıklı denek grubu b) EEDR denek grubu c) GEDR denek grubu.

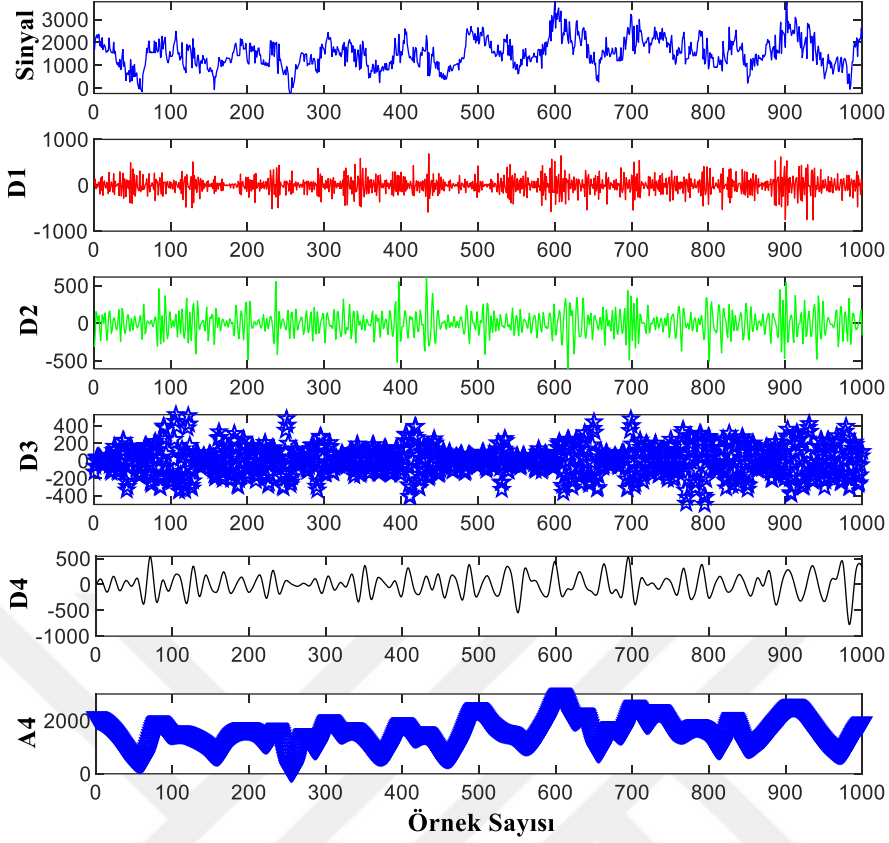
Şekilden de görüldüğü gibi sol göz yatay konumundan alınan VOG sinyallerinden ADD yöntemiyle hesaplanan A4 yaklaşım katsayısı, EEDR ve GEDR denek gruplarında sağlıklı gruba göre negatif bölgeye kaymıştır. Bunun yanı sıra, GEDR denek gruplarından elde edilen A4 yaklaşım ve D1-D4 detay katsayılarının diğer denek gruplarına kıyasla daha gürültülü olduğu gözlemlenmiştir.



(a)



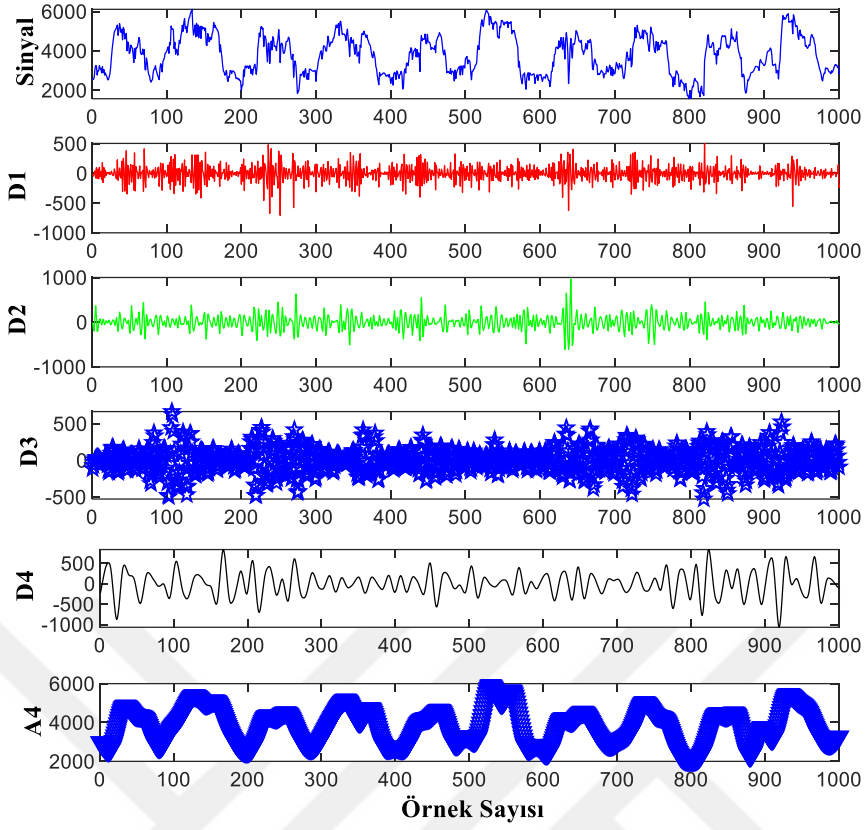
(b)



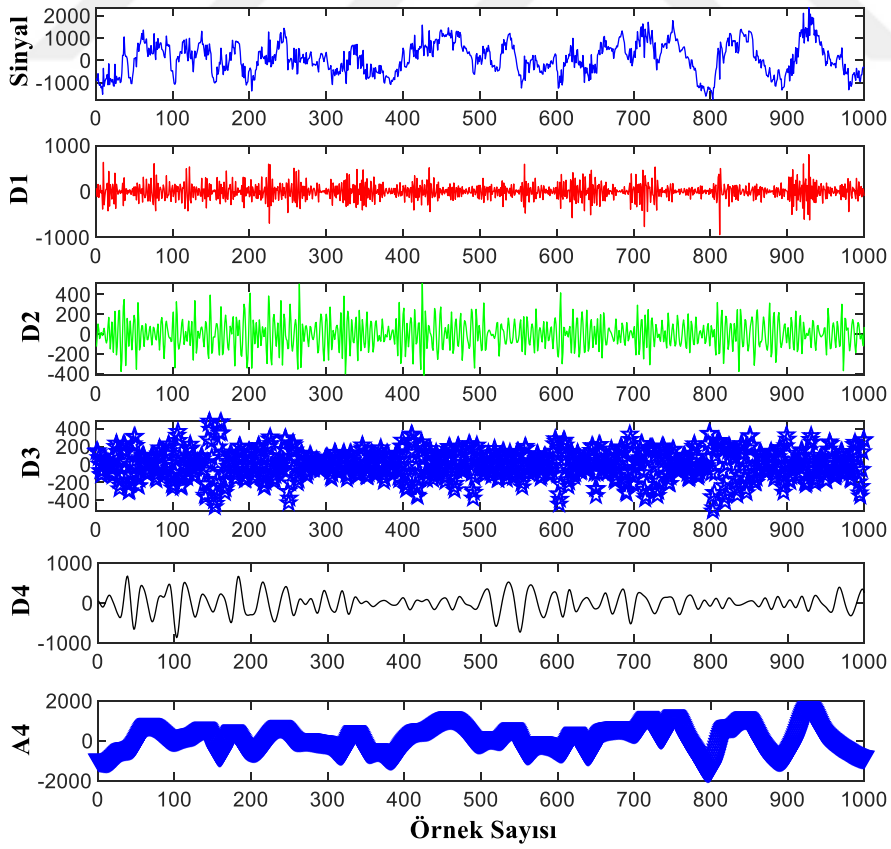
(c)

**Şekil 6.6** Sağ göz yatay konum için VOG sinyalleri ve ADD katsayıları a) Sağlıklı denek grubu b) EEDR denek grubu c) GEDR denek grubu.

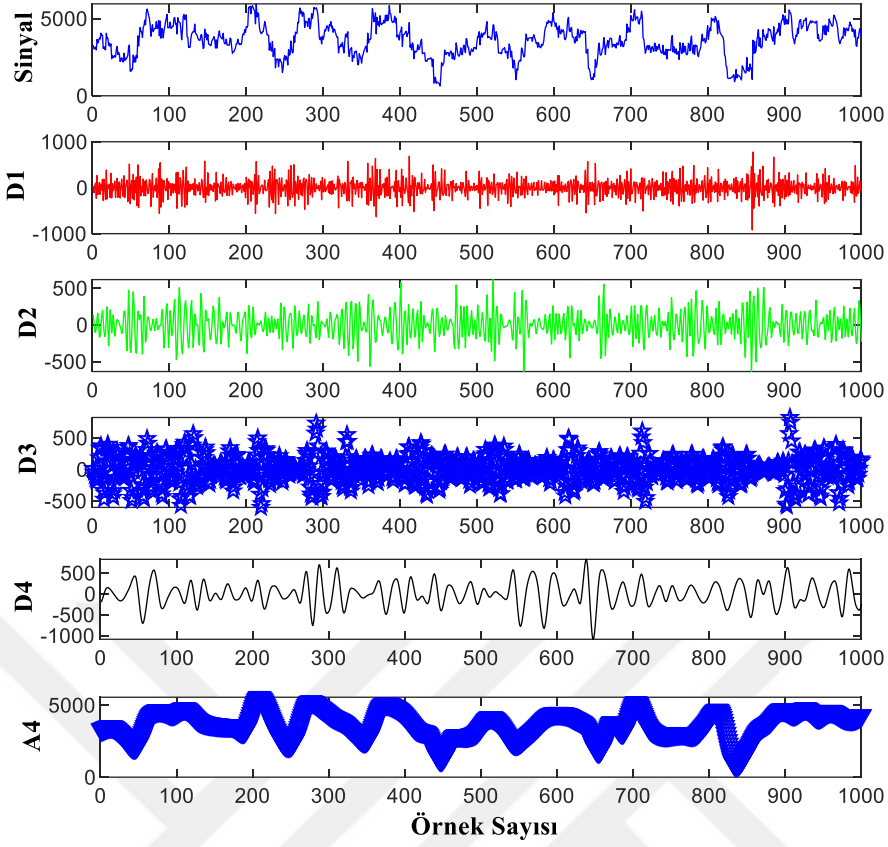
Şekil 6.6 incelendiğinde sağ göz yatay konumu için sağlıklı denek grubundan alınan VOG sinyallerinden elde edilen yaklaşım (A4) ve detay (D1-D4) katsayılarının, EEDR grubuna kıyasla daha sık aralıklarla oluştuğu görülmektedir. Bununla birlikte, GEDR denek grubundan alınan VOG sinyallerinden elde edilen katsayıların diğer denek gruplarından elde edilen katsayılara nazaran daha gürültülü ve bozucu bir etkiye sahip olduğu tespit edilmiştir.



(a)



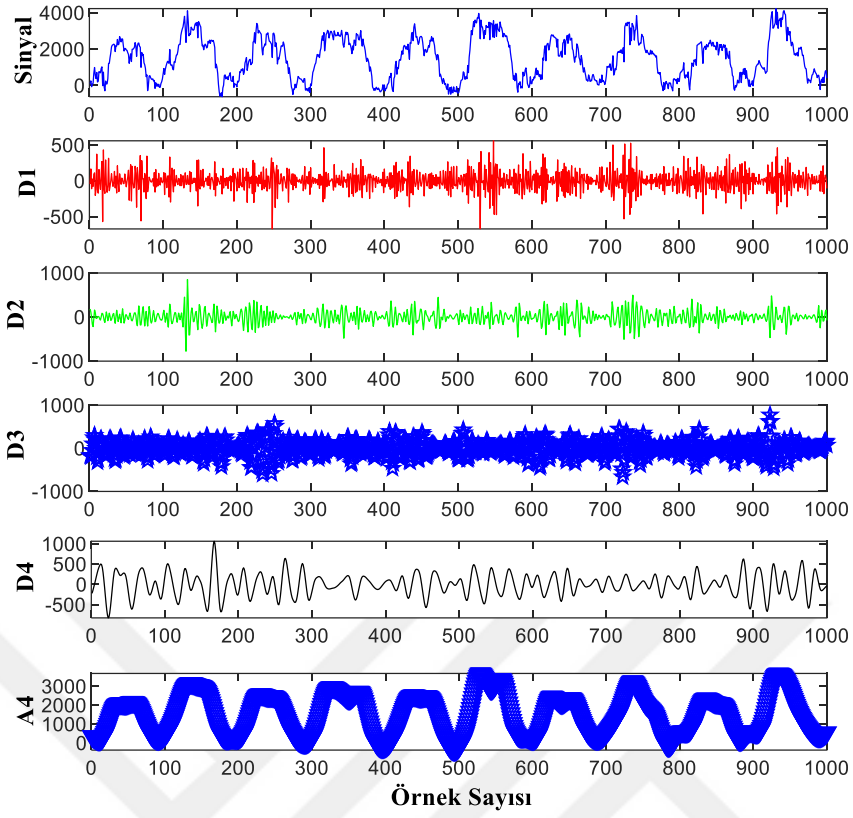
(b)



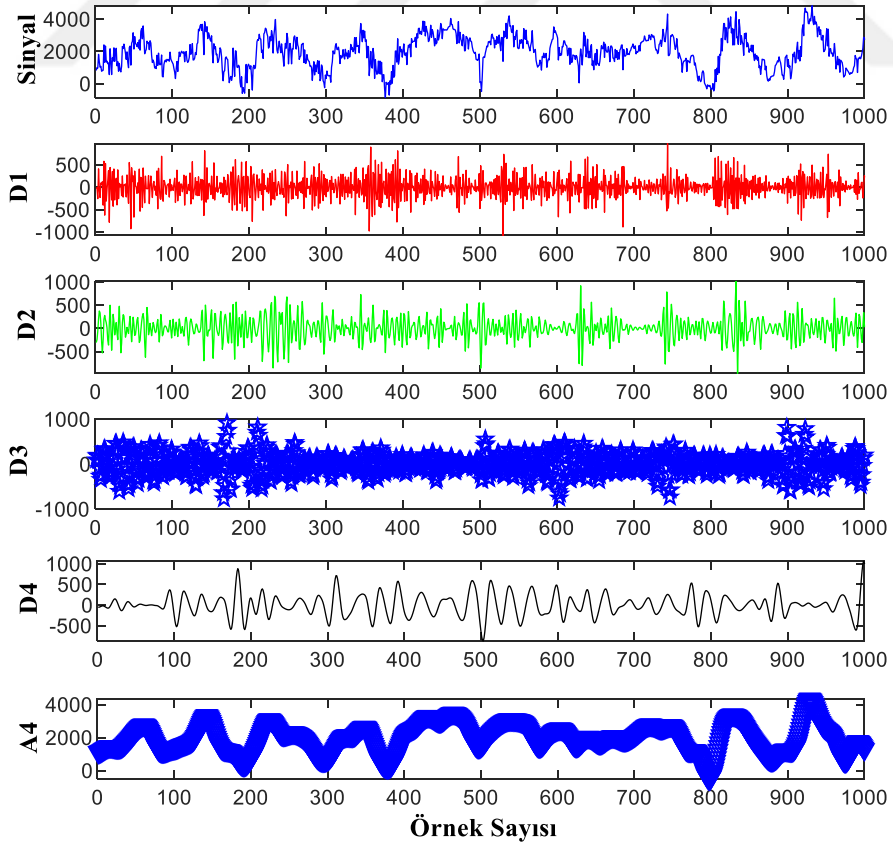
(c)

**Şekil 6.7** Sol göz dikey konum için VOG sinyalleri ve ADD katsayıları a) Sağlıklı denek grubu b) EEDR denek grubu c) GEDR denek grubu.

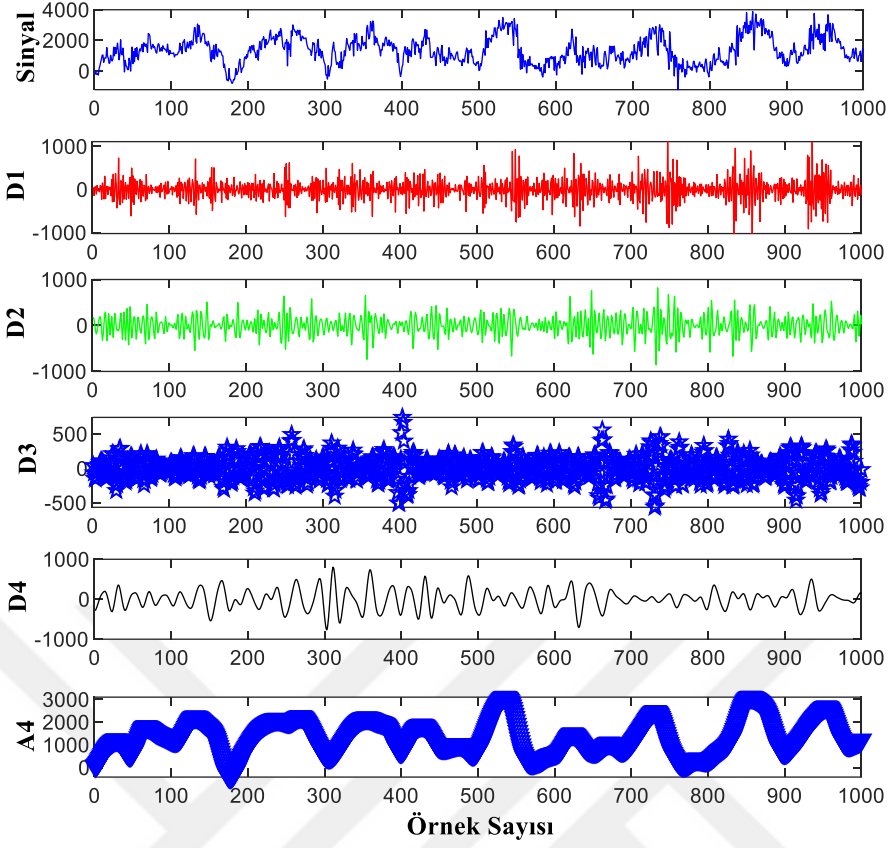
Sol göz dikey konumda (Şekil 6.7); A4 yaklaşım katsayısı, EEDR denek grubunda sağlıklı gruba kıyasla negatif bölgeye kaymıştır. GEDR denek grubu için A4 katsayısı pozitif bölgede bulunmuştur. Bununla birlikte GEDR denek grubundan alınan VOG sinyallerinden elde edilen katsayıların diğer denek gruplarından elde edilen katsayılara nazaran daha gürültülü olduğu ve sinyal karakteristiğinin tamamen değiştiği gözlemlenmiştir.



(a)



(b)



(c)

**Şekil 6.8** Sağ göz dikey konum için VOG sinyalleri ve ADD katsayıları a) Sağlıklı denek grubu b) EEDR denek grubu c) GEDR denek grubu.

Şekil 6.8 incelendiğinde sağ göz dikey konum için sağlıklı denek grubunun VOG sinyallerinden elde edilen ADD katsayılarının, EEDR ve GEDR denek gruplarınınki ile kıyaslandığında, DR hastalık evresine bağlı olarak katsayılardaki gürültü oranının arttığı ve karakteristiğinin bozulmaya başladığı belirlenmiştir.

Şekil 6.5-6.8'de sol/sağ göz yatay/dikey konumlarından ayrı ayrı alınan sağlıklı, EEDR ve GEDR denek gruplarına ait VOG sinyalleri arasındaki farklılıklar ADD yöntemi kullanılarak ortaya konulmuştur. Elde edilen sonuçlar göstermektedir ki; DR hastalığının VOG sinyalleri üzerindeki fizyolojik etkilerinin tespitinde ADD yönteminin kullanılması uygundur.



## 6.2 VIDEO-OKÜLOGRAFİ (VOG) SİNYALLERİNDEN DİYABETİK RETİNOPATİ HASTALIĞININ ÇOK KATMANLI YAPAY SİNİR AĞI İLE TAHMİNİ

Bu kısımda, VOG sinyallerinden DR hastalığının tespitinde çok katmanlı yapay sinir ağının (ÇKYSA) uygulanabilirliği araştırılmıştır. Bu amaç doğrultusunda öncelikle VOG sinyallerinin frekans ve zaman bölgesindeki bileşenlerinin analizi ADD yöntemiyle yapılmıştır. ADD’de ana dalgacık tipi olarak Coiflet4 (coif4) dalgacığı seçilerek 4. seviyede yaklaşım (A4) ve detay (D1-D4) katsayı bileşenleri elde edilmiştir.


Veri seti, yaşları 19-70 arasında değişen 6’sı sağlıklı, 6’sı EEDR ve 6’sı GEDR hastalığına sahip olan 18 gönüllü deneğe ait VOG sinyalleri 200 Hz örnekleme frekansıyla sağ/sol göz ve yatay/dikey konumlarından alınarak oluşturulmuştur. Daha sonra alınan sinyallerden elde edilen bileşenlerin istatistiksel (maksimum, minimum, ortalama, standart sapma ve varyans) analizi yapılarak 4 farklı göz konumuna ait öznitelik vektörleri belirlenmiştir. Çizelge 6.1’de sağlıklı bir denekten alınan VOG sinyalinin sol yatay göz konumu için hesaplanan öznitelik vektörü gösterilmiştir.

**Çizelge 6.1** VOG sinyal verilerinin sol yatay göz konumu için istatistiksel öznitelikleri.

Maksimum	Minimum	Ortalama	Standart Sapma	Varyans
4,64E-07	5,17E-07	6,42E-07	6,79E-07	1,23E-06
0,000213	0,000217	0,000147	0,000124	0,000398
0,000185	0,000165	0,000176	8,63E-05	0,000121
0,000167	0,000158	0,00011	0,000136	0,000215
0,000159	0,000162	0,000151	0,000145	0,000806

Çizelge 6.1’de görüldüğü gibi, her denek 25 farklı özniteliğe sahiptir. Bu nedenle sınıflandırıcı olarak seçilen ÇKYSA modelinin topolojisi 25 giriş nöronlu, 1 ara katmanlı ve 1 çıkış nöronuna sahip olacak şekilde tasarlanmıştır. Farklı nicel aralıklara sahip giriş vektörü, [0,1] aralığında normalize edilerek ağın giriş veri seti elde edilmiştir. Öğrenme algoritması olarak literatürde sıklıkla kullanılan Levenberg-Marquardt geri yayılım algoritması seçilmiştir [128]. Ara katman nöron sayısını bulmak için nöron sayısı 6-20 arasında değiştirilerek 200 farklı deneme yapılarak ÇKYSA topolojisinin eğitimi gerçekleştirilmiştir. Eğitim sürecinde, topolojinin ezberleme süreci engellenmek için hold-out çapraz doğrulama yöntemi kullanılmıştır. Eğitim süreci

sonunda, en düşük ortalama karesel hataya sahip ara katman nöron sayısı belirlenmiştir. Şekil 6.9'dan görüldüğü gibi ÇKYSA modeline ait ara katman nöron sayısı 14 olarak tespit edilmiştir.



Şekil 6.9 Ara katman nöron sayısının ortalama karesel hataya etkisi.

Ara katmandaki nöron sayısı tespit edildikten sonra, her bir göz için yatay/dikey konumlardan elde edilen sinyal öznelik veri seti seçilen ağ topolojisinde belirlenen eğitim/test yüzdeleri oranları ile eğitilip test edilmiştir. Test sonucu, elde edilen tahminlerin istatistiksel hata analizleri yapılmış ve sonuçlar Çizelge 6.2-Çizelge 6.5'te sırasıyla verilmiştir.

Çizelge 6.2 Sağ göz dikey konum için veri seti farklı oranlarda bölündüğündeki hata analizi.

Veri Seti (Eğitim- Test)	Regresyon Katsayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata
% 50 - % 50	0,78671	0,0692	0,1994
% 60 - % 40	0,80268	0,0634	0,1392
% 70 - % 30	0,86956	0,0433	0,1316
% 80 - % 20	0,92040	0,0270	0,0833

Çizelge 6.3 Sol göz dikey konum için veri seti farklı oranlarda bölündüğündeki hata analizi.

Veri Seti (Eğitim-Test)	Regresyon Katsayısı	Ortalama Karesel Hata	Ortalama Mutlak Hata
% 50 - % 50	0,76304	0,0726	0,2036
% 60 - % 40	0,82143	0,0616	0,1706
% 70 - % 30	0,84511	0,0532	0,1231
% 80 - % 20	0,87092	0,0441	0,0892

**Çizelge 6.4** Sağ göz yatay konum için veri seti farklı oranlarda bölündüğündeki hata analizi.

<b>Veri Seti (Eğitim-Test)</b>	<b>Regresyon Katsayısı</b>	<b>Ortalama Karesel Hata</b>	<b>Ortalama Mutlak Hata</b>
<b>% 50 - % 50</b>	0,90001	0,0323	0,1034
<b>% 60 - % 40</b>	0,94682	0,0189	0,0850
<b>% 70 - % 30</b>	0,96367	0,0138	0,0574
<b>% 80 - % 20</b>	0,99168	0,0028	0,0270

**Çizelge 6.5** Sol göz yatay konum için veri seti farklı oranlarda bölündüğündeki hata analizi.

<b>Veri Seti (Eğitim-Test)</b>	<b>Regresyon Katsayısı</b>	<b>Ortalama Karesel Hata</b>	<b>Ortalama Mutlak Hata</b>
<b>% 50 - % 50</b>	0,84455	0,0489	0,1396
<b>% 60 - % 40</b>	0,92256	0,0256	0,1192
<b>% 70 - % 30</b>	0,93448	0,0227	0,1044
<b>% 80 - % 20</b>	0,97026	0,0101	0,0568

Çizelge 6.2-Çizelge 6.5'ten görüldüğü gibi veri setinin bölünmesinde eğitim için ayrılan kısım artırılıp test için ayrılan kısım azaltıldığında regresyon katsayısının arttığı, ortalama karesel hata ile ortalama mutlak hatanın ise azaldığı gözlenmiştir. Çalışmada denenen veri seti kombinasyonları arasında en düşük hata değeri, veri setinin eğitim-test yüzdesinin %80-%20 olarak bölündüğü durumda elde edilmiştir. Son olarak, seçilen topolojinin sınıflandırma başarımını ölçmek için doğruluk analizi karmaşıklık matrisi yöntemi ile yapılmıştır. Bu analizde, farklı veri seti dağılımlarıyla belirlenen ağ topolojisi eğitilip test edilmiş ve sınıflandırma başarımı doğruluk, hassasiyet ve özgüllük parametreleriyle ölçülmüştür. Buna göre elde edilen başarımların sonuçları sağ/sol göz dikey/yatay göz konumları için sırasıyla Çizelge 6.6-Çizelge 6.9'da verilmiştir.

**Çizelge 6.6** Sağ göz dikey konum için veri seti farklı oranlarda bölündüğündeki istatistiksel analiz.

<b>Veri Seti (Eğitim-Test)</b>	<b>Doğruluk</b>	<b>Hassasiyet</b>	<b>Özgüllük</b>
<b>% 50 - % 50</b>	0,7778	1	0,6667
<b>% 60 - % 40</b>	0,8333	0,8333	0,9167
<b>% 70 - % 30</b>	0,8889	0,8333	0,9167
<b>% 80 - % 20</b>	0,9444	1	0,9167

**Çizelge 6.7** Sol göz dikey konum için veri seti farklı oranlarda bölündüğündeki istatistiksel analiz.

Veri Seti (Eğitim-Test)	Doğruluk	Hassasiyet	Özgüllük
% 50 - % 50	0,8333	1	0,75
% 60 - % 40	0,8889	1	0,8333
% 70 - % 30	0,8889	1	0,9167
% 80 - % 20	0,9444	1	1


**Çizelge 6.8** Sağ göz yatay konum için veri seti farklı oranlarda bölündüğündeki istatistiksel analiz.

Veri Seti (Eğitim-Test)	Doğruluk	Hassasiyet	Özgüllük
% 50 - % 50	0,8889	1	0,8333
% 60 - % 40	0,8889	0,8333	0,9167
% 70 - % 30	0,8889	1	0,8333
% 80 - % 20	1	1	1


**Çizelge 6.9** Sol göz yatay konum için veri seti farklı oranlarda bölündüğündeki istatistiksel analiz.

Veri Seti (Eğitim-Test)	Doğruluk	Hassasiyet	Özgüllük
% 50 - % 50	0,7778	0,8333	0,75
% 60 - % 40	0,8889	0,8333	0,9167
% 70 - % 30	0,8889	0,8333	0,9167
% 80 - % 20	0,9444	0,8333	1


Karmaşıklık matrisinde doğru pozitif (DP) ve doğru negatif (DN) değerleri toplamı seçilen ağın doğruluk tahminini vermektedir. Bu nedenle çalışmada en yüksek sınıflandırma performansının elde edildiği eğitim-test yüzdesinin %80-%20 olarak bölündüğü veri seti için karmaşıklık matrisindeki DP ve DN değerleri, farklı göz konumları ve hastalık evreleri için hesaplanmış ve elde edilen sonuçlar gerçek tanı bulgularıyla karşılaştırmalı olarak Şekil 6.10'da verilmiştir.




(a)



(b)



(c)



(d)

**Şekil 6.10** Veri seti %80-%20 için elde edilen karmaşıklık matrisi sonuçları a) Sağ göz yatay konum b) Sol göz yatay konum c) Sağ göz dikey konum d) Sol göz dikey konum.

Şekil 6.10a'da sağ göz yatay konum tahmin başarımı incelendiğinde, ÇKYSA topolojisinin sağlıklı, EEDR ve GEDR denek gruplarını %100 doğrulukla sınıflandırdığı gözlemlenmiştir. Şekil 6.10b'de sol göz yatay konum için ise %94,44 doğrulukla sınıflandırma başarımı elde edildiği görülmektedir. Dikey konumlara bakıldığında Şekil 6.10c ve Şekil 6.10d'den görüldüğü üzere her iki göz içinde %94,44'lük sınıflandırma doğruluğu elde edilmiştir. Sol göz dikey konumda seçicilik değeri, sağ göz dikey konuma göre daha yüksektir.

Sonuç olarak, seçilen ÇKYSA topolojisinin 4 farklı göz konumundan elde edilen sinyal özniteliklerini doğru bir şekilde sınıflandırdığı görülmüştür. Bu sonuç ışığında, ÇKYSA modelinin DR hastalığının her iki evresinin de sınıflandırılmasında kullanılabilirliği gösterilmiştir.

### 6.3 C4.5 KARAR AĞACI TEMELLİ ÖZİNTELİK SEÇİMİ İLE VIDEO-OKÜLOGRAFİ (VOG) SİNYALLERİNDEN DİYABETİK RETİNOPATİ HASTALIĞININ ÇOK KATMANLI YAPAY SİNİR AĞI İLE SINIFLANDIRILMASI

Bu kısımda; DR hastalığının sınıflandırılmasında öznitelik seçiminin ADD ve C4.5 karar ağacı algoritmalarına dayalı olarak yapıldığı iki farklı ÇKYSA modelinin sınıflandırma performansı araştırılmıştır. Veri seti olarak; yaşları 19-70 arasında değişen 7'si sağlıklı, 9'u EEDR ve 8'i GEDR hastalığına sahip olan 24 gönüllü denekten sinyaller alınmıştır.

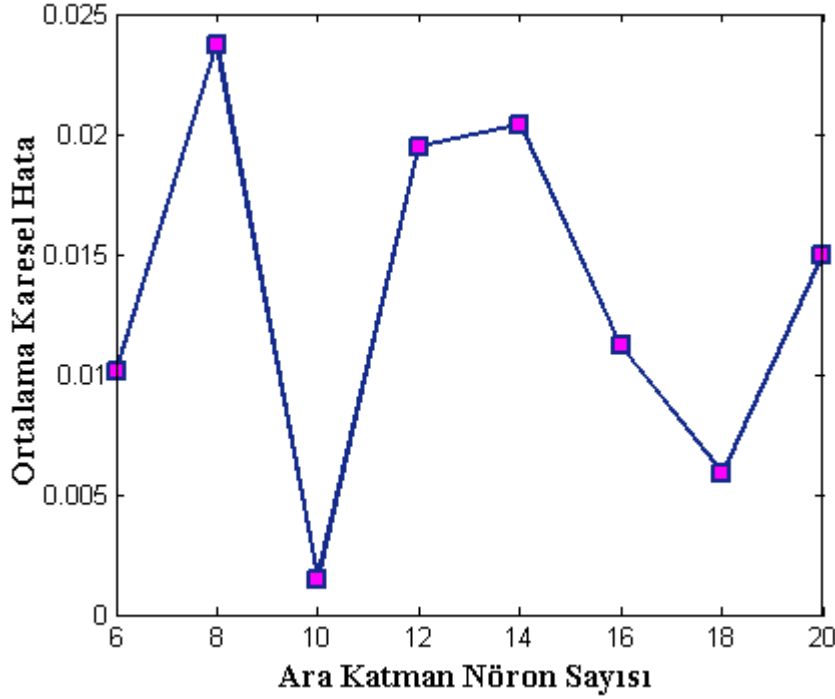
Çalışmada ilk olarak farklı denek gruplarından alınan VOG sinyallerinin öznitelikleri ADD yöntemiyle çıkarılmıştır. ADD'de ana dalgacık tipi olarak Coiflet4 (4. Seviye) seçilmiştir. ADD sonucu elde edilen 25 istatistiksel öznitelik vektörlerinin boyutları istatistiksel yöntemlerle (katsayıların maksimumu, minimumu, ortalaması, standart sapması ve varyansı) azaltılmıştır. Çizelge 6.10'da sağlıklı bir denekten alınan VOG sinyalinin sol yatay göz konumu için ADD yöntemine göre çıkarılan öznitelik vektörü verilmiştir.

**Çizelge 6.10** VOG sinyal verilerinin sol yatay göz konumu için istatistiksel öznitelikleri.

<b>Maksimum (<math>\mu</math>V)</b>	<b>Minimum (<math>\mu</math>V)</b>	<b>Ortalama (<math>\mu</math>V)</b>	<b>Standart Sapma (<math>\mu</math>V)</b>	<b>Varyans (<math>\mu</math>V)</b>
2311,5786	2516,63723	3614,94357	3245,5144	8920,56845
2285,4076	2516,06465	2600,89071	3232,5731	4522,94737
9657,5316	9116,91229	5635,14108	3974,5500	2099,36929
1786,7207	2555,19428	3449,40526	3651,7915	7741,84778
9555,4005	8825,49503	6234,75530	6294,4114	2629,77110

Elde edilen bu 25 farklı öznitelik 25 giriş nöronuna, 1 ara katmana ve 1 çıkış nöronuna sahip bir ÇKYSA ağ modeline uygulanarak, ağın performansı araştırılmıştır. Öğrenme algoritması olarak Levenberg-Marquardt geri yayılım algoritmasının kullanıldığı ağın giriş vektörü [0,1] aralığında normalize edilerek, ağ 200 iterasyon boyunca eğitilmiştir. Eğitim sürecinde hold-out çapraz doğrulama yöntemi kullanılmıştır. Şekil 6.11'de ara katmandaki nöronların sayısını

bulmak için ortalama karesel hata performansı üzerinde ara katman nöron sayısının deęişiminin etkisi araştırılmıştır. Şekilden de görüldüğü gibi ara katmandaki nöron sayısı 10 olduğunda, ortalama karesel hata minimum deęerdedir.

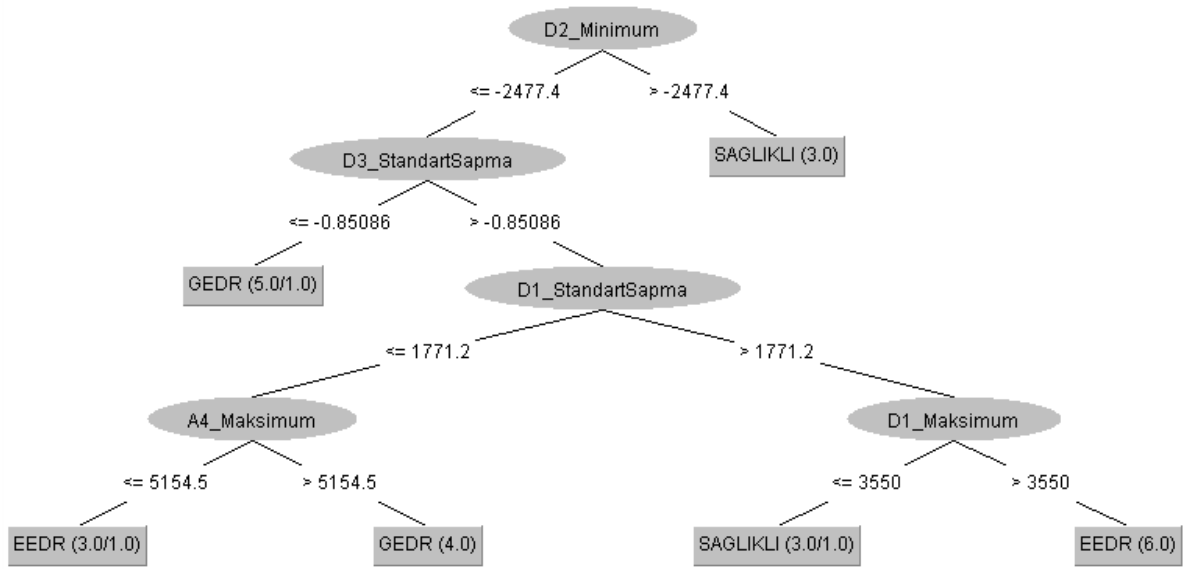


Şekil 6.11 Ara katman nöron sayısının ortalama karesel hataya etkisi.

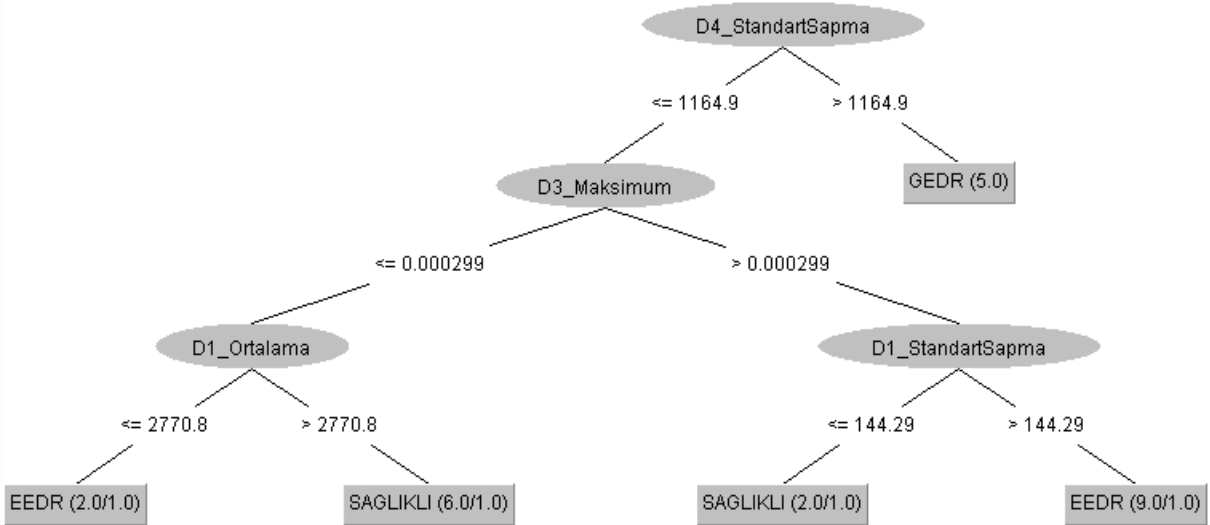
Bunun yanı sıra model performansının ortaya konması için regresyon katsayısı, ortalama karesel hata, ortalama mutlak hata, doğruluk, hassasiyet, duyarlılık ve özgüllük deęerleri veri setinin %80'inin eğitim ve %20'sinin test olarak bölünmesiyle hesaplanmıştır. Elde edilen sonuçlar Çizelge 6.12'de verilmiştir.

Çalışmada son olarak; Waikato Üniversitesi'nde Java tabanlı olarak geliştirilen Weka veri madenciliği yazılımında, ADD yöntemi ile elde edilen istatistiksel özniteliklerin giriş olduğu C4.5 karar ağacı algoritması (J48) kullanılarak öznitelik seçimi gerçekleştirilmiştir [129]. Buna göre, sağ/sol göz dikey/yatay konumlar için oluşturulan C4.5 karar ağaçları sırasıyla Şekil 6.12, Şekil 6.13, Şekil 6.14 ve Şekil 6.15'te verilmiştir.

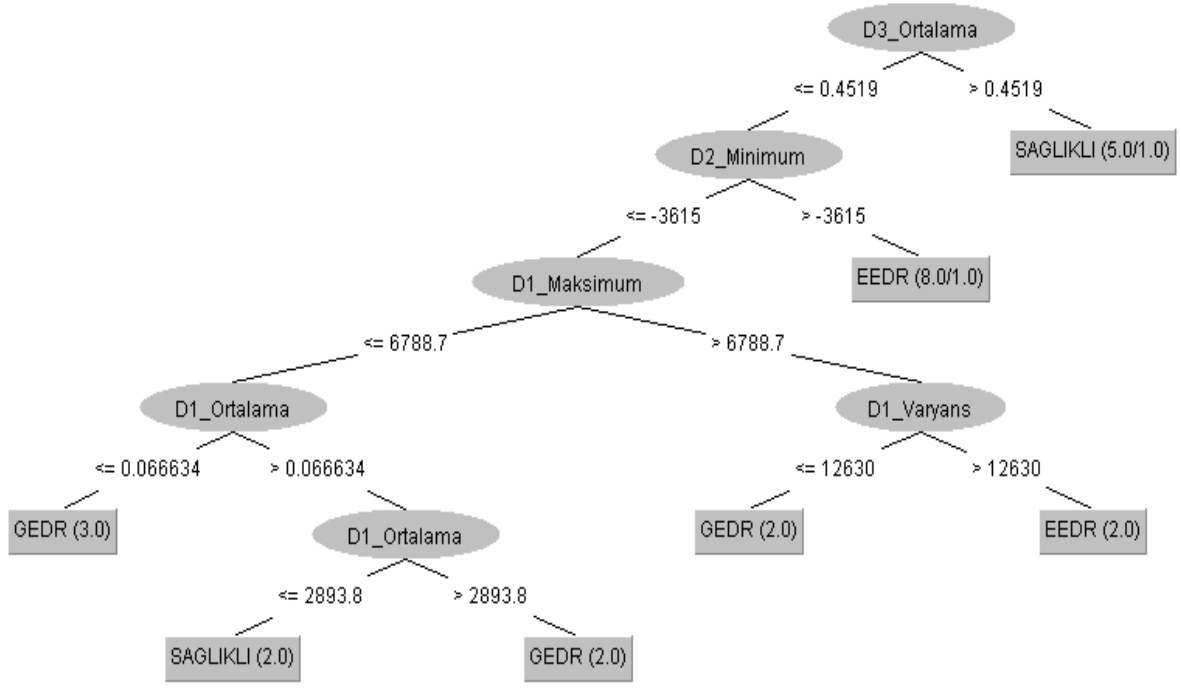




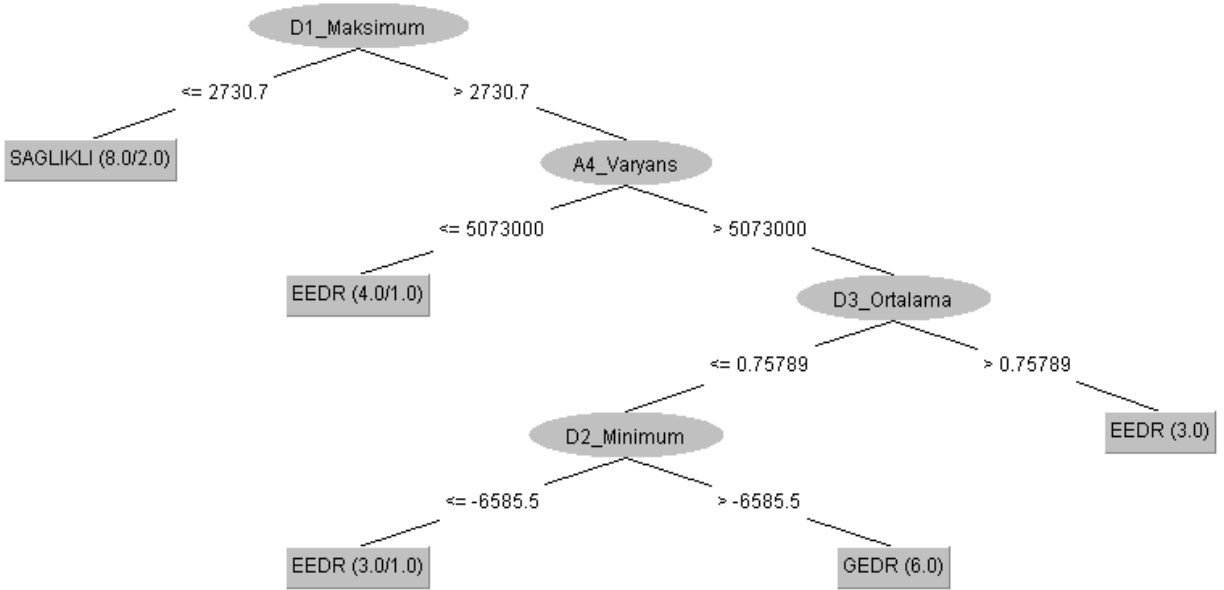
Şekil 6.12 Sağ göz dikey konum için oluşturulan C4.5 karar ağacı.



Şekil 6.13 Sol göz dikey konum için oluşturulan C4.5 karar ağacı.



Şekil 6.14 Sağ göz yatay konum için oluşturulan C4.5 karar ağacı.



Şekil 6.15 Sol göz yatay konum için oluşturulan C4.5 karar ağacı.

**Çizelge 6.11** C4.5 karar ağacı ile öznitelik seçimi.

<b>Göz Konumu</b>	<b>C4.5 Karar Ağacı Öznitelik Seçimi</b>
<b>Sağ Göz Dikey</b>	D1-Maksimum, D1-Standart Sapma, D2-Minimum, D3-Standart Sapma, A4-Maksimum
<b>Sol Göz Dikey</b>	D1-Ortalama, D1-Standart Sapma, D3-Maksimum, D4-Standart Sapma
<b>Sağ Göz Yatay</b>	D1-Maksimum, D1-Ortalama, D1-Varyans, D2-Minimum, D3-Ortalama
<b>Sol Göz Yatay</b>	D1-Maksimum, D2-Minimum, D3-Ortalama, A4-Varyans

C4.5 karar ağacı ile göz konumlarına göre seçilen öznitelikler Çizelge 6.11’de belirtilmiştir. Daha sonra seçilen bu özniteliklerin (sağ göz için 5 ve sol göz için 4) giriş nöronu olduğu, 1 ara katmana ve 1 çıkışa sahip bir ÇKYSA modeli tasarlanmıştır. Veri setinin %80 eğitim ve %20 test olarak bölünerek, tasarlanan modelin performansı regresyon katsayısı, ortalama karesel hata, ortalama mutlak hata, doğruluk, hassasiyet, duyarlılık ve özgüllük değerleri bulunarak hesaplanmıştır. Elde edilen sonuçlar Çizelge 6.12’de ADD & ÇKYSA modeli ile karşılaştırmalı olarak sunulmuştur.

**Çizelge 6.12** ADD & ÇKYSA ve C4.5 & ÇKYSA modellerinin istatistiksel analizleri.

<b>Model</b>	<b>Göz Konumu</b>	<b>Doğruluk (%)</b>	<b>Hassasiyet (%)</b>	<b>Duyarlılık (%)</b>	<b>Özgüllük (%)</b>
<b>ADD &amp; ÇKYSA</b>	<b>Sağ Dikey</b>	91,67	88,89	88,89	93,33
	<b>Sol Dikey</b>	95,83	100	90	93,33
	<b>Sağ Yatay</b>	91,67	77,78	100	100
	<b>Sol Yatay</b>	95,83	100	90	93,33
<b>C4.5 &amp; ÇKYSA</b>	<b>Sağ Dikey</b>	95,83	100	90	93,33
	<b>Sol Dikey</b>	95,83	100	90	93,33
	<b>Sağ Yatay</b>	95,83	88,89	100	100
	<b>Sol Yatay</b>	100	100	100	100

Çizelge 6.12’den görüldüğü gibi 4 farklı göz konumu için C4.5 & ÇKYSA modeli ortalama %96,87 doğrulukla sınıflandırma yaparken, ADD & ÇKYSA modeli ise ortalama %93,75 doğrulukla sınıflandırma yapmaktadır. Bu durum C4.5 & ÇKYSA modelinin ADD & ÇKYSA modeline göre daha yüksek sınıflandırma doğruluğuna sahip olduğunu göstermektedir. Bunun

yanı sıra, C4.5 & ÇKYSA modeli ortalama %97,22 hassasiyet, %95 duyarlılık ve %96,66 özgüllük değerleri ile güçlü bir karaktere sahip olduğu görülmüştür.

Çizelge 6.13 ve Çizelge 6.14'te sırasıyla test aşamasında kullanılan modellerin (ADD ve C4.5 karar ağacı) hata analizi sonuçları verilmiştir. Elde edilen sonuçlar göstermektedir ki; C4.5 & ÇKYSA modelinin, ADD & ÇKYSA modelinden daha düşük hata performansına ve daha yüksek regresyon katsayısına sahiptir.


**Çizelge 6.13** ADD & ÇKYSA modeli hata analizi.

<b>ADD &amp; ÇKYSA Modeli</b>	<b>Regresyon Katsayısı</b>	<b>Ortalama Karesel Hata</b>	<b>Ortalama Mutlak Hata</b>
<b>Sağ Göz Dikey</b>	0,93441	0,0222	0,0883
<b>Sol Göz Dikey</b>	0,94234	0,0178	0,0409
<b>Sağ Göz Yatay</b>	0,93640	0,0200	0,0879
<b>Sol Göz Yatay</b>	0,96957	0,0097	0,0491


**Çizelge 6.14** C4.5 & ÇKYSA modeli hata analizi.

<b>C4.5 &amp; ÇKYSA Modeli</b>	<b>Regresyon Katsayısı</b>	<b>Ortalama Karesel Hata</b>	<b>Ortalama Mutlak Hata</b>
<b>Sağ Göz Dikey</b>	0,93859	0,0210	0,0817
<b>Sol Göz Dikey</b>	0,97627	0,0083	0,0401
<b>Sağ Göz Yatay</b>	0,95151	0,0159	0,0678
<b>Sol Göz Yatay</b>	0,99534	0,0015	0,0156


Şekil 6.16'da farklı göz konumlarına ait gerçek tanı, ADD & ÇKYSA ve C4.5 & ÇKYSA tahminlerine göre hesaplanan karmaşıklık matrisleri 2 farklı hastalık evresi için kıyaslamalı olarak verilmiştir.




(a)



(b)



(c)



(d)

**Şekil 6.16** Veri seti %80-%20 için elde edilen karmaşıklık matrisi sonuçları a) Sağ göz dikey konum b) Sol göz dikey konum c) Sağ göz yatay konum d) Sol göz yatay konum.

Şekil 6.16a'da sağ göz dikey konum tahmin başarımı incelendiğinde; C4.5 karar ağacı yöntemi sonucunda seçilen öznitelikleri içeren ÇKYSA topolojisinin sağlıklı, EEDR ve GEDR denek gruplarını, ADD yönteminden elde edilen öznitelikleri kullanan ÇKYSA topolojisine göre daha yüksek ve %95,83 doğrulukla sınıflandırdığı gözlemlenmiştir. Şekil 6.16b'de tasarlanan her iki ÇKYSA topolojisi için sol göz dikey konumun tahmin başarımı eşit oranda (%95,83 doğruluk)


bulunmuştur. Şekil 6.16c'de ise sağ göz yatay konum için C4.5 karar ağacı & ÇKYSA modelinin (%95,83 doğruluk), ADD & ÇKYSA modeline nazaran daha yüksek sınıflandırma performansı (%91,67 doğruluk) sergilediği tespit edilmiştir. Şekil 6.16d'de sol göz yatay konum için C4.5 & ÇKYSA topolojisi ADD & ÇKYSA topolojisine göre daha yüksek sınıflandırma performansına sahip olduğu görülmüştür.

Sonuç olarak, C4.5 & ÇKYSA modelinin DR hastalığının evrelerinin sınıflandırılmasında ADD & ÇKYSA modeline göre daha yüksek başarımlar sergilediği ortaya koyulmuştur.

#### **6.4 VIDEO-OKÜLOGRAFİ (VOG) SİNYALLERİNDEN DİYABETİK RETİNOPATİ HASTALIĞININ TESPİTİNDE ÇOK KATMANLI YAPAY SİNİR AĞI İLE RADYAL TABANLI FONKSİYON AĞININ KARŞILAŞTIRILMASI**

Bu kısımda, DR hastalığının sınıflandırılmasında ÇKYSA ve radyal tabanlı fonksiyon ağı (RTFA) topolojilerinin sınıflandırma performansları irdelenmiştir. Veri seti olarak yaşları 19-70 arasında değişen 7'si sağlıklı, 7'si EEDR ve 7'si GEDR hastalığına sahip olan 21 gönüllü denekten VOG sinyalleri alınmıştır. Alınan sinyallerden Coiflet4 (4. Seviye) ana dalgacığı kullanılarak ADD yöntemi ile öznitelik çıkarımı yapılmıştır. Daha sonra istatistiksel yöntemlerle (katsayıların maksimumu, minimumu, ortalaması, standart sapması ve varyansı) elde edilen 25 istatistiksel öznitelik vektörlerinin boyutları azaltılmıştır.

Boyutları azaltılan 25 farklı öznitelik; 25 giriş nöronlu, 1 ara katmanlı ve 1 çıkış nöronlu 2 farklı YSA modeli (ÇKYSA ve RTFA) tasarımında kullanılmıştır. Modellerde, veriler [0,1] aralığında normalize edilerek giriş olarak kullanılmıştır. Normalize edilen veri seti ile ağ 200 iterasyon boyunca eğitilmiştir. Eğitim sürecinde hold-out çapraz doğrulama yöntemi kullanılmıştır. Ara katman nöron sayısını bulmak için, ara katman deneyi yapılmıştır. Bu deneyde veri setinin %80'lik bir kısmının eğitim ve geri kalan %20'lik kısmının ise test için kullanıldığı durumda ara katman nöron sayısındaki değişimin ortalama karesel hataya etkisine bakılmıştır (Şekil 6.17). Bu bağlamda, ortalama karesel hata en düşük 18 nöronlu ara katmanda elde edilmiştir.



Şekil 6.17 Ara katman nöron sayısının ortalama karesel hataya etkisi.

Sınıflandırma için kullanılması gereken ara katman nöron sayısı belirlendikten sonra Çizelge 6.15 ve Çizelge 6.16’da sırasıyla ÇKYSA ve RTFA modellerinin hata analizleri kıyaslamalı olarak verilmiştir. Her bir göz konumu için RTFA modelinde, ÇKYSA modeline göre daha düşük ortalama karesel hata elde edilmiştir.

Çizelge 6.15 ÇKYSA modeli hata analizi.

ÇKYSA Modeli	Regresyon Katsayısı (R)	R <sup>2</sup>	Ortalama Kareysel Hata	Ortalama Mutlak Hata
Sol Göz Yatay	0,94531	0,8828	0,0195	0,1072
Sağ Göz Yatay	0,93782	0,8766	0,0206	0,0956
Sol Göz Dikey	0,93003	0,8535	0,0244	0,0863
Sağ Göz Dikey	0,94954	0,8932	0,0178	0,0796

Çizelge 6.16 RTFA modeli hata analizi.

RTFA Modeli	Regresyon Katsayısı (R)	R <sup>2</sup>	Ortalama Kareysel Hata	Ortalama Mutlak Hata
Sol Göz Yatay	1	1	0	0
Sağ Göz Yatay	1	1	0	0
Sol Göz Dikey	1	1	0	0
Sağ Göz Dikey	1	1	0	0




Çizelge 6.17’de 2 farklı sınıflandırıcı kullanarak sınıflandırma başarımının nasıl değiştiği araştırılmıştır. Her bir göz konumu için RTFA modelinin ÇKYSA modeline kıyasla daha yüksek sınıflandırma başarımı gösterdiği tespit edilmiştir.


Çizelge 6.17 ÇKYSA ve RTFA modellerinin istatistiksel analizleri.

Model	Göz Konumu	Doğruluk	Hassasiyet	Duyarlılık	Özgüllük
ÇKYSA	Sol Göz Yatay	0,9524	0,8750	1	0,9286
	Sağ Göz Yatay	0,9524	1	0,8571	1
	Sol Göz Dikey	0,9524	0,8750	1	0,9286
	Sağ Göz Dikey	0,9048	0,7778	1	0,8571
RTFA	Sol Göz Yatay	1	1	1	1
	Sağ Göz Yatay	1	1	1	1
	Sol Göz Dikey	1	1	1	1
	Sağ Göz Dikey	1	1	1	1


Şekil 6.18’de karmaşıklık matrisi yöntemi kullanılarak en iyi veri seti bölütü (eğitim %80, test %20) ile eğitilen ÇKYSA ve RTFA modellerinin sınıflandırma başarımı ile gerçek tanı bulguları kıyaslamalı olarak verilmiştir.




(a)



(b)



(c)



(d)

**Şekil 6.18** Veri seti %80-%20 için elde edilen karmaşıklık matrisi sonuçları a) Sağ göz yatay konum b) Sol göz yatay konum c) Sağ göz dikey konum d) Sol göz dikey konum.

Şekil 6.18'den görüldüğü üzere her 4 farklı göz konumu için de RTFA modeli, ÇKYSA modeline göre daha yüksek ve %100 doğruluk ile sağlıklı, EEDR ve GEDR denek gruplarını sınıflandırmıştır. Şekil 6.18a, Şekil 6.18b ve Şekil 6.18d incelendiğinde; sol yatay, sağ yatay ve sol dikey göz konumlarında ÇKYSA modeli ile %95,24 sınıflandırma doğruluğu elde edilmiştir. Şekil 6.18c'de ise sağ dikey göz konumu için ise ÇKYSA modelinin sınıflandırma doğruluğu %90,48 bulunmuştur.

Sonuç olarak, DR hastalığının erken ve geç evrelerinin tespit edilmesi aşamasında RTFA modelinin ÇKYSA modeline göre daha yüksek sınıflandırma başarısına sahip olduğu gözlemlenmiştir.


## 6.5 VIDEO-OKÜLOGRAFİ (VOG) SİNYALLERİNDEN DİYABETİK RETİNOPATİ HASTALIĞININ AYRIK DALGACIK DÖNÜŞÜMÜ VE PARÇACIK SÜRÜ OPTİMİZASYONU TEMELLİ ÇOK KATMANLI YAPAY SİNİR AĞI İLE TESPİTİ

Geleneksel ÇKYSA topolojilerinde öğrenme performansını artırmak adına eğitim sürecine optimizasyon algoritmaları dahil edilmektedir. Bu doğrultuda çalışmada, DR hastalığı tespit edilirken sınıflandırıcı olarak literatürden farklı bir hibrit ÇKYSA model tasarlanmıştır. Hibrit


modelde öğrenme süreci parçacık sürü optimizasyonu (PSO) algoritması kullanılarak gerçekleştirilmiş, böylece daha kısa sürede etkin ağırlık değerleri elde edilip ağı eğitimi tamamlanarak sınıflandırıcının performans analizi yapılmıştır. Tasarlanan hibrit modele ait PSO algoritmasının sözde kodu aşağıda belirtilmiştir.

- 1. adım:** Rasgele üretilen başlangıç pozisyonları ve hızları ile başlangıç sürüsü (yani ağırlık vektörü) oluşturulur.
- 2. adım:** Sürü içerisindeki tüm parçacıkların uygunluk değerleri hesaplanır.
- 3. adım:** Her bir parçacık için mevcut jenerasyondan yerel kişisel en iyi ( $p_{eni}$ ) bulunur. Sürü içerisinde en iyilerin sayısı parçacık sayısı kadardır.
- 4. adım:** Mevcut jenerasyondaki yerel en iyiler içerisinde küresel en iyi ( $g_{eni}$ ) seçilir.
- 5. adım:** Pozisyon ve hız vektörleri güncellenir.
- 6. adım:** Durdurma kriteri olarak elde edilmesi beklenen  $g_{eni}$  değeri elde edilene kadar yukarıdaki adımlar tekrar edilir.
- 7. adım:** Son olarak elde edilen parçacık sürüsü (ağırlık vektörü) ağ topolojisine aktarılır.


Veri seti olarak yaşları 19-70 arasında değişen 17'si sağlıklı, 16'sı EEDR ve 17'si GEDR hastalığına sahip olan 50 gönüllü denekten VOG sinyalleri kullanılmıştır. Her bir denek grubu için ADD yöntemi kullanılarak öznitelik çıkarımı yapılmıştır. ADD'de VOG sinyallerinin değer aralığından dolayı Coiflet4 (coif4) ana dalgacığı tercih edilerek, yaklaşım (A4) ve detay (D1-D4) katsayıları elde edilmiştir. Buna göre sağlıklı, EEDR ve GEDR denek gruplarının 4 farklı göz konumundan alınan VOG sinyallerinden elde edilen A4 ve D1-D4 katsayıları Şekil 6.19, Şekil 6.20 ve Şekil 6.21'de gösterilmiştir.




(a)



(b)

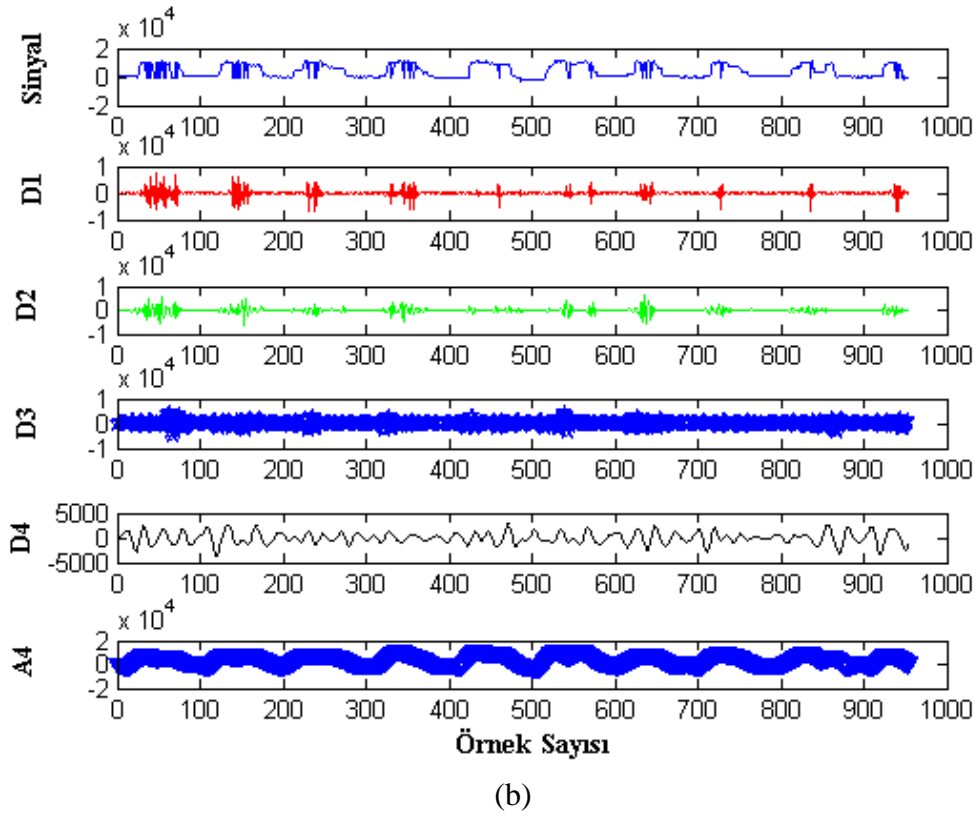
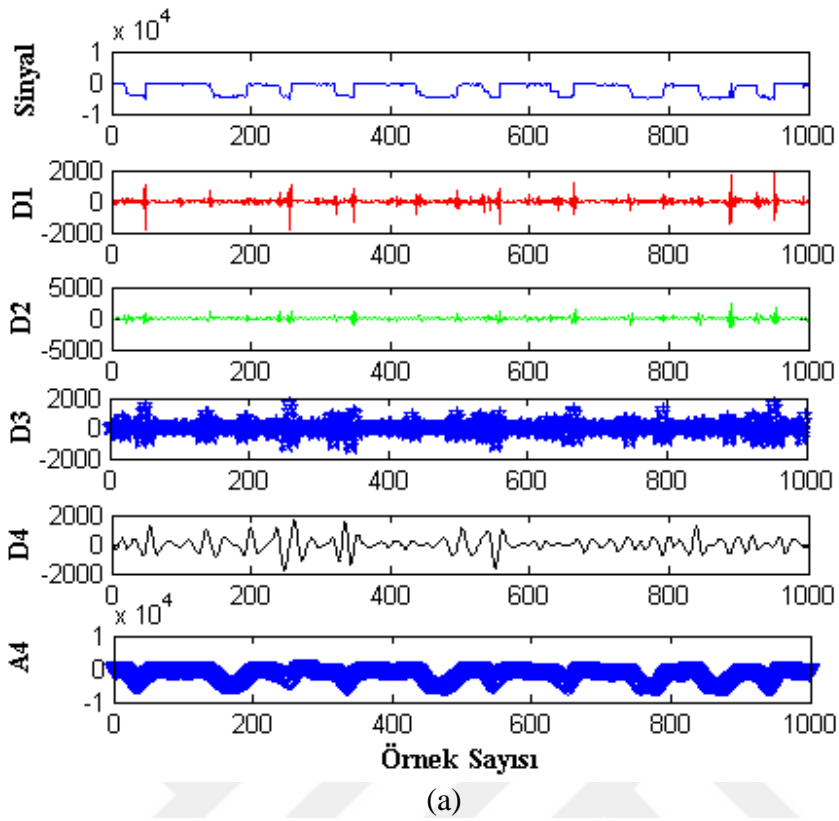



(c)




(d)

Şekil 6.19 Sağlıklı denek grubu için VOG sinyali ve ADD katsayıları a) Sol göz yatay konum b) Sol göz dikey konum c) Sağ göz yatay konum d) Sağ göz dikey konum.





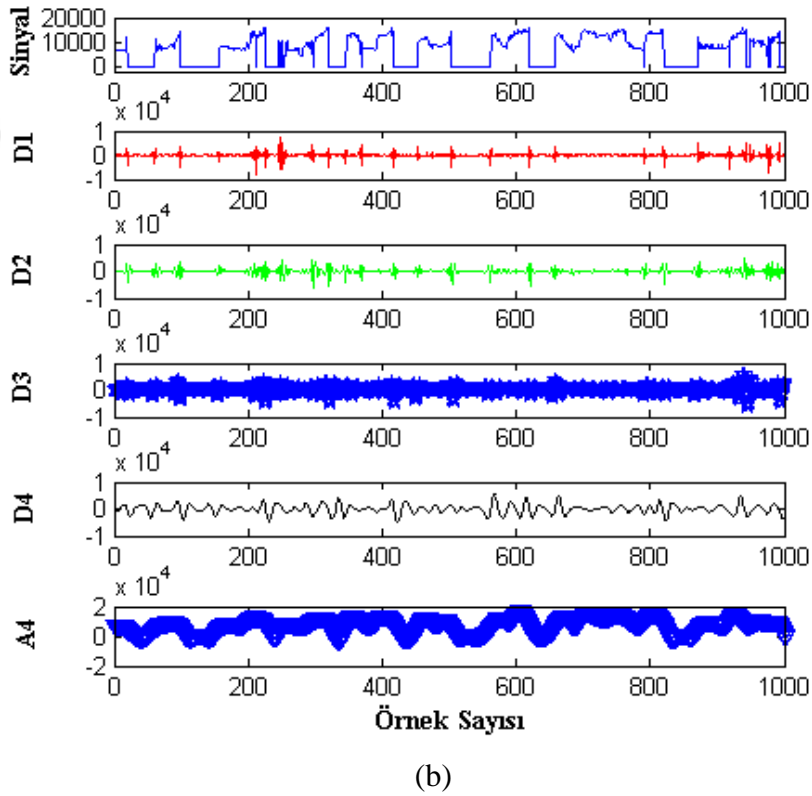
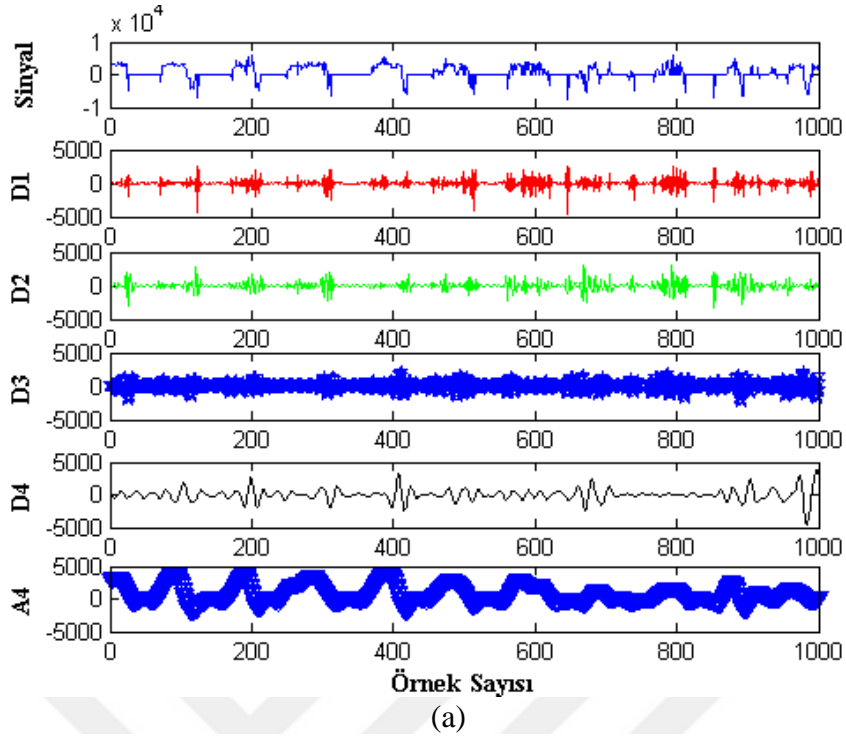
(c)




(d)

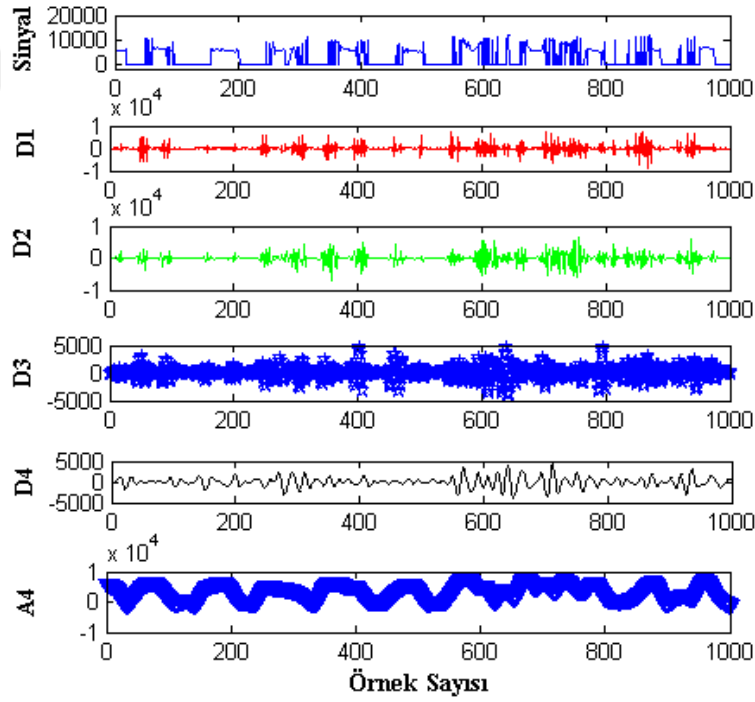
Şekil 6.20 EEDR denek grubu için VOG sinyali ve ADD katsayıları a) Sol göz yatay konum b) Sol göz dikey konum c) Sağ göz yatay konum d) Sağ göz dikey konum.







(c)



(d)

Şekil 6.21 GEDR denek grubu için VOG sinyali ve ADD katsayıları a) Sol göz yatay konum b) Sol göz dikey konum c) Sağ göz yatay konum d) Sağ göz dikey konum.

Şekil 6.19, Şekil 6.20 ve Şekil 6.21 incelendiğinde; sol yatay göz konumu için sağlıklı denek grubunda VOG sinyalinin genliğinin ve elde edilen ADD katsayılarının, EEDR denek grubuna göre daha yüksek olduğu görülmektedir. Bu etki sol dikey, sağ yatay ve sağ dikey göz konumları içinde benzer şekilde gözlemlenmiştir. GEDR denek gruplarından her bir göz konumu için alınan VOG sinyallerinden elde edilen ADD katsayılarının diğer denek gruplarına kıyasla daha gürültülü olduğu gözlemlenmiştir. Ayrıca, GEDR' nin VOG sinyalleri üzerindeki fizyolojik etkisinin EEDR ile benzer olduğu gözlemlenmiştir. Her bir göz konumu için GEDR denek grubundaki VOG sinyallerinin genliği sağlıklı gruba göre artmaktadır. Bununla birlikte GEDR deneklerinden alınan sinyallerde gürültünün EEDR'ye göre daha etkili olduğu gözlemlenmiştir. Buradan hareketle, DR hastalık evresinin ilerlemesinin fizyolojik olarak VOG sinyaline bozucu bir yönde etkisi olduğu tespit edilmiştir.

Sinyallerin zaman ve frekans bölgelerinde genlik değişimleri incelendikten sonra, elde edilen ADD katsayı vektörlerinin boyutlarını küçültmek amacıyla sinyallerin maksimum, minimum, karekök ortalaması ve standart sapma istatistiksel öznitelikleri göre bir veri seti elde edilmiştir. Elde edilen 4 farklı istatistiksel öznitelik ve ADD katsayılarına (A4, D1-D4) göre 20 girişli bir giriş vektörü tanımlanmıştır. Buna göre girişinde 20 nöron, çıkışında 1 nörona olan 1 ara katmanlı ÇKYSA modeli tasarlanmıştır. Modelde ara katmandaki nöron sayısı önceki kısımlarda tanımlanan ara katman nöron sayısı deneyine göre belirlenmiştir. Buna göre en düşük ortalama karesel hata değeri ara katmanda 16 nöron olması durumunda elde edilmiştir. Model tasarlandıktan sonra geliştirilen PSO optimizasyon algoritması ile elde edilen optimum ağ topolojisi eğitilmiştir. Optimum ağ topolojisinde sahip ADD-ÇKYSA PSO modelinin performansı, 4 farklı göz konumundan (sol yatay, sol dikey, sağ yatay ve sağ dikey) alınan sinyallerin öznitelik vektörleriyle eğitilip test edilmiştir. Test sürecinde karmaşıklık matrisi ile doğruluk analizi gerçekleştirilmiştir. Elde edilen analiz sonuçları Çizelge 6.18'de verilmiştir.


**Çizelge 6.18** ADD - ÇKYSA PSO modelinin istatistiksel analizi.

<b>Göz Konumu</b>	<b>Doğruluk (%)</b>	<b>Duyarlılık (%)</b>	<b>Özgüllük (%)</b>
<b>Sol Yatay</b>	96,00	93,75	96,97
<b>Sağ Yatay</b>	94,67	92,16	96,05
<b>Sol Dikey</b>	92,00	87,99	94,06
<b>Sağ Dikey</b>	90,67	86,03	93,08


Çizelge 6.18'den de görüldüğü gibi, sol dikey (%92) ve sol yatay (%96) göz konumundan alınan sinyaller, sırasıyla sağ dikey (%90,67) ve sağ yatay (%94,67) göz konumundan alınan sinyallere göre daha yüksek sınıflandırma başarımı ortaya koymuştur. Benzer şekilde, duyarlılık ve özgüllük değerlerinin de sol göz konumu için daha iyi sonuç verdiği görülmüştür. Toplamda, her iki gözden alınan VOG sinyalleri incelendiğinde; yatay göz konumlarının sınıflandırma başarımı dikey göz konumlarına göre daha yüksek elde edilmiştir.

## **6.6 VİDEO-OKÜLOGRAFİ (VOG) SİNYALLERİNDEN DİYABETİK RETİNOPATİ HASTALIĞININ HİLBERT - HUANG DÖNÜŞÜMÜ VE PARÇACIK SÜRÜ OPTİMİZASYONU TEMELLİ ÇOK KATMANLI YAPAY SİNİR AĞI İLE TESPİTİ**

Bu kısımda, VOG sinyallerinden DR hastalığının tespiti için öznelik çıkarımı aşamasında, ADD yöntemine göre durağan ve doğrusal olmayan sinyallerin zaman-frekans bölgesinde daha ayrıntılı bileşen analizi sunan Hilbert - Huang dönüşümü (HHD) kullanılmıştır. Sınıflandırıcı olarak, son zamanlarda popüler bir optimizasyon aracı olan PSO algoritması geleneksel ÇKYSA topolojisine uygulanarak elde edilen hibrit PSO temelli ÇKYSA modeli kullanılmıştır. Veri seti olarak yaşları 19-70 arasında değişen 17'si sağlıklı, 16'sı EEDR ve 17'si GEDR hastalığına sahip olan 50 denekten sinyaller alınmıştır. Alınan sinyallerden HHD ile öznelik vektörleri çıkartılmıştır. Öznelik vektörü olarak HHD ile elde edilen içsel mod fonksiyonları (İMF) ve artık (rezidüel) sinyaller kullanılmıştır. Bu vektörlerin boyutları istatistiksel yöntemlerle (katsayıların maksimumu, minimumu, karekök ortalaması, standart sapması) azaltılmıştır. Şekil 6.22a-6.25a'da sağlıklı denek grubundan alınan 4 farklı göz konumu için VOG sinyalleri; Şekil 6.22b-6.25b'de sinyallere ait HDD işleminden elde edilen ilk 4 içsel mod fonksiyonları ile artık sinyalleri gösterilmiştir.

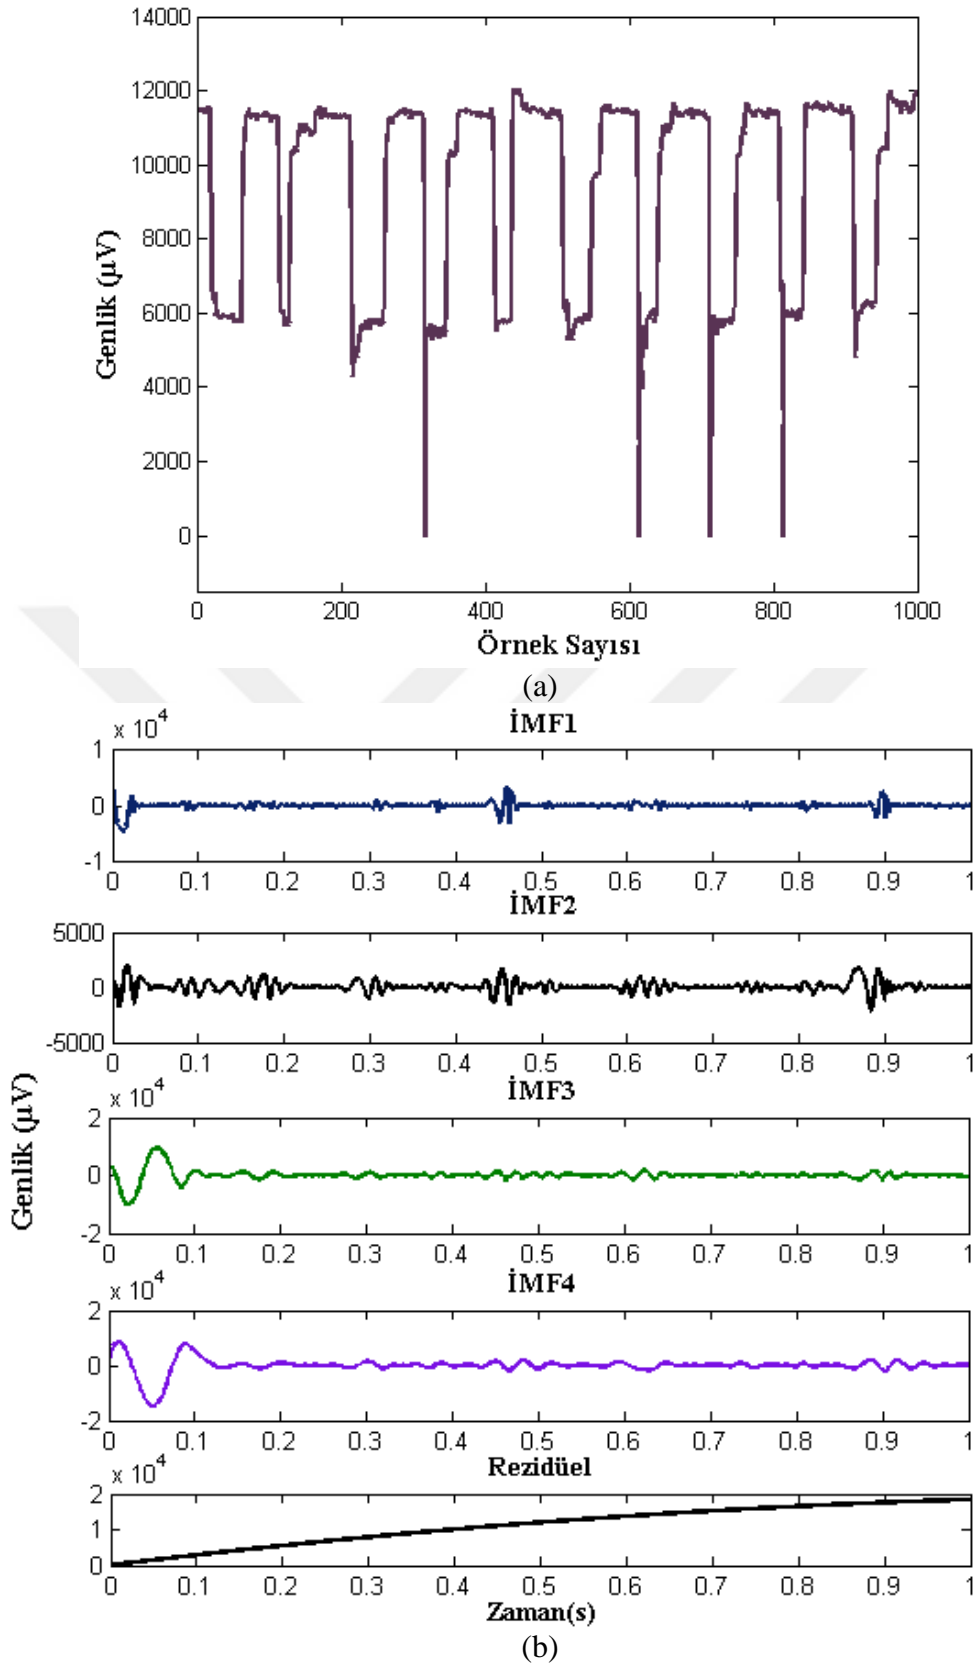


(a)

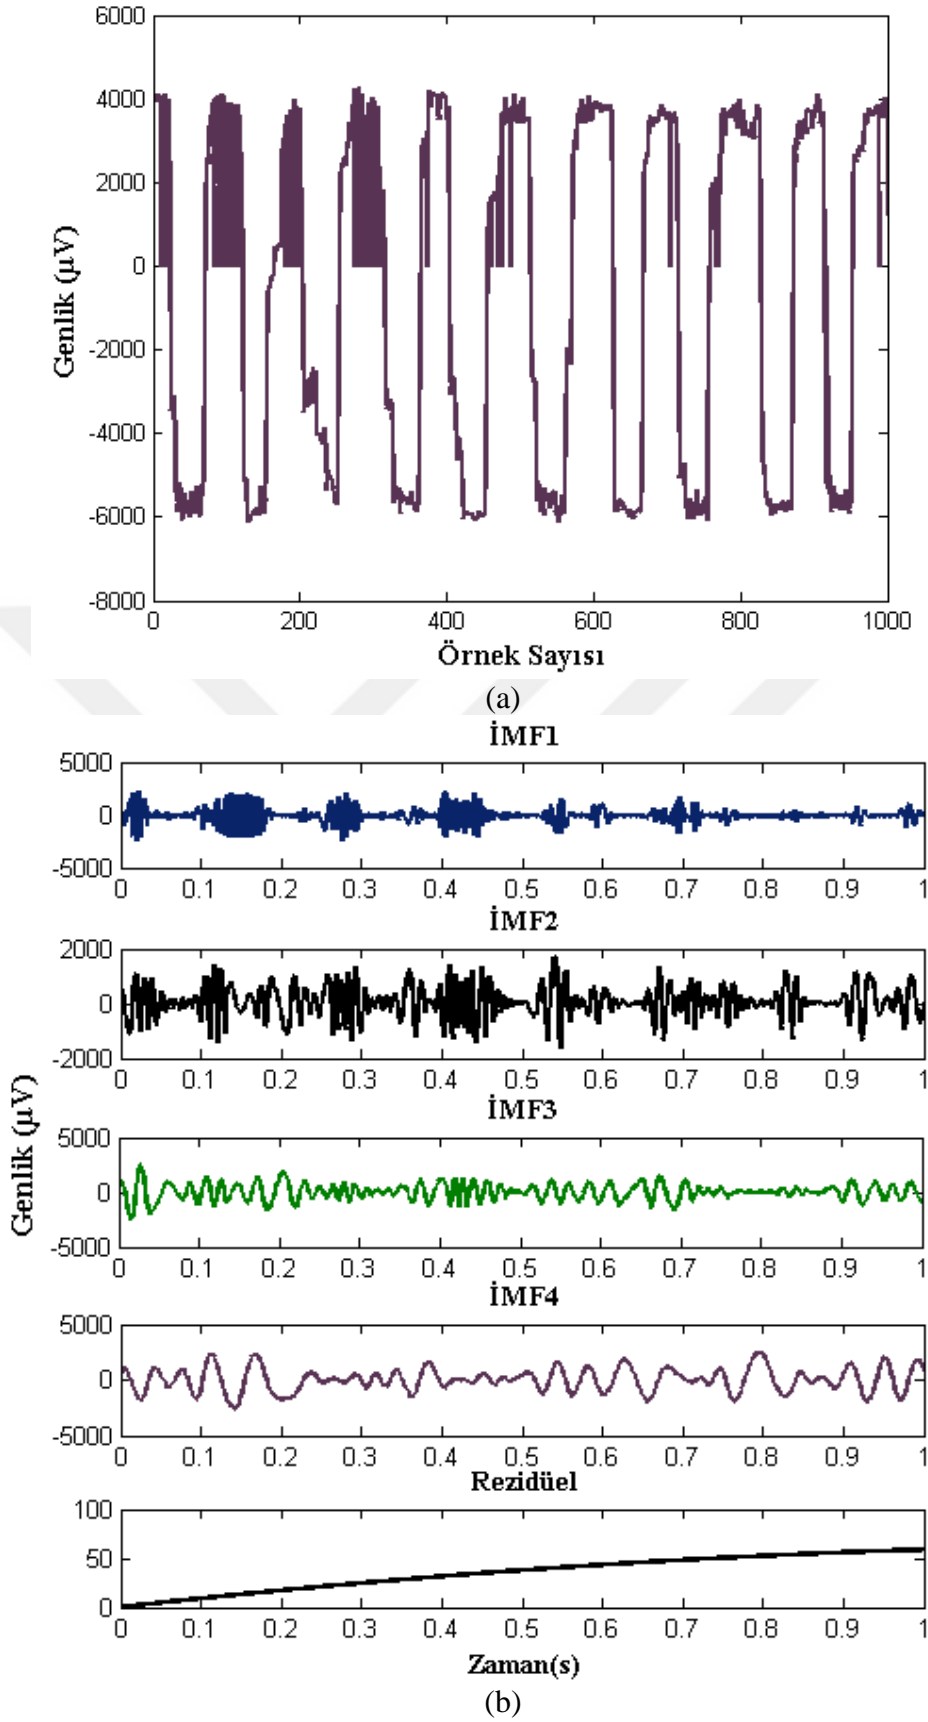


(b)


Şekil 6.22 Sağlıklı denek grubu için sol göz yatay konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal.



**Şekil 6.23** Sağlıklı denek grubu için sol göz dikey konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal.




Şekil 6.24 Sağlıklı denek grubu için sağ göz yatay konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal.



(a)

İMF1




(b)

Şekil 6.25 Sağlıklı denek grubu için sağ göz dikey konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal.




Şekil 6.22b-6.25b'den görüldüğü gibi İMF fonksiyonlarının genlik değerleri kendi aralarında değişkenlik göstermektedir. HDD işlemi sonucu elde edilen rezidüel sinyali, gerçek sinyal ile HDD sonucunda bulunan sinyal arasındaki farktır. Şekil 6.22-6.25 incelendiğinde; sol yatay göz konumundan alınan VOG sinyallerinin ve içsel mod fonksiyonlarının (İMF1-İMF4) genliklerinin değerleri, sağ yatay göz konumuna göre daha yüksektir. Aynı zamanda, sağ dikey göz konumundan alınan VOG sinyallerinin ve içsel mod fonksiyonlarının (İMF1-İMF4) genlikleri, sol dikey göz konumuna göre daha düşüktür.

Şekil 6.26a-6.29a'da EEDR denek grubundan alınan 4 farklı göz konumu için VOG sinyalleri; Şekil 6.26b-6.29b'de sinyallerin HDD işleminden elde edilen ilk 4 içsel mod fonksiyonları (İMF1-İMF4) ve artık sinyalleri gösterilmiştir.




(a)




(b)

Şekil 6.26 EEDR denek grubu için sol göz yatay konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal.




(a)




(b)

Şekil 6.27 EEDR denek grubu için sol göz dikey konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal.




(a)

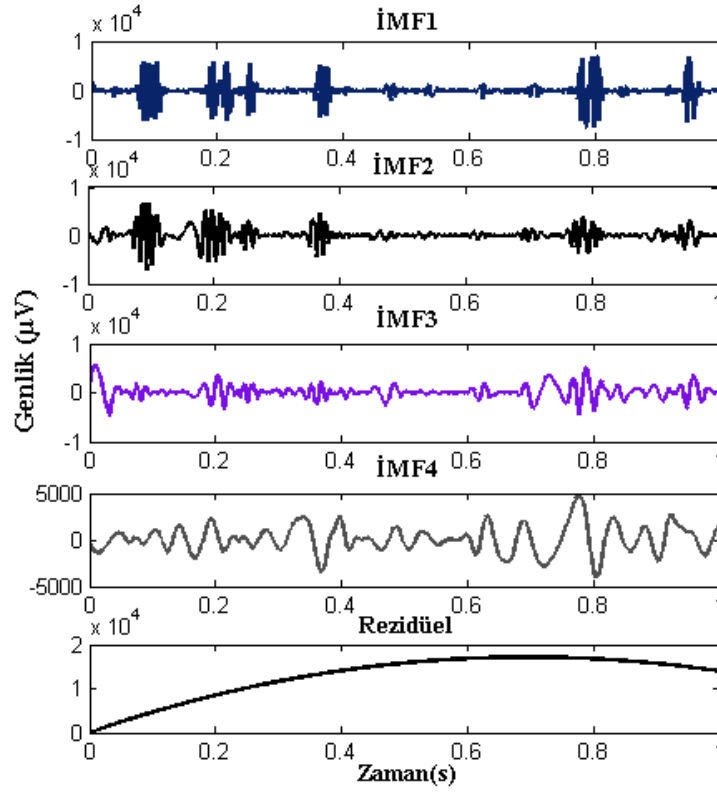


(b)

Şekil 6.28 EEDR Denek Grubu için sağ göz yatay konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal.



(a)

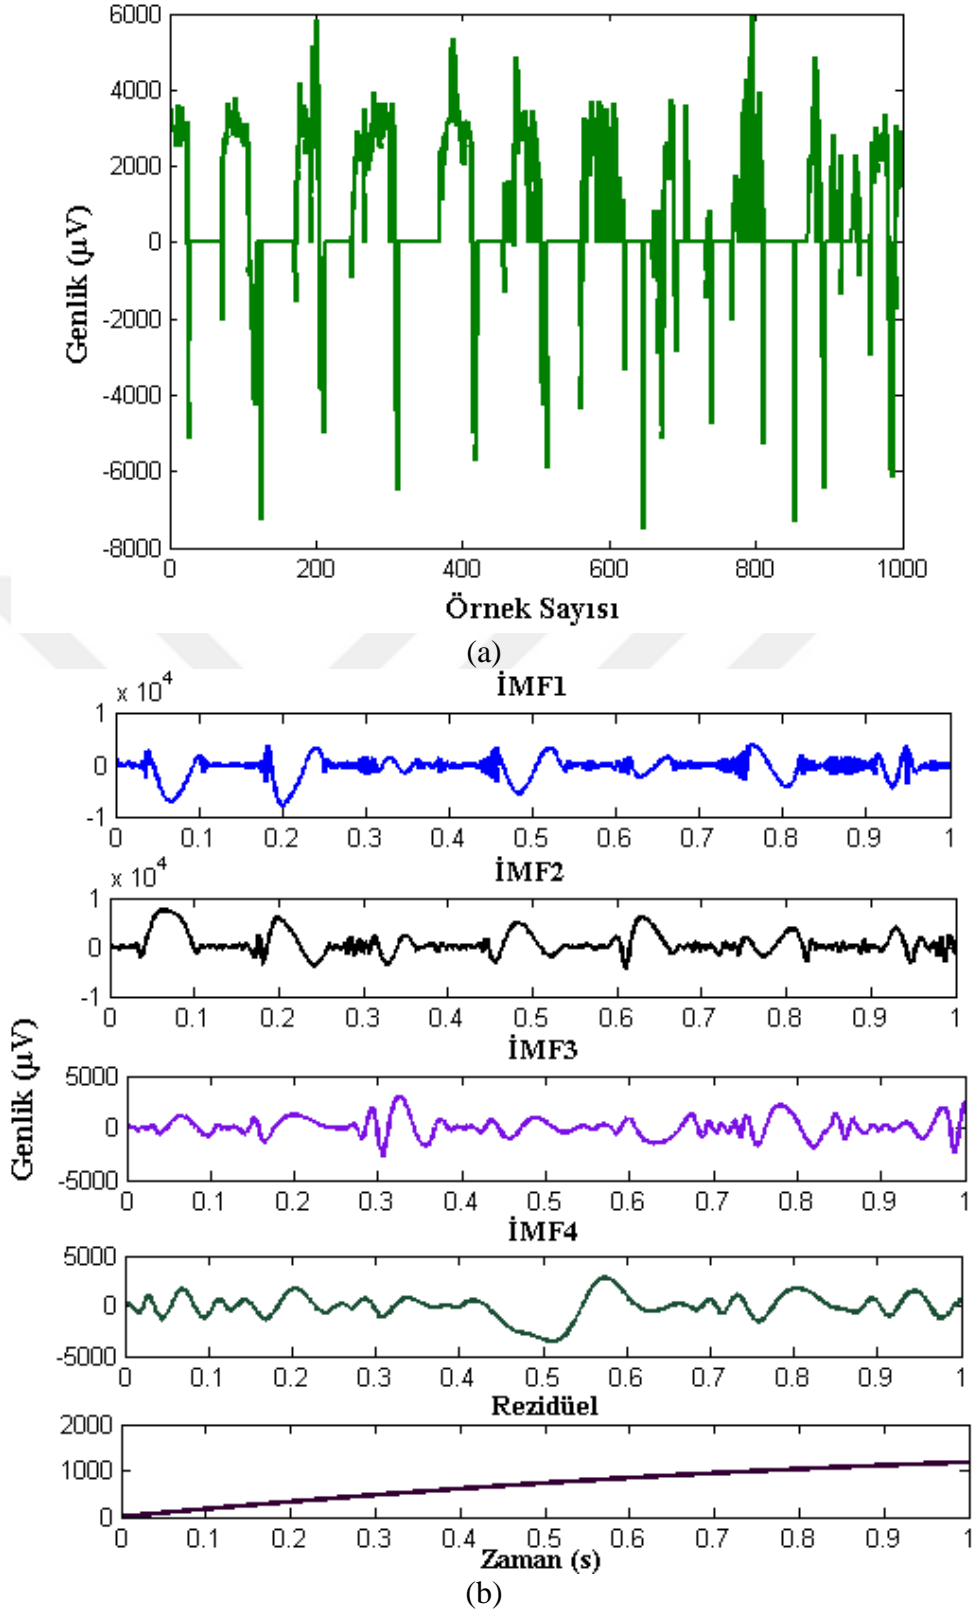


(b)


**Şekil 6.29** EEDR denek grubu için sağ göz dikey konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal.

Şekil 6.22-6.25 ile Şekil 6.26-6.29 kıyaslandığında; tüm göz konumlarında sağlıklı bireyden alınan VOG sinyal genliğinin ve HDD sonucunda elde edilen ilk 4 İMF katsayısının (İMF1-İMF4), EEDR hastalarından alınan VOG sinyal genliğinden ve HDD sonucunda elde edilen ilk 4 İMF katsayısından (İMF1-İMF4) daha yüksek olduğu açıkça görülmektedir. Bununla birlikte, EEDR denek grubundan alınan VOG sinyallerinin, sağlıklı deneklerden alınan sinyallere nazaran daha gürültülü olduğu gözlemlenmiştir. Öte yandan, EEDR’de dikey göz konumlarından alınan VOG sinyallerinin ve içsel mod fonksiyonlarının (İMF1-İMF4) genliklerinin, yatay göz konumlarından elde edilen sonuçlara göre daha yüksek olduğu tespit edilmiştir.


Şekil 6.30a-6.33a’da GEDR denek grubundan alınan 4 farklı göz konumu için VOG sinyalleri; Şekil 6.30b-6.33b’de sinyallere HDD işlemi uygulanmasıyla elde edilen ilk 4 içsel mod fonksiyonları ve artık sinyalleri verilmiştir.



Şekil 6.30 GEDR Denek Grubu için sol göz yatay konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal.

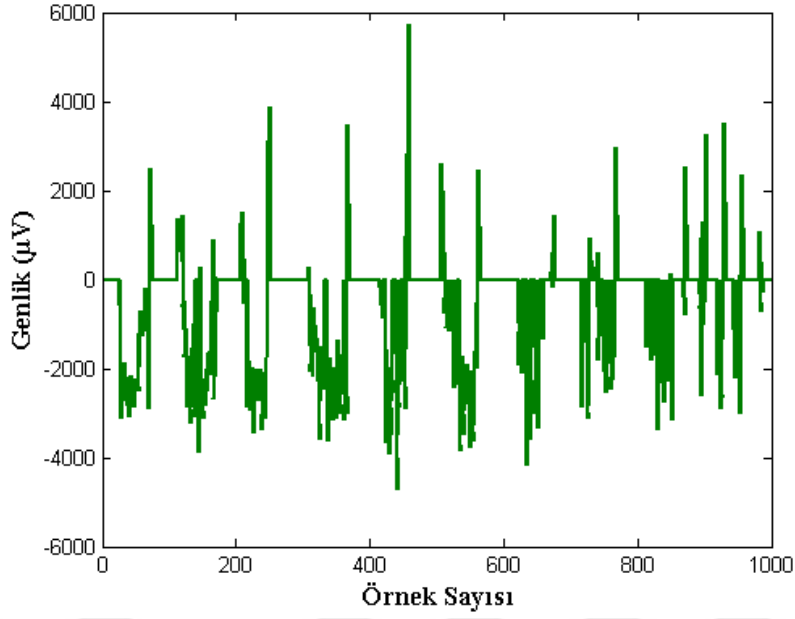


(a)




(b)

Şekil 6.31 GEDR denek grubu için sol göz dikey konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal.




(a)




(b)

Şekil 6.32 GEDR denek grubu için sağ göz yatay konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal.





(a)



(b)

Şekil 6.33 GEDR denek grubu için sağ göz dikey konum a) VOG sinyali b) İlk 4 içsel mod fonksiyonları ve artık sinyal.

Şekil 6.30-6.33'ten görüldüğü üzere 4 farklı göz konumu için GEDR hastalarından alınan VOG sinyal genlikleri ve HHD sonucunda elde edilen ilk 4 İMF katsayısının (İMF1-İMF4), sağlıklı (Şekil 6.22-6.25) ve EEDR (Şekil 6.26-6.29) denek gruplarına göre daha gürültülüdür. Aynı zamanda, diğer gruplar ile kıyaslandığında tüm göz konumlarında GEDR denek grubundan alınan VOG sinyal genliğinin ve HHD sonucunda elde edilen ilk 4 İMF katsayı (İMF1-İMF4) değerlerinin daha yüksek olduğu tespit edilmiştir. GEDR hastalığının etkisiyle VOG sinyallerindeki genlik sağlıklı bireye göre artarken, gürültünün EEDR'ye göre daha fazla arttığı gözlemlenmiştir. Bunun yanı sıra, dikey göz konumlarından alınan VOG sinyallerinin ve içsel mod fonksiyonları (İMF1-İMF4) genliklerinin, yatay göz konumlarından elde edilen sonuçlara göre daha yüksek olduğu belirlenmiştir.

Çalışmada son olarak, HHD yöntemiyle elde edilen öznitelikleri temel alan 7 farklı ÇKYSA modeli tasarlanmıştır. Tasarlanan modelde kullanılan öznitelikler sırasıyla İMF1, İMF2, İMF3, İMF4, İMF1-2, İMF1-3 ve İMF1-4 olarak belirlenmiştir. Her bir modelin giriş katmanındaki nöron sayısı farklı olup, belirlenen özniteliklere göre 4, 4, 4, 4, 8, 12 ve 16 olarak alınmıştır. Tek bir çıkış ve 16 nöronlu bir ara katmana sahip olan ÇKYSA modelinin ağırlıkları, PSO algoritması temelli bir eğitim yöntemi kullanarak optimize edilmiştir. Buna göre sol/sağ yatay/dikey göz konumları için tasarlanan 7 farklı HHD - ÇKYSA PSO modelinin performansları sırasıyla Çizelge 6.19-6.22'de verilmiştir.

**Çizelge 6.19** Sol yatay göz konumu için HHD - ÇKYSA PSO modelinin istatistiksel analizi.

<b>Sol Yatay Öznitelikler</b>	<b>Doğruluk (%)</b>	<b>Duyarlılık (%)</b>	<b>Özgüllük (%)</b>
<b>İMF1</b>	89,33	83,95	91,95
<b>İMF2</b>	90,67	85,78	92,93
<b>İMF3</b>	92,00	87,99	93,97
<b>İMF4</b>	93,33	89,83	94,95
<b>İMF1-2</b>	94,67	92,03	95,99
<b>İMF1-3</b>	96,00	93,87	96,97
<b>İMF1-4</b>	97,33	95,83	97,98

Çizelge 6.19' da görüldüğü gibi sol yatay göz konumu için en yüksek doğruluk (%97,33), duyarlılık (%95,83) ve özgüllük (%97,98) değerlerini öznitelik olarak İMF1-4 kullanılması durumunda elde edilmiştir. En düşük doğruluk (%89,33), duyarlılık (%83,95) ve özgüllük (%91,95) değerleri ise İMF1 özniteliği kullanıldığında hesaplanmıştır.

**Çizelge 6.20** Sağ yatay göz konumu için HHD - ÇKYSAPSO modelinin istatistiksel analizi.

Sağ Yatay Öznitelikler	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
İMF1	88,00	81,99	91
İMF2	89,33	83,82	91,92
İMF3	90,67	85,65	92,90
İMF4	92,00	87,86	93,94
İMF1-2	93,33	89,70	94,92
İMF1-3	94,67	91,90	95,96
İMF1-4	96,00	93,74	96,94

Çizelge 6.20’de sağ yatay göz konumu için öznitelik olarak İMF1-4 seçildiğinde en yüksek doğruluk (%96), duyarlılık (%93,74) ve özgüllük (%96,94) değerleri elde edilirken; İMF1 özniteliği kullanıldığında en düşük doğruluk (%88), duyarlılık (%81,99) ve özgüllük (%91) değerleri tespit edilmiştir.

**Çizelge 6.21** Sol dikey göz konumu için HHD - ÇKYSAPSO modelinin istatistiksel analizi.

Sol Dikey Öznitelikler	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)
İMF1	86,67	80,02	89,93
İMF2	88,00	81,86	90,97
İMF3	89,33	83,69	91,89
İMF4	89,33	83,82	91,92
İMF1-2	90,67	85,65	92,90
İMF1-3	92,00	87,86	93,94
İMF1-4	93,33	89,57	94,89

Çizelge 6.21 den açıkça görüldüğü gibi sol dikey göz konumu için en yüksek doğruluk (%93,33), duyarlılık (%89,57) ve özgüllük (%94,89) değerlerinin İMF1-4 öznitelik grubuna ait olduğu tespit edilmiştir. Buna karşın en düşük doğruluk (%86,67), duyarlılık (%80,02) ve özgüllük (%89,93) değerleri ise İMF1 özniteliğine aittir.

**Çizelge 6.22** Sağ dikey göz konumu için HHD - ÇKYSAPSO modelinin istatistiksel analizi.

<b>Sağ Dikey Öznitelikler</b>	<b>Doğruluk (%)</b>	<b>Duyarlılık (%)</b>	<b>Özgüllük (%)</b>
<b>İMF1</b>	86,67	79,92	89,92
<b>İMF2</b>	86,67	80,09	89,95
<b>İMF3</b>	88,00	81,93	90,99
<b>İMF4</b>	89,33	83,76	91,91
<b>İMF1-2</b>	89,33	83,89	91,94
<b>İMF1-3</b>	90,67	85,72	92,92
<b>İMF1-4</b>	92,00	87,93	93,96

Sağ dikey göz konumu için en yüksek doğruluk (%92), duyarlılık (%87,93) ve özgüllük (%93,96) değerlerinin öznitelik olarak İMF1-4 grubunun seçilmesinde; en düşük doğruluk (%86,67), duyarlılık (%79,92) ve özgüllük (%89,92) değerlerinin ise İMF1 özniteliğinin kullanılması durumundan elde edildiği belirlenmiştir (Çizelge 6.22).

Sonuç olarak; 4 farklı göz konumu için öznitelik olarak ilk 4 İMF'nin kullanıldığı durumda (İMF1-4) en yüksek sınıflandırma başarımı, ilk İMF'nin (İMF1) kullanıldığı durumda ise en düşük sınıflandırma başarımı elde edilmiştir. Bu durum kullanılan İMF sayısı arttıkça sınıflandırma performansının diğer İMF gruplarına göre daha iyi sonuç verdiğini göstermektedir. Öte yandan, yatay göz konumunun sınıflandırma başarımının dikey göz konumunun göre daha yüksek olduğu gözlenmiştir.

## BÖLÜM 7

### SONUÇ VE ÖNERİLER

Günümüz teknoloji çağında beslenme ve yaşam koşullarının değişimiyle doğru orantılı olarak metabolik hastalıklar artış göstermiştir. Bu bağlamda, insanların en yaygın karşılaştıkları hastalık diyabettir. Diyabet hastalığı vücuttaki pek çok organın yapısını bozmaktadır. Bu hastalığın gözün retina tabakasına önemli etkileri olduğu son zamanlarda yapılan çalışmalarda vurgulanmıştır [130-133]. En önemli etki ise diyabetik retinopati (DR) hastalığı olarak ortaya konulmuştur. DR, şeker hastalığına bağlı olarak kan şekerinin yükselmesi sonucu retina kılcal damarlarının etkilenmesi ile başlayan ve ilerleyen evrelerde görme duyusunun tamamen yitilmesiyle sonuçlanabilen bir süreçtir. Bu çalışmada, Video-Okülografi (VOG) sinyallerine DR hastalığının fizyolojik etkileri gösterilmiş ve önerilen yöntemler ile sinyal öznelikleri çıkarılarak erken teşhis için farklı sınıflandırıcı modellerinin kullanılabilirliği ortaya konulmuştur.

Gelişen teknolojilere bağlı olarak, DR hastalığı ile ilgili otomatik tespit çalışmaları büyük ivme kazanmış olmasına rağmen hastalık teşhisi, retinal fundus görüntüsüne dayalı olarak uzman hekimin görüşüne bağlı kalmaktadır. Bu durum hastalığın teşhisini zorlaştırmakla birlikte, sürecini de uzatmaktadır. Ayrıca, bu hastalığın düzenli muayene gerektirmesi ve uzman hekim sayısındaki azlık nedeniyle klinik tabanlı karar destek sistemlerinin geliştirilmesini zorunlu hale getirmektedir. Tıp alanında, kararların hızlı ve doğru şekilde verilmesi hayati öneme sahiptir. DR hastalığının ilerlemesinin durdurulmasında en önemli aşamayı erken tanı oluşturmaktadır. Bu doğrultuda uzman hekime karar desteği sağlamak amacıyla literatürdeki DR hastalığının erken tespiti konusunda yapılan çalışmalarda sıklıkla retinal fundus görüntüleri kullanılmıştır. Ancak bu süreçte görüntülerin bir uzman hekim tarafından yorumlanma zorunluluğu bulunmaktadır. Bu nedenle yapılan çalışmada, uzman hekim görüşüne bağlılığı en aza indirmek için retina görüntüsü yerine literatürden farklı olarak VOG sinyalleri tercih edilmiştir. Çalışmanın ilk amacı, DR hastalığının sinyal üzerine fizyolojik etkilerinin

belirlenmesi ve sinyal özniteliklerinin çıkarılmasıdır. Sonraki aşama ise öznitelikleri kullanarak farklı sınıflandırıcı performanslarının belirlenmesidir.

Fizyolojik etkilerin tespitinde, öznitelik çıkartma yöntemi olarak ayırık dalgacık dönüşümü (ADD) ve Hilbert-Huang dönüşümü (HHD) ayrıştırma yöntemleri kullanılmıştır. Böylece sinyalin zaman ve frekans bölgesi bileşenleri elde edilmiştir. İstatistiksel yöntemlerle (maksimum, minimum, ortalama, karekök ortalaması, standart sapma ve varyans) öznitelik vektörleri çıkarılmıştır. Bunun yanı sıra yapılan çalışmada öznitelik seçimi yöntemi olarak C4.5 karar ağacının kullanılmasının hastalığın evrelerinin tespitinde uygulanabilirliği araştırılmıştır. Farklı yöntemlerle (ADD, HDD, C4.5) çıkarılan öznitelikler çok katmanlı yapay sinir ağı (ÇKYSA) ve radyal tabanlı fonksiyon ağı (RTFA) modellerine uygulanarak modellerin sınıflandırma başarımları araştırılmıştır. Çalışmada ayrıca geleneksel yapay sinir ağlarına kıyasla daha yüksek performans sergileyen parçacık sürü optimizasyonu (PSO) algoritmasını kullanan hibrit bir ÇKYSA modeli tasarlanarak performans analizleri yapılmıştır.

DeneySEL çalışmalar ışığında, hem ham VOG sinyal analiziyle hem de ADD ve HHD yöntemleri sonucunda; sol göz yatay konum göz hareketlerinde erken evre diyabetik retinopati (EEDR), sağlıklı denek grubuna göre sinyal genliğini yaklaşık 2 kat arttırmakta (0,3 mV) ve gürültü oranını artırarak sinyali negatif bölgeye kaydırmaktadır. Geç evre diyabetik retinopati (GEDR) ise, sağlıklı denek grubuna göre genliği çok değiştirmemekle birlikte sinyali negatif bölgeye kaydırıp, sinyal karakteristiğini tamamen değiştirmektedir. Sağ göz yatay konum göz hareketlerinde EEDR denek grubu, sağlıklı gruba göre sinyal genliğini yaklaşık 1,5 kat (0,2 mV) arttırmakta ve sinyal davranış karakteristiğini farklılaştırmaktadır. GEDR denek grubu ise, sağlıklı gruba kıyasla genliği değiştirmemekte ancak bozucu etkisiyle sinyal karakteristiğini tamamen değiştirmektedir. Sol göz dikey konum göz hareketlerinde EEDR, sağlıklı denek grubuna göre sinyal genliğini 0,1 mV azaltmakta ve gürültüyü artırarak sinyal karakteristiğini büyük oranda değiştirmektedir. Ek olarak, sinyali negatif bölgeye kaydırmaktadır. GEDR ise, sağlıklı denek grubuna nazaran sinyal genliğini çok az değiştirmekte (yüksek veya eşit) ve sinyal pozitif bölgede kalsa da karakteristiğini tamamen farklılaştırmaktadır. Sağ göz dikey konum göz hareketlerinde, sinyal genliği sağlıklı denek grubundan GEDR grubuna doğru aynı kalsa da her evrede gürültü artmakta ve evre ilerledikçe sinyal tamamen farklı bir davranış sergilemektedir.

Çalışmada, ilk olarak 18 dengeli dağılımlı denekten alınan VOG sinyallerinden veri seti oluşturulmuştur. Bu veri setinden, Coiflet4 (coif4) temelli ADD yöntemi yardımıyla 25 farklı özniteliğe sahip öznitelik vektörü elde edilmiştir. Bu vektör ile 14 ara katman nörona sahip ÇKYSA ağı eğitilmiştir. Test sonuçlarında, ÇKYSA ağının sağ göz yatay konum için sağlıklı, EEDR ve GEDR denek gruplarında %100, sol göz yatay konum için %94,44 ve dikey konumlarda ise her iki göz içinde %94,44'lük sınıflandırma başarımı gösterdiği gözlemlenmiştir. İkinci aşamada 24 dengesiz dağılımlı deneklerden alınan VOG sinyalleri veri seti için kullanılmıştır. İlk aşamadaki ADD parametreleri değiştirilmeden 25 öznitelik üzerine C4.5 karar ağacı algoritması ile optimizasyon işlemi uygulanmıştır. Bu işlem sonucunda, sağ göz için 5 ve sol göz için 4 öznitelik seçilerek öznitelik vektörü oluşturulmuştur. Oluşturulan öznitelik vektörü ile 10 ara katman nöronlu ÇKYSA ağı eğitilmiştir. Test sonuçlarında C4.5 ile optimize edilen ÇKYSA ağının, sol göz dikey konum için %95,83, sağ göz yatay konum için %95,83, sağ göz dikey konum için %95,83 ve sol göz yatay konum için %100 sınıflandırma başarımına sahip olduğu tespit edilmiştir. Buradan hareketle, dengeli veri seti için başarılı olan ÇKYSA ağının, dengesiz veri seti için de başarılı bir şekilde sınıflandırma başarımına sahip olduğu görülmüştür. Ek olarak; tüm göz konumlarında (sol/sağ, yatay/dikey) C4.5 karar ağacı algoritması ile optimize edilen ÇKYSA ağının, geleneksel ÇKYSA ağ yapısına göre daha iyi performans sergilediği gösterilmiştir. Üçüncü aşamada, RTFA ağının sınıflandırma başarımı 21 denekten alınan VOG sinyallerini içeren dengeli bir veri seti için araştırılmış ve geleneksel ÇKYSA ağı ile performansı karşılaştırılmıştır. Çalışmada, ilk aşamada kullanılan ADD yöntemi parametreleri sabit bırakılarak öznitelik çıkarım işlemi yapılmıştır. 25 özniteliği içeren vektör ile 18 ara katman nöronlu geleneksel ÇKYSA ve RTFA ağları eğitilmiştir. Eğitim sonucunda, RTFA ağı tüm göz konumlarında (sol/sağ, yatay/dikey), %100 sınıflandırma başarımı göstermiş ve geleneksel ÇKYSA ağından daha yüksek başarımlar sergilemiştir.

Son aşamada ise diğer çalışmalardan farklı olarak, 17'si sağlıklı; 16'sı erken evre ve 17'si geç evre diyabetik retinopati rahatsızlığına sahip olan 50 denekten alınan sinyaller ile dengesiz dağılımlı yapıya sahip bir veri seti oluşturulmuştur. Bu veri setine ADD yöntemi uygulanarak 20 öznitelik vektörü ve HHD yöntemi kullanılarak sırasıyla, İMF1, İMF2, İMF3, İMF4, İMF1-2, İMF1-3 ve İMF1-4 içsel mod fonksiyonlarından 4,4,4,4,8,12,16 öznitelik vektörleri elde edilmiştir. Elde edilen vektörler, geleneksel 16 ara katman nöronuna sahip ÇKYSA mimarisinin yanında, yeni tasarlanan PSO tabanlı bir hibrit ÇKYSA mimarisini eğitmek için kullanılmıştır. ADD tabanlı özniteliklerle eğitilen ÇKYSA PSO ağı sol dikey göz için %92, sol yatay göz için %96, sağ dikey göz için %90,67 ve sağ yatay göz için %94,67 sınıflandırma

başarımıyla geleneksel ÇKYSA modelden daha yüksek bir başarımlı sergilemiştir. HHD tabanlı öznelik vektörleriyle eğitilen ÇKYSAPSO ağındaki en yüksek başarımlı, İMF1-4 içsel mod fonksiyonları kombinasyonuyla oluşturulan veri setinde elde edilmiştir. İMF1-4 kombinasyonuyla hazırlanan veri setiyle eğitilen ÇKYSAPSO ağının, sol dikey göz için %93,33, sol yatay göz için %97,33, sağ dikey göz için %92 ve sağ yatay göz için %96 sınıflandırma başarımlııyla geleneksel ÇKYSA modelinden ve ADD tabanlı eğitilen modellerden daha iyi başarımlıya sahip olduğu görülmüştür.

Sonuç olarak; VOG sinyallerinden DR hastalık evrelerinin, ADD ve HHD yöntemleri temelli birbirinden farklı, dengeli ve dengesiz dağılımlı veri setleri ile eğitilen ÇKYSA ağlarıyla (ÇKYSA, RTFA, C4.5 & ÇKYSA ve ÇKYSAPSO) başarılı bir şekilde tespit edilebileceği gösterilmiştir. Hastalığın VOG sinyalleri üzerine fizyolojik etkileri net bir şekilde ortaya konulmuştur. Bu çalışmanın, DR hastalığının erken tespitiyle hastaya uygulanacak tedavinin başarı yüzdesinin artışına zemin hazırlayacağı ve diğer göz hastalıklarının erken tanısı için EOG ve VOG sinyalleri temelli tasarlanacak karar destek sistemlerine ışık tutacağı düşünülmektedir.



## KAYNAKLAR

- [1] **Wong A M F** (2008) *Eye Movement Disorders*. 1st Edition, ISBN: 978-0-19-532426-6, Oxford University Press, New York, 312 pp.
- [2] **Malmivuo J and Plonsey R** (1995) The Electric Signals Originating in The Eye. *Bioelectromagnetism: Principles and Applications of Bioelectric and Biomagnetic Fields*, 1st Edition, ISBN: 978-0-19-505823-9, Oxford University Press, New York, 437-447.
- [3] **Roglic G** (2016) WHO Global Report on Diabetes: A Summary. *International Journal of Noncommunicable Diseases*, 1 (1): 3-8.
- [4] **Kobrin Klein B E** (2007) Overview of Epidemiologic Studies of Diabetic Retinopathy. *Ophthalmic Epidemiology*, 14 (4): 179-183.
- [5] **Jiménez-Báez M V, Márquez-González H, Bárcenas-Contreras R, Morales-Montoya C and Espinosa-García L F** (2015) Early Diagnosis of Diabetic Retinopathy in Primary Care. *Colombia Médica*, 46 (1): 14-18.
- [6] **Walter T, Klein J C, Massin P and Erginay A** (2002) A Contribution of Image Processing to The Diagnosis of Diabetic Retinopathy—Detection of Exudates in Color Fundus Images of The Human Retina. *IEEE Transactions on Medical Imaging*, 22 (10): 1236-1243.
- [7] **Nayak J, Bhat P S, Acharya R, Lim C M and Kagathi M** (2008) Automated Identification of Diabetic Retinopathy Stages Using Digital Fundus Images. *Journal of Medical Systems*, 32 (2): 107-115.
- [8] **Acharya R, Chua C K, Ng E Y K, Yu W and Chee C** (2008) Application of Higher Order Spectra for The Identification of Diabetes Retinopathy Stages. *Journal of Medical Systems*, 32 (6): 481-488.
- [9] **Chhablani J, Deepa M J, Tyagi M, Narayanan R and Kozak I** (2015) Fluorescein Angiography and Optical Coherence Tomography in Myopic Choroidal Neovascularization. *Eye*, 29 (4): 519-524.
- [10] **Priya R and Aruna P** (2013) Diagnosis of Diabetic Retinopathy Using Machine Learning Techniques. *ICTACT Journal on Soft Computing*, 3 (4): 563-575.

## KAYNAKLAR (devam ediyor)

- [11] **Rajput Y M, Manza R R, Patwari M B, Rathod D D, Borde P L and Yannawar P L** (2015) Detection of Non-Proliferative Diabetic Retinopathy Lesions Using Wavelet and Classification Using K-means Clustering. *International Conference on Communication Networks (ICCN)*, 19-21 Kasım 2015, Gwalior, Hindistan, 381-387.
- [12] **Noronha K, Acharya U R, Nayak K P, Kamath S and Bhandary S V** (2012) Decision Support System for Diabetic Retinopathy Using Discrete Wavelet Transform. *Journal of Engineering in Medicine*, 227 (3): 251-261.
- [13] **Acharya U R, Lim C M, Ng E Y K, Chee C and Tamura T** (2009) Computer-based Detection of Diabetes Retinopathy Stages Using Digital Fundus Images. *Proceedings of The Institution of Mechanical Engineers, Part H: Journal of Engineering in Medicine*, 223 (5): 545-553.
- [14] **Solkar S and Das L** (2017) A New Approach for Detection and Classification of Diabetic Retinopathy Using PNN and SVM Classifiers. *IOSR Journal of Computer Engineering*, 19 (5): 62-68.
- [15] **Pratt H, Coenen F, Broadbent D M, Harding S P and Zheng Y** (2016) Convolutional Neural Networks for Diabetic Retinopathy. *Procedia Computer Science*, 90 (1): 200-205.
- [16] **Lin C S, Lue L W, Yeh M S, Hwang T S and Lee S H** (2003) A New Image Processing Method for Evaluating The Pupillary Responses in a HMD-Type Eye-Tracking Device. *Optics & Laser Technology*, 35 (7): 505-515.
- [17] **Clarke A H, Ditterich J, Drüen K, Schönfeld U and Steineke C** (2002) Using High Frame Rate CMOS Sensors for Three-Dimensional Eye Tracking. *Behavior Research Methods, Instruments & Computers*, 34 (4): 549-560.
- [18] **Chen X and Wenfang L** (2012) A Pupil Location Method for Wifi-Based Video-Oculography System. *AASRI Procedia*, 1 (1): 389-393.
- [19] **Kim S C, Nam K C, Lee W S and Kim D W** (2006) A New Method for Accurate and Fast Measurement of 3D Eye Movements. *Medical Engineering & Physics*, 28 (1): 82-89.
- [20] **Hanuška J, Bonnet C, Rusz J, Sieger T, Jech R, Rivaud-Péchoux S, Vidailhet M, Gaymard B and Růžička E** (2015) Fast Vergence Eye Movements are Disrupted in Parkinson's Disease: A Video-Oculography Study. *Parkinsonism & Related Disorders*, 21 (7): 797-799.

## KAYNAKLAR (devam ediyor)

- [21] **Kaya C, ErKaymaz O, Ayar O ve Ozer M** (2016) Ayrık Dalgacık Dönüşümü Kullanarak Video-Okülografi (VOG) Sinyallerinden Diyabetik Retinopati Hastalığının Fizyolojik Etkilerinin Belirlenmesi. *Tıp Teknolojileri Ulusal Kongresi (TIPTEKNO)*, 27-29 Ekim 2016, Antalya, Türkiye, 142-145.
- [22] **Kaya C, ErKaymaz O, Ayar O ve Ozer M** (2017) Video-Okülografi (VOG) Sinyallerinden Diyabetik Retinopati Hastalığının Yapay Sinir Ağları İle Tespiti. *IEEE 25. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU)*, 15-18 Mayıs 2017, Antalya, Türkiye, 1-4.
- [23] **Kaya C, ErKaymaz O, Ayar O ve Ozer M** (2017) C4.5 Karar Ağacı Temelli Öznitelik Seçimi İle Video-Okülografi (VOG) Sinyallerinden Diyabetik Retinopati Hastalığının Sınıflandırılması. *Tıp Teknolojileri Ulusal Kongresi (TIPTEKNO)*, 12-14 Ekim 2017, Trabzon, Türkiye, 76-79.
- [24] **Kaya C, ErKaymaz O, Ayar O and Ozer M** (2017) Multi-Layer Perceptron and Radial Basis Function Neural Network Models for Classification of Diabetic Retinopathy Disease Using Video-Oculography Signals. *19th International Conference on Biomedical Engineering (ICBE)*, 2-3 Kasım 2017, Barselona, İspanya, *International Journal of Biomedical and Biological Engineering*, Barselona (e-book), Vol. 11, 606-611.
- [25] **Kaya C, ErKaymaz O, Ayar O and Özer M** (2018) Impact of Hybrid Neural Network on The Early Diagnosis of Diabetic Retinopathy Disease from Video-Oculography Signals. *Chaos, Solitons & Fractals*, 114: 164-174.
- [26] **Malhotra A, Minja F J, Crum A and Burrowes D** (2011) Ocular Anatomy and Cross-Sectional Imaging of The Eye. *Seminars in Ultrasound, CT and MRI*, 32 (1): 2-13.
- [27] **Chan S M and Boisjoly H** (2004) Advances in The Use of Adhesives in Ophthalmology. *Current Opinion in Ophthalmology*, 15 (4): 305-310.
- [28] **URL-1** <<http://diyabetim.net/goz-komplikasyonlari>>, Ziyaret tarihi: 20.06.2019.
- [29] **O'Dwyer A P (Ed.) ve Akova A Y (Ed.)** (2016) *Temel Göz Hastalıkları*. 3. Baskı, ISBN: 978-975-277-592-3, Güneş Tıp Kitabevleri, Ankara, 1288 s.
- [30] **Ridyard E** (2015) Extraocular Muscles: Variation in Their Anatomy, Length and Cross-Sectional Diameter. *International Journal of Anatomy and Research*, 3 (3) : 1198-1206.
- [31] **Harries A, Shah S, Teismann N, Price D and Nagdev A** (2010) Ultrasound Assessment of Extraocular Movements and Pupillary Light Reflex in Ocular Trauma. *The American Journal of Emergency Medicine*, 28 (8) : 956-959.

## KAYNAKLAR (devam ediyor)

- [32] **URL-2** <<https://www.improveeyesighthq.com/strabismus-surgery.html>>, Ziyaret tarihi: 18.05.2019.
- [33] **URL-3** <[https://www.dartmouth.edu/~dons/figures/chapt\\_4/fig\\_4-1.htm](https://www.dartmouth.edu/~dons/figures/chapt_4/fig_4-1.htm)>, Ziyaret tarihi: 18.05.2019.
- [34] **Özyurt O** (2012) Hareketsiz Hastalar İçin Gerçek Zamanlı Göz Kırpma İletişim Sistemi Tasarımı ve Uygulaması. *Yüksek Lisans Tezi*, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik ve Bilgisayar Sistemleri Eğitimi Anabilim Dalı, Konya, 110 s.
- [35] **Güven D** (2009) Retina ve Optik Sinirin Anatomisi ve Fizyolojisi. *Türkiye Klinikleri Journal of Dermatology-Special Topics*, 2 (3): 6-12.
- [36] **Du Bois-Reymond E H** (2018) *Untersuchungen Ueber Thierische Electricitat*. 2nd edition, ISBN: 978-0-24-355061-6, Forgotten Books, Londra, 622 pp.
- [37] **Gündoğan F Ç, Uysal Y, Erdem Ü, Sobacı G ve Bayraktar M Z** (2006) Elektrokülogram Normal Değerlerimiz. *Gülhane Tıp Dergisi*, 48 (1): 79-82.
- [38] **Yanoff M and Duker J S** (2013) *Ophthalmology*. 4th edition, ISBN: 978-145-5739-83-7, Elsevier, Hollanda, 1428 pp.
- [39] **Heckenlively J R (Ed.) and Arden G B (Ed.)** (2006) *Principles and Practice of Clinical Electrophysiology of Vision*. 2nd edition, ISBN: 978-026-2083-46-1, The MIT Press, Londra, 1016 pp.
- [40] **Keserü M, Feucht M, Bornfeld N, Laube T, Walter P, Rössler G, Velikay-Parel M, Hornig R and Richard G** (2012) Acute Electrical Stimulation of The Human Retina with an Epiretinal Electrode Array. *Acta Ophthalmologica*, 90 (1): e1-e8.
- [41] **Robson A G, Nilsson J, Li S, Jalali S, Fulton A B, Tormene A P, Holder G E and Brodie S E** (2018) ISCEV Guide to Visual Electrodiagnostic Procedures. *Documenta Ophthalmologica*, 136 (1): 1-26.
- [42] **Odom J V, Bach M, Barber C, Brigell M, Holder G E, McCulloch D L, Mizota A and Tormene A P** (2016) ISCEV Standard for Clinical Visual Evoked Potentials. *Documenta Ophthalmologica*, 133 (1): 1-9.
- [43] **Pihl-Jensen G, Schmidt M F and Frederiksen J L** (2017) Multifocal Visual Evoked Potentials in Optic Neuritis and Multiple Sclerosis: A Review. *Clinical Neurophysiology*, 128 (7): 1234-1245.

## KAYNAKLAR (devam ediyor)

- [44] **Güven A** (2005) Göze Ait Elektrofizyolojik Sinyaller Kullanılarak Yapay Sinir Ağları Destekli Bazı Göz Hastalıklarının Teşhisi. *Doktora Tezi*, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik Mühendisliği Anabilim Dalı, Kayseri, 105 s.
- [45] **Miguel-Jiménez J M, Boquete L, Ortega S, Rodriguez-Ascariz J M and Blanco R** (2010) Glaucoma Detection By Wavelet-Based Analysis of The Global Flash Multifocal Electroretinogram. *Medical Engineering & Physics*, 32 (6): 617-622.
- [46] **Yip Y W Y, Man T C, Pang C P and Brelén M E** (2018) Improving The Quality of Electroretinogram Recordings Using Active Electrodes. *Experimental Eye Research*, 176 (1): 46-52.
- [47] **Barraco R, Adorno D P and Brai M** (2011) An Approach Based on Wavelet Analysis for Feature Extraction in The A-Wave of The Electroretinogram. *Computer Methods and Programs in Biomedicine*, 104 (3): 316-324.
- [48] **Öztürk N, Gündüz M K ve Okka M** (2015) Patern Elektroretinografide Normal Değerler. *Journal of Retina-Vitreous*, 23 (3): 231-236.
- [49] **Krasodomska K, Lubiński W, Potemkowski A and Honczarenko K** (2010) Pattern Electroretinogram (PERG) and Pattern Visual Evoked Potential (PVEP) in The Early Stages of Alzheimer's Disease. *Documenta Ophthalmologica*, 121 (2): 111-121.
- [50] **Erkaymaz H, Özer M ve Kaya C** (2015) Sinirsel Bulanık Yaklaşımı İle EOG Kontrollü Yön Tespit Sistemi. *19. Biyomedikal Mühendisliği Ulusal Toplantısı (BİYOMUT)*, 5-6 Kasım 2015, İstanbul, Türkiye, 1-4.
- [51] **D'Souza S and Sriraam N** (2013) Statistical Based Analysis of Electrooculogram (EOG) Signals: A Pilot Study. *International Journal of Biomedical and Clinical Engineering*, 2 (1): 12-25.
- [52] **Banerjee A, Dattab S, Palb M, Konarb A, Tibarewalaa D N and Janarthanan R** (2013) Classifying Electrooculogram to Detect Directional Eye Movements. *Procedia Technology*, 10 (1): 67-75.
- [53] **Ghasad P P** (2016) Design and Implementation of Electro-Oculogram Based Brain-Computer-Interaction. *8th International Conference on Computational Intelligence and Communication Networks (CICN)*, 23-25 Aralık 2016, Tehri, Hindistan, 637-640.
- [54] **Moschos M M, Gouliopoulos N S and Kalogeropoulos C** (2014) Electrophysiological Examination in Uveitis: A Review of The Literature. *Clinical Ophthalmology*, 8 (1): 199-214.

## KAYNAKLAR (devam ediyor)

- [55] **Rasku J, Joutsijoki H, Pyykkö I and Juhola M** (2012) Prediction of a State of a Subject on The Basis of a Stabilogram Signal and Video Oculography Test. *Computer Methods and Programs in Biomedicine*, 108 (2): 580-588.
- [56] **Larrazabal A J, Cena C G and Martínez C E** (2019) Video-Oculography Eye Tracking Towards Clinical Applications: A Review. *Computers in Biology and Medicine*, 108 (1): 57-66.
- [57] **Webster J G** (Ed.) (2011) *Medical Instrumentation: Application and Design*. 4th edition, ISBN: 978-047-1676-00-3, John Wiley & Sons, New Jersey, 736 pp.
- [58] **Khandpur R S** (2004) *Biomedical Instrumentation: Technology and Applications*. 1st edition, ISBN: 978-007-1447-84-3, McGraw-Hill Education, New York, 924 pp.
- [59] **Ardıç D S** (2009) Optokinetik Nistagmus Sistemi Tasarımı. *Yüksek Lisans Tezi*, Başkent Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Anabilim Dalı, Ankara, 106 s.
- [60] **Swapna G, Vinayakumar R and Soman K P** (2018) Diabetes Detection Using Deep Learning Algorithms. *ICT Express*, 4 (4): 243-246.
- [61] **Grosman B, Ilany J, Roy A, Kurtz N, Wu D, Parikh N, Voskanyan G, Konvalina N, Mylonas C, Gottlieb R, Kaufman F and Cohen O** (2016) Hybrid Closed-Loop Insulin Delivery in Type 1 Diabetes During Supervised Outpatient Conditions. *Journal of diabetes science and technology*, 10 (3): 708-713.
- [62] **Kernel W and Brückel J** (2014) Definition, Classification and Diagnosis of Diabetes Mellitus. *Experimental and Clinical Endocrinology & Diabetes*, 122 (7): 384-386.
- [63] **Lyu Y, Zeng X, Li F and Zhao S** (2019) The Effect of The Duration of Diabetes on Dry Eye and Corneal Nerves. *Contact Lens and Anterior Eye*, 42 (4): 380-385.
- [64] **Liu R, Ma B, Gao Y, Ma B, Liu Y and Qi H** (2019) Tear Inflammatory Cytokines Analysis and Clinical Correlations in Diabetes and Nondiabetes with Dry Eye. *American Journal of Ophthalmology*, 200 (1): 10-15.
- [65] **Lynch S K and Abràmoff M D** (2017) Diabetic Retinopathy is a Neurodegenerative Disorder. *Vision Research*, 139 (1): 101-107.
- [66] **URL-4** <<http://www.goz.kim/forum-4-diabetik-goz.html>>, Ziyaret tarihi: 01.07.2019.

## KAYNAKLAR (devam ediyor)

- [67] **Adem K** (2018) Exudate Detection for Diabetic Retinopathy with Circular Hough Transformation and Convolutional Neural Networks. *Expert Systems with Applications*, 114 (1): 289-295.
- [68] **Kreider K E** (2019) The Diagnosis and Management of Atypical Types of Diabetes. *The Journal for Nurse Practitioners*, 15 (2): 171-176.
- [69] **Zhang W, Zhong J, Yang S, Gao Z, Hu J, Chen Y and Yi Z** (2019) Automated Identification and Grading System of Diabetic Retinopathy Using Deep Neural Networks. *Knowledge-Based Systems*, 175 (1): 12-25.
- [70] **Mohammadpoory Z, Nasrolahzadeh M, Mahmoodian N and Haddadnia J** (2019) Automatic Identification of Diabetic Retinopathy Stages By Using Fundus Images and Visibility Graph Method. *Measurement*, 140 (1): 133-141.
- [71] **Biyani R S and Patre B M** (2018) Algorithms for Red Lesion Detection in Diabetic Retinopathy: A review. *Biomedicine & Pharmacotherapy*, 107 (1): 681-688.
- [72] **Tuğcu B and Özdemir H** (2016) Optik Disk Drusenli Tanısında Görüntüleme Yöntemleri. *Turkish Journal Of Ophthalmology*, 46 (1): 232-236.
- [73] **Nesper P L, Soetikno B T, Zhang H F and Fawzi A A** (2017) OCT Angiography and Visible-Light OCT in Diabetic Retinopathy. *Vision Research*, 139 (1): 191-203.
- [74] **URL-5** <<https://www.venividigoz.com/goz-hastaliklari/ffa>>, Ziyaret tarihi: 12.05.2019.
- [75] **Aksu A E K, Erdemir V A T and Gürel M S** (2017) Optik Koherens Tomografi. *Turkiye Klinikleri Journal of Dermatology-Special Topics*, 10 (1): 67-71.
- [76] **Liu G, Xu D and Wang F** (2018) New Insights Into Diabetic Retinopathy By OCT Angiography. *Diabetes Research and Clinical Practice*, 142 (1): 243-253.
- [77] **URL-6** <<https://www.venividigoz.com/goz-hastaliklari/oct-optik-koherens-tomografi>>, Ziyaret tarihi: 12.05.2019.
- [78] **Ozgonul C, Kucukevcilioglu M and Gokce G** (2016) The Use of Ultrasound in Ocular Diseases. *The American Journal of Emergency Medicine*, 34 (1): 100-112.
- [79] **Simenc G B, Ambrozic J, Prokselj K, Tul N, Cvijic M, Mirkovic T and Lucovnik M** (2018) Ocular Ultrasonography for Diagnosing Increased Intracranial Pressure in Patients with Severe Preeclampsia. *International Journal of Obstetric Anesthesia*, 36 (1): 49-55.

## KAYNAKLAR (devam ediyor)

- [80] URL-7 <<https://www.venividigoz.com/goz-hastaliklari/usg-ultrasonografi>>, Ziyaret tarihi: 12.05.2019.
- [81] Hyvärinen A, Ramkumar P, Parkkonen L and Hari R (2010) Independent Component Analysis of Short-Time Fourier Transforms for Spontaneous EEG/MEG Analysis. *NeuroImage*, 49 (1): 257-271.
- [82] Öner İ V, Yeşilyurt M K ve Yılmaz E Ç (2017) Wavelet Analiz Tekniği ve Uygulama Alanları. *Ordu Üniversitesi Bilim ve Teknoloji Dergisi*, 7 (1): 42-56.
- [83] Goswami J C and Chan A K (2011) *Fundamentals of Wavelets: Theory, Algorithms and Applications*. 2nd edition, ISBN: 978-047-0484-13-5, John Wiley & Sons, New Jersey, 359 pp.
- [84] Arı N, Özen Ş ve Çolak Ö H (2008) Dalgacık Teorisi (Wavelet) Matlab Uygulamaları İle. 1. Baskı, ISBN: 9944341707, Palme Yayıncılık, Ankara, 152 s.
- [85] Subaşı A (2007) EEG Signal Classification Using Wavelet Feature Extraction and a Mixture of Expert Model. *Expert Systems with Applications*, 32 (4): 1084–1093.
- [86] Budu K (2013) Comparison of Wavelet-Based ANN and Regression Models for Reservoir in Flow Forecasting. *Journal of Hydrologic Engineering*, 19 (7): 1385-1400.
- [87] Tanyeri U (2014) Dalgacık Dönüşümüne Dayalı Yayınım Filtresi Tasarımı. *Doktora Tezi*, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Endüstriyel Teknoloji Eğitimi Anabilim Dalı, Ankara, 151 s.
- [88] Huang N E, Shen Z, Long S R, Wu M C, Shih H H, Zheng Q, Yen N C, Tung C C and Liu H H (1998) The Empirical Mode Decomposition Method and The Hilbert Spectrum for Non-Stationary Time Series Analysis. *Proceedings of the Royal Society of London Series A*, 454 (1): 903-995.
- [89] Yücelbaş Ş, Yücelbaş C, Tezel G, Özşen S and Yosunkaya Ş (2018) Automatic Sleep Staging Based on SVD, VMD, HHT and Morphological Features of Single-Lead ECG Signal. *Expert Systems with Applications*, 102 (1): 193-206.
- [90] Yan R and Gao R X (2006) Hilbert–Huang Transform-Based Vibration Signal Analysis for Machine Health Monitoring. *IEEE Transactions on Instrumentation and Measurement*, 55 (6): 2320-2329.
- [91] Picinbono B (1997) On Instantaneous Amplitude and Phase of Signals. *IEEE Transactions on Signal Processing*, 45 (3): 552-560.



## KAYNAKLAR (devam ediyor)

- [92] **Djemili R, Bourouba H and Korba M A** (2016) Application of Empirical Mode Decomposition and Artificial Neural Network for The Classification of Normal and Epileptic EEG signals. *Biocybernetics and Biomedical Engineering*, 36 (1): 285-291.
- [93] **Öztemel E** (2016) *Yapay Sinir Ağları*. 4. Baskı, ISBN: 978-975-679-739-6, Papatya Yayıncılık, İstanbul, 232 s.
- [94] **Erkaymaz O, Özer M and Perc M** (2017) Performance of Small-World Feedforward Neural Networks for The Diagnosis of Diabetes. *Applied Mathematics and Computation*, 311 (1): 22-28.
- [95] **Elmas Ç** (2016) *Yapay Zekâ Uygulamaları*. 3. Baskı, ISBN: 978-975-023-686-0, Seçkin Yayıncılık, Ankara, 448 s.
- [96] **Dede G** (2008) Yapay Sinir Ağları ile Konuşma Tanıma. *Yüksek Lisans Tezi*, Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik Mühendisliği Anabilim Dalı, Ankara, 84 s.
- [97] **Karaboğa D** (2017) *Yapay Zekâ Optimizasyon Algoritmaları*. 4. Baskı, ISBN: 978-605-133-764-7, Nobel Akademik Yayıncılık, Ankara, 246 s.
- [98] **Uzun R, Yılmaz E and Özer M** (2017) Effects of Autapse and Ion Channel Block on The Collective Firing Activity of Newman–Watts Small-World Neuronal Networks. *Physica A: Statistical Mechanics and Its Applications*, 486 (1): 386-396.
- [99] **Erkaymaz H** (2014) Elektrokulogram (EOG) Sinyalinin İncelenmesi ve Yapay Zekâ Teknikleri İle Modellenmesi. *Doktora Tezi*, Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Zonguldak, 126 s.
- [100] **Yılmaz A** (2017) *Yapay Zekâ*. 2. Baskı, ISBN: 978-605-911-880-4, Kodlab Yayıncılık, İstanbul, 384 s.
- [101] **Mane S M, Kambli R A, Kazi F S and Singh N M** (2015) Hand Motion Recognition From Single Channel Surface EMG Using Wavelet & Artificial Neural Network. *Procedia Computer Science*, 49 (1): 58-65.
- [102] **Acir N, Oztura I, Kuntalp M, Baklan B and Guzelis C** (2005) Automatic Detection of Epileptiform Events in EEG By a Three-Stage Procedure Based on Artificial Neural Networks. *IEEE Transactions on Biomedical Engineering*, 52 (1): 30-40.
- [103] **Erkaymaz O** (2012) İleri Yönlü Yapay Sinir Ağlarında Küçük Dünya Ağı Yaklaşımı ve Uygulamaları. *Doktora Tezi*, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Sakarya, 142 s.

## KAYNAKLAR (devam ediyor)

- [104] **Erkaymaz H, Özer M, Kaya C ve Orak İ M** (2015) Ön Eşik Filtreleme Algoritması İle EOG Temelli Akıllı Yön Tespit Sistemi. *IEEE 23. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU)*, 16-19 Mayıs 2015, Malatya, Türkiye, 1-4.
- [105] **Balaban M E ve Kartal E** (2015) *Veri Madenciliği ve Makine Öğrenmesi Temel Algoritmaları ve R Dili İle Uygulamaları*. 1. Baskı, ISBN: 978-975-436-089-9, Çağlayan Kitabevi, İstanbul, 288 s.
- [106] **Saikia A, Kakoty N M, Phukan N, Balakrishnan M, Sahai N, Paul S and Bhatia D** (2018) Combination of EMG Features and Stability Index for Finger Movements Recognition. *Procedia Computer Science*, 133 (1): 92-98.
- [107] **Aydemir E** (2018) *Weka İle Yapay Zekâ*. 1. Baskı, ISBN: 978-975-024-915-0, Seçkin Yayıncılık, İstanbul, 216 s.
- [108] **Kubat C** (2014) *Matlab Yapay Zekâ ve Mühendislik Uygulamaları*. 2. Baskı, ISBN: 978-605-510-612-6, Pusula Yayıncılık, İstanbul, 754 s.
- [109] **Erkaymaz H, Özer M and Orak İ M** (2015) Detection of Directional Eye Movements Based on The Electrooculogram Signals Through an Artificial Neural Network. *Chaos Solitons & Fractals*, 56 (1): 202-208.
- [110] **URL-8** <<https://towardsdatascience.com/applied-deep-learning-part-1-artificial-neural-networks-d7834f67a4f6>>, Ziyaret tarihi: 02.07.2019.
- [111] **Van Der Malsburg C** (1986) Frank Rosenblatt: Principles of Neurodynamics: Perceptrons and The Theory of Brain Mechanisms. *Brain Theory*, Palm G (Ed.) and Aertsen A (Ed.), 1st edition, ISBN: 978-3-642-70913-5, Springer, Berlin, 245-248.
- [112] **Erkaymaz O and Özer M** (2016) Impact of Small-World Network Topology on The Conventional Artificial Neural Network for The Diagnosis of Diabetes. *Chaos, Solitons & Fractals*, 83 (1): 178-185.
- [113] **Li Y, Liu Q, Tan S R and Chan R H** (2016) High-Resolution Time-Frequency Analysis of EEG Signals Using Multiscale Radial Basis Functions. *Neurocomputing*, 195 (1): 96-103.
- [114] **Velez-Langs O** (2014) Feature Reduction Using a RBF Network for Classification of Learning Styles in First Year Engineering Students. *Revista chilena de ingenieria*, 22 (1): 140-151.
- [115] **Silahtaroglu G** (2016) *Veri Madenciliği Kavram ve Algoritmaları*. 3. Baskı, ISBN: 978-975-6797-81-5, Papatya Yayıncılık, İstanbul, 304 s.

## KAYNAKLAR (devam ediyor)

- [116] **Özkan Y** (2016) *Veri Madenciliği Yöntemleri*. 3. Baskı, ISBN: 978-975-679-782-2, Papatya Yayıncılık, İstanbul, 240 s.
- [117] **Pektaş A O** (2013) *SPSS İle Veri Madenciliği*. 1. Baskı, ISBN: 978-605-866-604-7, Dikeyksen Yayıncılık, İstanbul, 296 s.
- [118] **Atyabi A, Luerssen M H and Powers D M** (2013) PSO-Based Dimension Reduction of EEG Recordings: Implications for Subject Transfer in BCI. *Neurocomputing*, 119 (1): 319-331.
- [119] **Ahirwal M K, Kumar A and Singh G K** (2014) Adaptive Filtering of EEG/ERP Through Noise Cancellers Using an Improved PSO Algorithm. *Swarm and Evolutionary Computation*, 14 (1): 76-91.
- [120] **Shirvany Y, Edelvik F, Jakobsson S, Hedström A and Persson M** (2013) Application of Particle Swarm Optimization in Epileptic Spike EEG Source Localization. *Applied Soft Computing*, 13 (5): 2515-2525.
- [121] **Melgani F and Bazi B** (2008) Classification of Electrocardiogram Signals with Support Vector Machines and Particle Swarm Optimization. *IEEE Transactions on Information Technology in Biomedicine*, 12 (5): 667-677.
- [122] **Mirvaziri H and Mobarakeh Z S** (2017) Improvement of EEG-Based Motor Imagery Classification Using Ring Topology-Based Particle Swarm Optimization. *Biomedical Signal Processing and Control*, 32 (1): 69-75.
- [123] **Orhan U, Hekim M and Özer M** (2011) EEG Signals Classification Using The K-Means Clustering and a Multilayer Perceptron Neural Network Model. *Expert Systems with Applications*, 38 (10): 13475-13481.
- [124] **Tantithamthavorn C, McIntosh S, Hassan A E and Matsumoto K** (2016) An Empirical Comparison of Model Validation Techniques for Defect Prediction Models. *IEEE Transactions on Software Engineering*, 43 (1): 1-18.
- [125] **Manzoor I and Kumar N** (2017) A Feature Reduced Intrusion Detection System Using ANN Classifier. *Expert Systems with Applications*, 88 (1): 249-257.
- [126] **Dangare C S and Apte S S** (2012) Improved Study of Heart Disease Prediction System Using Data Mining Classification Techniques. *International Journal of Computer Applications*, 47 (10): 44-48.

## KAYNAKLAR (devam ediyor)

- [127] **Kaya C, Erkaymaz O, Ayar O ve Özer M** (2018) Elektrokülogram (EOG) Sinyallerinden Göz Kıırma Kusurlarının Veri Madencilięi Teknikleri Kullanılarak Sınıflandırılması. *IEEE 26. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU)*, 2-5 Mayıs 2018, İzmir, Türkiye, 1-4.
- [128] **Narang A, Batra B, Ahuja A, Yadav J and Pachauri N** (2018) Classification of EEG Signals for Epileptic Seizures Using Levenberg-Marquardt Algorithm Based Multilayer Perceptron Neural Network. *Journal of Intelligent & Fuzzy Systems*, 34 (3): 1669-1677.
- [129] **URL-9** <<https://www.cs.waikato.ac.nz/ml/weka>>, Ziyaret tarihi: 12.05.2019.
- [130] **Mermeklieva E A** (2019) Pattern Electroretinography and Retinal Changes in Patients with Diabetes Mellitus Type 2. *Neurophysiologie Clinique*, 49 (3): 209-215.
- [131] **Schmidt-Erfurth U, Sadeghipour A, Gerendas B S, Waldstein S M and Bogunović H** (2018) Artificial Intelligence in Retina. *Progress in Retinal and Eye Research*, 67 (1): 1-29.
- [132] **Pardue M T and Allen R S** (2018) Neuroprotective Strategies for Retinal Disease. *Progress in Retinal and Eye Research*, 65 (1): 50-76.
- [133] **Salamat N, Missen M M S and Rashid A** (2019) Diabetic Retinopathy Techniques in Retinal Images: A Review. *Artificial Intelligence in Medicine*, 97 (1): 168-188.

## ÖZGEÇMİŞ

Ceren KAYA 1986 yılında İzmir’de doğdu; ortaöğrenimini İzmir Buca Anadolu Lisesi’nde tamamladı. 2004 yılında girdiği Zonguldak Karaelmas Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümünden, 2005 yılında Pamukkale Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümüne yatay geçiş yaparak 2008 yılında mezun oldu. 2009 yılında İngiltere’de Surrey Üniversitesi Mühendislik ve Fiziksel Bilimler Fakültesi Biyomedikal Mühendisliği Bölümünde yüksek lisansa başladı ve 2010 yılında mezun oldu. 2014 yılından itibaren Zonguldak Bülent Ecevit Üniversitesi Biyomedikal Mühendisliği Bölümü Biyoelektronik Anabilim Dalı’nda araştırma görevlisi olarak çalışmaktadır.

### **ADRES BİLGİLERİ:**

Adres: Zonguldak Bülent Ecevit Üniversitesi, Farabi Kampüsü, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü, İncivez Mahallesi, 67100, Merkez / ZONGULDAK

Tel: (+90) 372 291 19 33

E-posta: crnkaya@hotmail.com