



**T.C.  
RECEP TAYYIP ERDOĞAN ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ  
FİZİK ANABİLİM DALI**

**ARDIŞIL İLERİ ANA DALGACIK SEÇİM YÖNTEMİ  
ÖZNİTELİKLERİ İLE FOTOPLETİSMOGRAFİ  
İŞARETLERİNİN SINIFLANDIRILMASI**

**(Doktora Tezi)**

**Tuğba AYDEMİR**

**Danışman  
Prof. Dr. Mehmet ŞAHİN**

**RİZE  
2023**

## KABUL VE ONAY

Recep Tayyip Erdoğan Üniversitesi, Lisansüstü Eğitim Enstitüsü, Fizik Anabilim Dalında, Prof. Dr. Mehmet ŞAHİN danışmanlığında, Tuğba AYDEMİR tarafından hazırlanan *Ardışıl İleri Ana Dalgacık Seçim Yöntemi Öznitelikleri ile Fotopletismografi İşaretlerinin Sınıflandırılması* adlı bu tez çalışması, 15/12/2022 tarihinde yapılan savunma sınavı sonucunda oy birliğiyle/oy çokluğuyla başarılı bulunarak jürimiz tarafından **Doktora Tezi** olarak kabul edilmiştir.

| Jüri Üyeleri | Unvanı, Adı SOYADI              | İmza |
|--------------|---------------------------------|------|
| Başkan       | : Prof. Dr. Ahmet Hakan YILMAZ  |      |
| Üye          | : Prof. Dr. Mehmet ŞAHİN        |      |
| Üye          | : Prof. Dr. Murat TOMAKİN       |      |
| Üye          | : Doç. Dr. Ayşe Pınar MERT CÜCE |      |
| Üye          | : Dr. Öğr. Üyesi Tuba ÇAKICI    |      |

## **ETİK BEYAN**

Fizik Doktora Programından mezun olmak üzere teslim ettiğim “Ardışıl İleri Ana Dalgacık Seçim Yöntemi Öznitelikleri ile Fotopletismografi İşaretlerinin Sınıflandırılması” adlı tezim, bilim ve araştırma etiği prensiplerine riayet edilerek tarafımdan yazılmıştır.

Tez çalışmamda, başka kaynaklardan aktarılan bütün bilgi ve alıntılar, Enstitünüz Tez Yazım Kılavuzuna uygun olarak açıkça gösterilmiştir. Kaynağı gösterilenler dışında kalan bütün bilgiler uygun araştırma yöntemi kullanılarak tarafımdan edinilmiş ve esere bu şekilde yansıtılmıştır. Şahsıma ait olmayan hiçbir bilgi, kasıt veya kusurlar, şahsıma aitmiş gibi gösterilmemiştir. İnternet kaynakları dâhil, sahibine/kaynağına atıf yapılmaksızın hiçbir bilgi kullanılmamıştır. Aksinin ortaya çıkması halinde doğacak bütün hukuki, idari, akademik ve etik sorumluluk tarafıma ait olacaktır. Eserin tesliminden sonra herhangi bir zamanda, bilim etiğine aykırılık tespit edilmesi ve / veya eserimle ilgili intihal veya intihal şeklinde anlaşılabacak bir durumun ortaya çıkması halinde; Üniversiteniz ve eğitim kadronuzun hiçbir şekilde sorumlu tutulmayacağını hür irademle kabul, beyan ve taahhüt ederim.

15/12/2022

**Tuğba AYDEMİR**

## ÖN SÖZ

Bu çalışma deri yüzeyinden optik bir yaklaşımla kaydedilebilen, tıp ve mühendislik alanında kullanımı giderek artan fotopletismografi işaretlerinin yüksek doğrulukla sınıflandırılmasına imkân veren bir yöntem önermektedir. Fizik, tıp ve mühendislik alanlarını içeren özelliği ile çok disiplinli bir içeriğe sahip bu tez çalışmasının bu alandaki araştırmacılara faydalı olmasını temenni ederim.

Bu çalışmanın bu noktaya gelinceye kadar emeği geçen danışmanım Sayın Prof. Dr. Mehmet ŞAHİN'e en içten saygı ve minnetlerimi sunarım. Yine, tez çalışmalarım süresince değerli zamanlarını ayırıp, bilgi ve deneyimleri ile tezimin kalitesinin artmasına katkı sunan Sayın Prof. Dr. Murat TOMAKİN ve Sayın Doç. Dr. Ayşe Pınar MERT CÜCE'ye sonsuz şükranlarımı belirtmek isterim.

Maddi ve manevi desteğini hiçbir zaman esirgemeyen, bu tez çalışmasına olan motivasyonumu ve gayretimi arttıran değerli eşim Önder AYDEMİR'e ve oğullarım Furkan Alper ve Metehan'a yürekten teşekkürlerimi sunarım.

Tuğba AYDEMİR  
2023/RİZE

## İÇİNDEKİLER

|                                                                             |       |
|-----------------------------------------------------------------------------|-------|
| KABUL VE ONAY .....                                                         | I     |
| ETİK BEYAN.....                                                             | II    |
| ÖN SÖZ .....                                                                | III   |
| İÇİNDEKİLER .....                                                           | IV    |
| TÜRKÇE ÖZET .....                                                           | VI    |
| ABSTRACT.....                                                               | VII   |
| KISALTMALAR.....                                                            | IVIII |
| TABLolar LİSTESİ.....                                                       | X     |
| ŞEKİLLER LİSTESİ .....                                                      | XII   |
| GİRİŞ .....                                                                 | 1     |
| 1. GENEL BİLGİLER .....                                                     | 2     |
| 1.1. Fotopletismografi Sinyallerinin Kullanım Alanları.....                 | 2     |
| 1.2. Optik Kurallar.....                                                    | 2     |
| 1.3. Sinyaller ve Sinyal Çeşitleri .....                                    | 4     |
| 1.4. Fotopletismografi.....                                                 | 5     |
| 1.5. Örüntü Tanıma ve Makine Öğrenmesi .....                                | 8     |
| 1.6. Literatür Özeti.....                                                   | 11    |
| 1.7. Tezin Kapsamı.....                                                     | 13    |
| 2. YAPILAN ÇALIŞMALAR.....                                                  | 15    |
| 2.1. Materyal.....                                                          | 15    |
| 2.1.1. Veri Seti 1 Tanıtımı .....                                           | 15    |
| 2.1.2. Veri Seti 2 Tanıtımı .....                                           | 17    |
| 2.1.3. Veri Seti 3 Tanıtımı .....                                           | 18    |
| 2.2. Yöntem.....                                                            | 20    |
| 2.2.1. Dalgacık Dönüşümü .....                                              | 20    |
| 2.2.2. Öznitelik Çıkarma Yöntemleri .....                                   | 23    |
| 2.2.3. $k$ -En Yakın Komşuluk Sınıflandırıcısı .....                        | 25    |
| 2.2.4. Sınıflandırıcı Eğitimi .....                                         | 28    |
| 2.2.5. Ardışıl İleri Ana Dalgacık Seçim Yöntemi ile Öznitelik Çıkarma ..... | 29    |
| 3. BULGULAR.....                                                            | 32    |
| 3.1. Veri Seti 1 için Elde Edilen Bulgular .....                            | 32    |

|                                                  |     |
|--------------------------------------------------|-----|
| 3.2. Veri Seti 2 için Elde Edilen Bulgular ..... | 40  |
| 3.3. Veri Seti 3 için Elde Edilen Bulgular ..... | 44  |
| 4. TARTIŞMA VE SONUÇLAR .....                    | 578 |
| KAYNAKÇA.....                                    | 64  |



**Recep Tayyip Erdoğan Üniversitesi Lisansüstü Eğitim Enstitüsü**

**Ana Bilim Dalı** : Fizik

**Tez Türü** : Doktora

**Danışman** : Prof. Dr. Mehmet ŞAHİN

**Hazırlayan** : Tuğba AYDEMİR

**Yıl** : 2022

**Sayfa Sayısı** : 70

## **ÖZET**

### **ARDIŞIL İLERİ ANA DALGACIK SEÇİM YÖNTEMİ ÖZNİTELİKLERİ İLE FOTOPLETİSMOGRAFİ İŞARETLERİNİN SINIFLANDIRILMASI**

Mikro-vasküler doku yatağındaki kan hacmi değişikliklerini saptamak için kullanılan, acı vermeyen, basit, düşük maliyetli ve müdahalesiz optik bir yöntem olan fotopletismografi (PPG) tıp ve mühendislik alanında kullanımı giderek artış gösteren fizyolojik verilerden bir tanesidir. Özellikle örüntü tanıma ve makine öğrenmesi algoritmalarındaki gelişmeler bu sinyallere dayalı uygulamalara olan ilgiyi daha da arttırmıştır. PPG sinyalleri kullanılarak; kalp ve tansiyon rahatsızlıkları, stres seviyesi, kişi tanıma ve yorgunluk tespiti gibi yöntemler önerilmektedir. Bu çalışmalar daha çok iki sınıflı problemleri ele alarak yeni öznetelik çıkarma yaklaşımları sunmaktadır. Elde edilen sonuçlar görece başarılı olsa da halen daha geliştirilmeye açık performans seviyelerindedir. Bu tez çalışmasında ardışıl ileri ana dalgacık seçimi yöntemi öznetelikleri ile PPG işaretlerinin yüksek performans ile sınıflandırılması önerilmiştir. Önerilen yöntemin geçerliliği ve kararlılığı 3 ayrı PPG veri setine uygulanmıştır. Öznetelikler, belirlenen ana dalgacıklarla elde edilen dalgacık dönüşümü katsayılarının standart sapması ve ortalama değerleri hesaplanarak elde edilmiştir. Daha sonra elde edilen öznetelikler  $k$ -en yakın komşuluk yöntemi ile sınıflandırılmıştır. Önerilen yöntem ile Veri Seti 1 (zihinsel iş yükü seviyesinin belirlenmesi), Veri Seti 2 (hipertansiyon hastalığının belirlenmesi) ve Veri Seti 3 (insan faaliyet izleme) için sırasıyla ortalama %65,76, %73,39 ve %86,54 sınıflandırma doğruluklarına ulaşılmıştır. Elde edilen sonuçlar önerilen yöntemin PPG işaretlerini sınıflandırmada önemli potansiyelinin olduğunu göstermiştir.

**Anahtar Kelimeler:** Fotopletismografi, Öznetelik Çıkarma, Dalgacık Dönüşümü

**Recep Tayyip Erdogan University Institute of Graduate Studies**

**Department** : Physics  
**Thesis Type** : Doctorate  
**Supervisor** : Prof. Dr. Mehmet ŞAHİN  
**Author** : Tuğba AYDEMİR  
**Year** : 2022  
**Pages** : 70

## **ABSTRACT**

### **CLASSIFICATION OF PHOTOPLETHYSMOGRAPHY SIGNALS USING FEATURES OF SEQUENTIAL FORWARD MOTHER WAVELET SELECTION METHOD**

Photoplethysmography (PPG), a painless, simple, low-cost and non-invasive optical method used to detect blood volume changes in the vascular tissue bed, is one of the physiological data that is increasingly used in medicine and engineering. Especially the developments in pattern recognition and machine learning algorithms have increased the interest in applications based on these signals. By using PPG signals, methods such as heart and blood pressure disorders, stress level, person recognition and fatigue detection are suggested. These studies offer new feature extraction approaches by dealing mostly with two-class problems. Although the results obtained are relatively successful, they are still at performance levels that are open to improvement. In this thesis, it is proposed to classify PPG signals with high performance with sequential forward main wavelet selection method features. The validity and stability of the proposed method was applied to 3 separate PPG datasets. The features were obtained by calculating the standard deviation and average values of the wavelet transform coefficients obtained with the determined main wavelets. Then, the obtained features were classified using the k-nearest neighborhood method. The proposed method achieved average classification accuracies of 65,76%, 73,39%, and 86,54% for Data Set 1 (determination of mental workload level), Data Set 2 (detection of hypertension disease), and Data Set 3 (human activity monitoring), respectively. The obtained results showed that the proposed method has significant potential in classifying PPG signals.

**Keywords:** Photoplethysmography, Feature Extraction, Wavelet Transform



## KISALTMALAR

|               |   |                                     |
|---------------|---|-------------------------------------|
| AİADS         | : | Ardışıl İleri Ana Dalgacık Seçim    |
| B             | : | Basıklık                            |
| BG            | : | Band Gücü                           |
| coif          | : | Coiflet                             |
| Ç             | : | Çarpıklık                           |
| D             | : | Dalgacık                            |
| db            | : | Daubechies                          |
| DD            | : | Dalgacık Dönüşümü                   |
| DSDS          | : | Doğru Sınıflandırılan Deneme Sayısı |
| EEG           | : | Elektroansefalogram                 |
| EKDS          | : | Eğitim Kümesi Deneme Sayısı         |
| EKG           | : | Elektrokardiyografi                 |
| FD            | : | Fourier Dönüşümü                    |
| GN            | : | Genlik Normalizasyonu               |
| Hz            | : | Hertz                               |
| İ             | : | İterasyon                           |
| <i>k</i> -EYK | : | <i>k</i> -En Yakın Komşuluk         |
| LED           | : | Light-Emitting Diode                |
| mexh          | : | Meksika Şapkası                     |
| meyr          | : | Meyer                               |
| morl          | : | Morlet                              |
| OD            | : | Ortalama Değeri                     |
| Ort           | : | Ortalama                            |
| Ö             | : | Ölçek                               |
| PPG           | : | Fotopletismografi                   |
| rPPG          | : | Remote Fotopletismografi            |
| SD            | : | Sınıflandırma Doğruluğu             |
| shan          | : | Shannon                             |
| sn            | : | Saniye                              |
| SSD           | : | Standart Sapma Değeri               |

SSN : Standart Sapma Normalizasyonu  
sym : Symlet  
TDS : Toplam Deneme Sayısı  
TKDS : Test kümesi deneme sayısı  
VS1 : Veri Seti 1  
VS2 : Veri Seti 2  
VS3 : Veri Seti 3



## TABLÖLAR LİSTESİ

|                                                                                            |    |
|--------------------------------------------------------------------------------------------|----|
| <b>Tablo 1.</b> Her bir görev için toplam deneme sayıları.....                             | 17 |
| <b>Tablo 2.</b> Kaydedilen verilerin uzunluğu.....                                         | 19 |
| <b>Tablo 3.</b> Kullanılan eğitim kümesi deneme sayısı ve test kümesi deneme sayısı.....   | 20 |
| <b>Tablo 4.</b> 6 sn'lik PPG verilerine ait AİADS sonuçları.....                           | 33 |
| <b>Tablo 5.</b> 8 sn'lik PPG verilerine ait AİADS sonuçları.....                           | 34 |
| <b>Tablo 6.</b> 10 sn'lik PPG verilerine ait AİADS sonuçları.....                          | 35 |
| <b>Tablo 7.</b> VS2 için elde edilen AİADS sonuçları .....                                 | 41 |
| <b>Tablo 8.</b> S1 kişinin 1 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....      | 45 |
| <b>Tablo 9.</b> S1 kişinin 2 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....      | 45 |
| <b>Tablo 10.</b> S1 kişinin 3 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 45 |
| <b>Tablo 11.</b> S2 kişinin 1 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 46 |
| <b>Tablo 12.</b> S2 kişinin 2 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 46 |
| <b>Tablo 13.</b> S2 kişinin 3 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 46 |
| <b>Tablo 14.</b> S3 kişinin 1 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 47 |
| <b>Tablo 15.</b> S3 kişinin 2 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 47 |
| <b>Tablo 16.</b> S3 kişinin 3 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 48 |
| <b>Tablo 17.</b> S4 kişinin 1 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 48 |
| <b>Tablo 18.</b> S4 kişinin 2 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 49 |
| <b>Tablo 19.</b> S4 kişinin 3 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 49 |
| <b>Tablo 20.</b> S5 kişinin 1 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 50 |
| <b>Tablo 21.</b> S5 kişinin 2 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 50 |
| <b>Tablo 22.</b> S5 kişinin 3 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 50 |
| <b>Tablo 23.</b> S6 kişinin 1 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 51 |
| <b>Tablo 24.</b> S6 kişinin 2 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 52 |
| <b>Tablo 25.</b> S6 kişinin 3 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 52 |
| <b>Tablo 26.</b> S7 kişinin 1 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 53 |
| <b>Tablo 27.</b> S7 kişinin 2 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 53 |
| <b>Tablo 28.</b> S7 kişinin 3 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları .....     | 54 |
| <b>Tablo 29.</b> VS3'ün ortalama AİADS sonuçları .....                                     | 54 |
| <b>Tablo 30.</b> 1 sn'lik pencere uzunluğu duruma ait band gücü öznelilikleri sonuçları .. | 55 |

|                                                                                              |  |
|----------------------------------------------------------------------------------------------|--|
| <b>Tablo 31.</b> 2 sn'lik pencere uzunluđu duruma ait band g c   znitelikleri sonu ları ..55 |  |
| <b>Tablo 32.</b> 3 sn'lik pencere uzunluđu duruma ait band g c   znitelikleri sonu ları ..56 |  |
| <b>Tablo 33.</b> 1 sn'lik pencere duruma ait istatistiksel  zniteliklerin sonu ları.....56   |  |
| <b>Tablo 34.</b> 2 sn'lik pencere duruma ait istatistiksel  zniteliklerin sonu ları.....57   |  |
| <b>Tablo 35.</b> 3 sn'lik pencere duruma ait istatistiksel  zniteliklerin sonu ları.....57   |  |



## ŞEKİLLER LİSTESİ

|                                                                                                   |    |
|---------------------------------------------------------------------------------------------------|----|
| Şekil 1. 6 kanallı PPG sistemi .....                                                              | 6  |
| Şekil 2. Yansıyan ışığın yakalanması ile elde edilen PPG sistemi .....                            | 7  |
| Şekil 3. Geçen ışığın yakalanması ile elde edilen PPG sistemi.....                                | 7  |
| Şekil 4. PPG ve EKG işaretlerinin senkronizasyonu.....                                            | 8  |
| Şekil 5. Örüntü tanıma ve makine öğrenmesi döngüsü .....                                          | 8  |
| Şekil 6. İş yüklerinin süre ve sırası .....                                                       | 16 |
| Şekil 7. Örnek PPG işaretleri: a) 0-geri, b) 2-geri, c) 3-geri görev .....                        | 16 |
| Şekil 8. VS2 için örnek PPG verisi.....                                                           | 17 |
| Şekil 9. Deney prosedürü.....                                                                     | 18 |
| Şekil 10. PPG denemesi örnekleri, (a) dinlenme durumu, (b) skuat hareketi, (c) step hareketi..... | 19 |
| Şekil 11. Sık kullanılan bazı ana dalgacık çeşitleri .....                                        | 23 |
| Şekil 12. Makine öğrenmesi modelinin aşamaları.....                                               | 26 |
| Şekil 13. k-EYK'nın genel işleyişi .....                                                          | 27 |
| Şekil 14. Birini-dışarıda-bırak çapraz onaylama modeli .....                                      | 29 |
| Şekil 15. Ardışıl ileri ana dalgacık seçim yöntemi akış şeması.....                               | 30 |
| Şekil 16. 6 sn'lik PPG verileri için artış oranları.....                                          | 32 |
| Şekil 17. 8 sn'lik PPG verileri için artış oranları.....                                          | 36 |
| Şekil 18. 10 sn'lik PPG verileri için artış oranları.....                                         | 36 |
| Şekil 19. İstatistiksel özniteliklerin 6 sn'lik segment sonuçları .....                           | 37 |
| Şekil 20. İstatistiksel özniteliklerin 8 sn'lik segment sonuçları .....                           | 37 |
| Şekil 21. İstatistiksel özniteliklerin 10 sn'lik segment sonuçları .....                          | 38 |
| Şekil 22. Band gücü özniteliklerin 6 sn'lik segment sonuçları .....                               | 39 |
| Şekil 23. Band gücü özniteliklerin 8 sn'lik segment sonuçları .....                               | 39 |
| Şekil 24. Band gücü özniteliklerin 10 sn'lik segment sonuçları .....                              | 40 |
| Şekil 25. Band geçiren filtreye dayalı akış şeması .....                                          | 41 |
| Şekil 26. Band geçiren filtre .....                                                               | 42 |
| Şekil 27. k-EYK için olası tüm band geçiren filtreleme sonuçları .....                            | 43 |
| Şekil 28. VS2 için istatistiksel öznitelik sonuçları .....                                        | 44 |

## GİRİŞ

Fizik, maddenin yapısını, enerji ile ilişkisini, uzay-zaman boyunca davranışını inceleyen, gözlem, deney ve ölçümlere dayalı bir doğa bilimidir. Fizik bilimi, doğa bilimlerinin temeli olarak kimya, biyoloji, tıp, mühendislik, teknoloji gibi birçok disiplinle ilişki içinde olan bir çalışma sahasıdır. Oldukça geniş bir çalışma alanına sahip olan fizik biliminin 8 ana alt dalı vardır. Bu alt dallar; mekanik, optik, termodinamik, çekirdek fiziği, atom ve molekül fiziği, yüksek enerji ve plazma fiziği, katıhal fiziği, ve elektromanyetizmadır. Işığın hayatımızda önemli bir yere sahip olmasından dolayı optik bu dallar içerisinde önemli bir yer tutar. Çünkü optik; ışığı, ışık olaylarını ve ışığın madde ile etkileşimini inceleyen fizik bilimimin bir kolu olarak tıptan mühendisliğe, biyolojiden kimyaya ve haberleşme sistemlerine kadar çok geniş bir kullanım alanına sahiptir. Örneğin, optik bilgisiyyle üretilen gözlükler birçok insanın yaşam kalitesini arttırırken, optik araçlardan biri olan aynalar günlük hayatımızın vazgeçilmezlerindendir. Optiğin karşımıza çıkan bir diğerk kullanım alanı ise optik haberleşme sistemidir. Bu sistemde elektronik sinyaller ışığa dönüştürölerek verileri bir fiber üzerinden iletmek için ışık dalgası teknolojisi kullanılır. Bu cihazlar optiğin yansıma, geçirme, soğurma gibi özellikleri kullanılarak tasarlanmıştır. Yine optik bilgisiyyle üretilen mikroskop, röntgen cihazları, bilgisayarlı tomografi cihazı tıpta tanı ve teşhis alanında oldukça yaygın olarak kullanılmaktadır. Gözle görölmemeyen kızılötesi ışık dalgalarının maddeden yansıma ve geçirgenlik özellikleri kullanılarak geliştirilmiş fotopletismografi (PPG) tekniğinin kullanımı da bazı hastalıkların tanı ve teşhisi için giderek yaygınlaşmaktadır.

## 1. GENEL BİLGİLER

### 1.1. Fotopletismografi Sinyallerinin Kullanım Alanları

Günümüzün baş döndürücü gelişmeleri arasındaki sensör teknolojileri ile elde edilen büyük verinin örüntü tanıma ve makine/derin öğrenmesi algoritmaları ile işlenmesi son on yılın en popüler konuları arasında ön plana çıkmaktadır. Öyle ki; bu algoritmalar finanstan, eğitime, spordan tarıma, tıptan mühendisliğe kadar birçok alanda kullanılarak akıllı sistemler üretilmektedir. PPG sinyalleri ile örüntü tanıma ve makine öğrenmesi algoritmaları ile yapılan çalışmaların sayısı da literatürde giderek artmaktadır. Yine bu sinyaller (PPG) kullanılarak kalp ve tansiyon rahatsızlıkları, stres seviyesi tespiti, biyometri çalışmaları ve yorgunluk tespiti gibi yöntemler önerilmektedir.

### 1.2. Optik Kurallar

Güneş, bulunduğu Samanyolu galaksisindeki neredeyse tüm gezegenlerin doğal ışık kaynağıdır. Güneşin yüzeyindeki sıcaklık ve sürekli gerçekleşen reaksiyonlar sayesinde ‘foton paketi’ olarak bilinen ve dünyamıza kadar ulaşan enerjisine, ışık ya da görünür ışık adı verilir. Işık yani elektromanyetik dalga, görülebilen ya da görülemeyen ışık olarak da tabir edilir. Tüm bu ışık türlerini içeren sınıflandırma çizelgesine Elektromanyetik tayf (spektrum) denir. Elektromanyetik tayf, atom altı uzunluklardan binlerce kilometre uzunluklara kadar çok geniş dalga boylarındaki ışıınımları kapsayan bir ölçektir. Elektromanyetik spektrum başlıca yedi kategoride incelenir. Bunlar yüksek frekanstan düşük frekansa doğru; Gama ışınları, X-ışınları, Mor ötesi, Görünür ışık, Kızılötesi, Mikrodalga ve Radyo dalgalarıdır.

Elektromanyetik dalganın Spektrumdaki yerini, dalganın frekansı veya dalga boyu belirler. Dalga boyu ( $\lambda$ ) tekrarlayan iki dalga tepesi veya dalga çukuru arasındaki mesafeyi, frekans ( $\nu$ ) ise herhangi bir noktadan bir saniyede geçen dalga sayısını tanımlamaktadır. Bu sebeptir ki frekans ve dalga boyu ters orantılıdır. Öyleyse elektromanyetik dalganın frekansı arttıkça enerjisi de artar. Farklı frekansa sahip elektromanyetik dalgalar farklı özelliklere sahiptir. Bu özelliklerin farklılığı nedeniyle kullanım alanları da değişmektedir.

Radyo Dalgaları: Radyo dalgaları elektromanyetik spektrumda, en küçük frekansa yani en büyük dalga boyuna sahip elektromanyetik dalgalardır. Düşük

frekanslarından dolayı taşıdıkları enerji de düşüktür. Bu yüzden sağlığa olumsuz etkileri yok denecek kadar azdır. Dalga boyları yaklaşık olarak 1mm ile 100 km'den fazla bir alan aralığına uzanırken frekansı 300 gigahertz (GHz) ile 30 Hertz (Hz) aralığındadır.

**Mikrodalga:** Mikrodalga kelimesi dalga boyunun 1m'den kısa olduğu elektromanyetik dalgaları tanımlar. Frekansı 300 megahertz (MHz)~100cm ile 300 gigahertz (GHz)~0.1cm arasında değişen, yüksek frekanslı düşük dalga boylu elektromanyetik dalgalardır. Frekans arttıkça birim zamanda taşınan bilgi de arttığı için mikrodalgalar uydularla iletişimde ve Radar teknolojilerinde kullanılmaktadır.

**Kızılötesi (Infrared veya IR):** Kızılötesi ışınlar, Elektromanyetik spektrumda Mikrodalga ile Görünür Bölge arasındadır. Kızılötesi ışığın dalga boyu 750 nanometre ile 1 mikrometre arasında, frekansı ise 430 THz-300GHz arasındadır. Bu dalga boyunda ki Kızılötesi dalgaları insan gözü görünmez, çünkü insan gözünde ki görme hücreleri 400 - 700 nanometre arasına duyarlıdır. Tüm elektromanyetik dalgalar gibi kızılötesi ışık da hem dalga hem de parçacık (foton) özelliği gösterir. Güneş'ten dünyamıza gelen toplam enerjinin yarıdan fazlası, infrareddir. Bu ışımlar atomlar tarafından emildiklerinde maddeyi ısıttıkları için ısı radyasyonu olarak da isimlendirilirler.

Infrared, vücut dokularının 1 cm derinliğine kadar nüfuz edebilme özelliği ile tıpta bazı hastalıkların teşhis ve tanısında kullanılır.

**Görünür Bölge (Işık):** Elektromanyetik spektrumda insan gözünün görebildiği aralığı tanımlayan görünür bölgenin dalga boyu aralığı yaklaşık 380-700 nanometredir. Görünür bölgede gördüğümüz renkler, sırasıyla gökkuşağında gördüğümüz renklerdir. İnsan gözü, elektromanyetik spektrumun yaklaşık yüzde 0.0035'lik bir kısmını görebilmektedir.

**Morötesi:** Morötesi ya da kısaca ultraviyole (UV) radyasyon, dalga boyu 100-400 nm arasındaki ışınlardır. Işığın bu küçük dalga boyu yani yüksek enerjisi insan hücrelerine nüfuz edebilir ve DNA molekülüne zarar verebilir. Ultraviyole radyasyonun ana kaynağı Güneştir ve Güneş ışığında %7 Morötesi, %48 Kızılötesi, %44 Görünür ışık vardır.

**X-Işınları:** Alman fizikçi Wilhelm Röntgen tarafından keşfedilen X-ışınları yüksek oranda enerji taşıyan elektromanyetik radyasyondur. Dalga boyları 0.01-10 nm



arasındadır. Sahip olduđu küçük dalga boyu yani yüksek enerjisi sayesinde insan vücudu da dâhil birçok cisimden geçebilir. Tıpta X-ışınları, vücuttaki doku ve yapıları görüntülemekte ve bazı hastalıkların teşhis ve tedavisinde kullanılmaktadır.

Gama Işınları: 10 pikometre dalga boyuna sahip Gama ışınları çok yüksek enerjiye sahiptirler. Uzayda gerçekleşen nükleer tepkimelerin sonucunda üretilirler. Çok yüksek frekansa sahip olmalarından dolayı metallere ve beton engellerden bile kolaylıkla geçebilir ve hücrelere büyük zararlar verebilirler. Maddeye oldukça kolay nüfuz edebilme özelliğinden dolayı tıpta kanser gibi çeşitli hastalıkların tedavisinde kullanılmaktadır.

### 1.3. Sinyaller ve Sinyal Çeşitleri

Tarihsel olarak bir sinyal, iletilen herhangi bir işaret, sembol veya fiziksel el hareketi, bilgi veya mesaj anlamına geliyordu. İlk elektronik bilgi iletimi, mors kodu idi. Sinyaller insan üretimi olduđu gibi doğal fiziksel sistemler de sinyal üretir. Günlük yaşamımız sinyallerle doludur. Örneğin zaman içinde sıcaklığın değişimi, bu değişim çevremiz hakkında birtakım bilgiler verir. Matematiksel olarak sinyal; bir fiziksel olayda bağımsız değişkeni genelde zaman olan ve bu nedenle zaman içinde belli bir kurala göre (deterministik) ya da belli bir kurala göre tanımlanamayan (rastgele) değerler dizisidir. Deterministik sinyaller, bir fiziksel olayda mevcut olan bağımsız değişkenler arasındaki ilişkiyi matematiksel bir fonksiyon olarak ifade edilebilirken, rastgele sinyaller belirli bir kurala göre oluşmadıklarından bunlar matematiksel bir fonksiyon olarak ifade edilemez ancak bunlara belirli bir hataya sahip fonksiyonlar uydurulabilir.

Zamanın her anı için bir değeri olan sinyallere ‘analog veya sürekli sinyaller’ denilirken, zamanın sadece belirli anları için bir değere sahip olan sinyallere ise ‘dijital veya ayrık sinyaller’ denilir. Bir örnek vermek gerekirse doğadaki sesler veya insan vücudundaki nöral aktivite, kalp basıncı değişimi veya damarlardaki kan hacmi değişimi sürekli sinyallere örnek olarak verilebilir. Bu örneklerden hareketle, söz konusu bu sinyaller kaydedilmek istenirse bugünkü teknoloji ile dijital kaydetme cihazları olan ses kayıt cihazı, elektroensefalogram, elektrokardiyogram (EKG), elektromiyogram ve PPG kullanılmaktadır. Bu cihazlar analog sinyallerin belirli zaman aralıklarındaki genlik değerlerini ayrık sinyal biçiminde kaydederler. Bu işleme

örnekleme denilir ve örnekleme frekansı parametresi ile örnekleme zaman sıklığı ayarlanır.

Nyquist kriterine göre, bir analog sinyaldeki temel bilgi kaybolmadan ayrık sinyal halinde kaydedilebilmesi için söz konusu sinyalin sahip olduğu en yüksek frekans bileşeninin en az iki katı frekansında örnekleme gerekmektedir. Örneğin;  $x(t)=\cos(2\pi 50t)+\sin(2\pi 100t)+3\cos(2\pi 250t)$  gibi bir sürekli sinyalin frekans bileşenleri 50 Hz, 100 Hz ve 250 Hz'dir. En yüksek frekans bileşeni 250 Hz olduğu için Nyquist kriterine göre örnekleme frekansı en az 500 Hz olmalıdır. Bu sınır sürekli sinyaldeki temel bilgiyi kaybetmekle tutmak arasında adeta bıçak sırtı bir değer olduğu için gerçekleştirilecek uygulamanın hassasiyetine bağlı olarak örnekleme frekansı çok daha yüksek seçilmelidir.


Sinyallerin kendi örüntülerini tekrar edip etmeme durumlarına göre ise sinyaller 'periyodik' ve 'periyodik olmayan' sinyaller olarak ikiye ayrılır. Periyodik sinyaller bir T zamanında bir kendi formunu aynen tekrarlarlar ve  $x(t)=x(t+T)$  olarak gösterilirler. Periyodik sinyallere  $x(t)=\sin(2\pi 10t)$  verilebilir. Böyle bir sinyalin frekansı 10 Hz'dir ve frekans periyot arasındaki  $f=1/T$  ilişkisi kullanılarak  $T=0.1$  sn'de bir bu sinyalin kendi örüntüsünü tekrar ettiği bulunabilir. Doğadaki sesler ve insandan kaydedilen sinyaller gibi kendi formunu hiçbir zaman tekrar etmeyen sinyaller ise periyodik olmayan sinyaller olarak tanımlanır. Burada şunun altını çizmek gerekir ki; bir EKG veya PPG sinyali ilk bakışta kendini aynen tekrar eden tepecikler dizisi olarak görülse de özünde her bir kalp atışında ortaya çıkan EKG/PPG sinyal parçacıkları %100 oranında birbirinin aynı değildir. Bu bakımdan EKG/PPG sinyalleri de periyodik olmayan sinyaller grubundadır.

#### 1.4. Fotopletismografi

PPG, mikro-vasküler doku yatağındaki kan hacmi değişikliklerini saptamak için kullanılabilen, acı vermeyen, basit, düşük maliyetli ve müdahalesiz (cerrahi müdahale gerektirmeyen) optik bir tekniktir. PPG işaretlerinin ölçüm kolaylığı ve bunlardan elde edilen verilerin çeşitliliği gibi sağladığı avantajlardan dolayı biyomedikal uygulamalarda kullanımı giderek yaygınlaşmaktadır. Öyle ki, nabız oksimetreler ve kan basıncı (nabız) ölçümü yapan PPG tabanlı cihazlar ticari olarak piyasada mevcuttur. PPG tekniği, genel olarak kırmızı ya da yakın kızılötesi dalga boyunda ışık yayan diyot (*ing.* Light Emitting Diode, LED) ve fotodedektör kullanan,


oldukça sade opto-elektronik bir donanım içeriğine sahiptir (de Trefford ve Lafferty, 1984; Jonathan ve Leahy, 2010). En yaygın bilgiyi her kalp atımı ile senkronize bir şekilde ortaya çıkan periferik nabız (cildin üst kısmına yakından geçen ve altında kemiklerin bulunduğu damarlardan alınan nabız) sinyal örüntüsünü vererek sağlar. Bununla beraber kardiyovasküler sisteme ait değerli bilgiler taşıdığı ve bu bilgileri örüntü tanıma ve makine öğrenmesi teknikleri ile ortaya çıkarılabileceği de kabul edilmektedir (Rodriguez-Labra vd., 2021; Kinnunen vd., 2020).

LED ile vücudun ilgili bölgesine  $\lambda$  dalga boyunda ışık gönderilerek yansıyan ya da geçen ışığın fotodedektörle elde edilmesiyle PPG işareti oluşur. Bu modelin çalışabilmesi için vücutta bir çıkıntıya sahip uzuv kullanılması gerekir. Bu açıdan en uygun uzuvlar Şekil 1’de de gösterildiği gibi el parmakları, kulak memesi ve ayak parmaklarıdır. Bu şekil aynı zamanda 6 kanallı bir PPG sistemini de temsil etmektedir.




**Şekil 1.** 6 kanallı PPG sistemi

Şekil 2’de yansıyan ışığı, Şekil 3’te ise uzuvdan geçen ışığı yakalayan fotodedektör ile PPG işaretlerinin elde edilişi gösterilmiştir. Tipik bir PPG işaretinin 3 temel bileşeni vardır: **1)** ışığın ilk önce karşılaştığı deri, kas ve kemikten geçen büyük bir DC (doğru akım, 0 Hz frekansında) bileşen, **2)** damarlardan geçen küçük bir AC (alternatif akım,  $>0$  Hz frekansında) bileşen, **3)** arteriyel kan damarından (atar damar) da geçen ışıktan meydana gelen kalp atımının frekans bileşenidir.




**Şekil 2.** Yansıyan ışığın yakalanması ile elde edilen PPG sistemi



**Şekil 3.** Geçen ışığın yakalanması ile elde edilen PPG sistemi


Geçen ışığın yakalanmasına dayalı sistemde kalbin sistolik hareketinde (Kalbin kasılması, kalpten damara doğru pompalanan kanın damar duvarında yaptığı basınç, “büyük tansiyon”) atardamarlardaki kan miktarı artar ve daha az ışık iletilir. Bu hareketin tersi olan kalbin diyastolik anında (Kalbin gevşemesiyle damarda kalan basınç, “küçük tansiyon”) damarlardaki kan miktarı azalacağından ışık iletiminde de bir artış söz konusu olur. Anlaşılabacağı üzere PPG işaretindeki değişimin temel kaynağı kalbin sistolik ve diyastolik hareketidir. Bundan dolayı PPG işaretleri, EKG işaretleri ile Şekil 4’te gösterildiği gibi senkronizasyon (eşzamanlama) göstermektedir.



Şekil 4. PPG ve EKG işaretlerinin senkronizasyonu (eşleme)

### 1.5. Örüntü Tanıma ve Makine Öğrenmesi

Oldukça yaygın kullanımı olan örüntü tanıma (*ing.* pattern recognition) ve makine öğrenmesi (*ing.* machine learning) yöntemleri günümüzde başta tıp (Emmert-Streib ve Dehmer, 2019; Fatima ve Pasha, 2017; Cabitza vd., 2017) ve mühendislik (Tozlu vd., 2021; Aydemir vd., 2020a; Gaur vd., 2021) olmak üzere finans (Wie vd., 2021) ve tarım (Raj vd., 2015; Liakos vd., 2018) gibi birçok alanda önemli bir araç haline gelmiştir. Bu yöntemler özellikle üretim (Osswald vd., 2020), güvenlik (Kourtiti vd., 2021), teşhis (Elaziz vd., 2020; Myszczyńska vd., 2020; Tanveer vd., 2020) ve tedavi (Chu vd., 2020) konularında kullanıcılarına birçok kolaylık ve zamandan tasarruf sağlamaktadır. Örüntü tanıma ve makine öğrenmesi döngüsü genel olarak Şekil 5’te gösterildiği gibi dört bloktan oluşmaktadır.



Şekil 5. Örüntü tanıma ve makine öğrenmesi döngüsü

Sinyalin alınması aşamasında kamera, elektrot ve sensör gibi almaçlarla uygulamanın girdisini oluşturacak sinyaller kaydedilir. Bu aşamada kullanılacak kayıt cihazının özellikleri, örnekleme frekansı ve toplam deneme kaydı (veri seti büyüklüğü) sayısı önemli parametrelerdir. Örnekleme frekansı, analog bilgiyi sayısal işaret işlemenin yapılabilmesi için dijital forma dönüştürmek amacıyla dikkate alınan bir

parametredir ve her bir saniyede elde edilmiş veri noktalarının/görüntülerinin sayısı olarak tanımlanır. Örneğin, bir EKG işaretinin 10 Hz'lik bir örnekleme frekansı ile kaydedilmesi, analog EKG işaretinin 1 saniyelik kısmından eşit aralıklar ile (verilen bu örnek için 0,1 saniye) 10 veri noktası kaydedilmesi anlamına gelmektedir. Örnekleme frekansı yüksek olduğunda bir yandan analog işaretin içerdiği bilgi o denli az kayıpla kaydedilmiş olurken, diğer yandan aşırı veri depolanması ile hesaplama karmaşıklığı ve süresi artar. Tam tersi durumda yani örnekleme frekansı düşük olduğunda analog işaretin içerdiği bilgi o denli kayıplı olarak kaydedilirken, veri düşük boyutlu olacağından hesaplama süresi nispeten kısa olacaktır. Böyle bir ikilemli durumda “en uygun örnekleme frekansı ne olmalıdır?” sorusu akıllara gelmektedir. Bunun net bir cevabının olmadığı literatürdeki uygulamalardan da görüldüğü gibi ele alınan uygulamanın hassasiyetine (duyarlılığına) ve ilgilenilen işaret türünün frekansına bağlıdır. Nyquist örnekleme kuramı, işaretin içerdiği en yüksek frekans bileşeninin en azından 2 katının örnekleme frekansı olarak seçilmesi gerektiğini söylerken, bu seviye verinin içerdiği bilginin önemli bir parçasının kaybedilmesi ile kaybedilmemesi arasında bir sınır değeridir. Bu açıdan değerlendirildiğinde örnekleme frekansının en azından Nyquist örnekleme kuramının belirlediği değerden daha yüksek seçilmesi gerektiği ortaya çıkmaktadır.

Sinyalin alınması aşamasındaki diğer parametre olan toplam deneme kaydı sayısı ise makine öğrenmesi modelinin kararlılığı açısından önemlidir. Yeterli deneme kaydı yapılmadığı durumda gürültülü ya da küçük değişikliklere uğramış deneme kayıtları doğru sınıflandırılmaz. Veri setinin büyüklüğü, eğitim ve test kümelerine ayrılmış veri setinin defalarca makine öğrenmesi aşamasına tabi tutulup ortalama sınıflandırma doğruluğu ve bunların standart sapmasının hesaplanmasıyla anlaşılabilir. Literatürde standart sapma değerinin %5'in altında olması kararlı bir sınıflandırma modeli için yeterli görülmüştür (Tozlu vd., 2021; Aydemir vd., 2021).

Önişleme, yaygın olarak normalizasyon, filtreleme veya gürültü azaltma amacıyla uygulanan bir aşama olup, her zaman uygulanmayabilir. En sık uygulanan normalizasyon teknikleri sırasıyla Eşitlik 1 ve Eşitlik 2'de verilen [0-1] normalizasyonu olarak da bilinen genlik normalizasyonu (GN) ve standart sapma normalizasyonudur (SSN).

$$GN = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (1)$$

$$SSN = \frac{x_i - \mu_x}{\sigma_x} \quad (2)$$

Bu eşitliklerde  $x_i$ ;  $x$  sinyalinin  $i$ . ( $i=1, 2, 3...$ ) değerini,  $x_{min}$ ;  $x$  sinyalinin en küçük değerini,  $x_{max}$ ;  $x$  sinyalinin en büyük değerini,  $\mu_x$ ;  $x$  sinyalinin ortalama değerini ve  $\sigma_x$ ;  $x$  sinyalinin standart sapmasını göstermektedir. Bu tekniklerinden [0-1] normalizasyonu denemelere girişim yapan DC değerin neden olduğu aşırı genlik yükselmesi veya düşmesini engellemek amacıyla uygulanır. Aksi durumda aynı sınıfa ait denemelerden çıkarılan öznitelikler çok farklı bölgelerde kümelenmeler gösterir ki bu da sınıflandırma performansını düşürür. Benzer şekilde standart sapma normalizasyonu da işaretlere bulaşan gürültüden dolayı işaretlerin standart sapmalarının denemeler arasında çok büyük farklılıklar arz eder. Bu durum [0-1] normalizasyonunda olduğu gibi öznitelik uzayının farklı bölgelerde küme öbekleri içermesine neden olur ve sınıflandırma performansını düşmesine sebebiyet verir.

Önişleme tekniklerinden olan filtreleme (süzgeçleme) ise hem gürültü bertaraf etme hem de arzu edilen frekans bölgesindeki bilgiye odaklanma amaçları ile gerçekleştirilir. Örneğin EEG işaretlerinde klinik uygulamalar 0-30 Hz arasını inceler (Zhang vd., 2021). Bunun için bir alçak geçiren süzgeç kullanılarak 30 Hz'in üzerindeki frekans bileşenleri sinyalden atılır. Başka bir uygulamada ise EEG işaretlerinin (8-12 Hz) bölgesine odaklanılabilir (Dou vd., 2022). Bu durumda da band geçiren süzgeç kullanılarak sadece ilgili frekans bölgesi sinyalde tutulurken diğer bileşenler atılabilir.

Öznitelik çıkarma, farklı sınıflar için kaydedilen işaretlerin ayırt edici özelliklerinin çıkarılıp, öznitelik vektörünün elde edilmesi işlemidir. Bu aşama veri analiz sisteminin önemli ve kritik bir aşamasıdır. Çünkü çıkarılan özniteliklerin kullanışlılığı direkt olarak sınıflandırıcının performansını, dolayısıyla da teşhis sisteminin çalışma performansını etkiler. Öznitelik çıkarma işleminde çok farklı yöntemlerle farklı öznitelikler elde edilebilmektedir. Çıkarılan her öznitelik vektörü işareti tanımlayabilir fakat sınıflandırma aşamasında hiçbirisi yüzde yüz doğruluk vermeyebilir. Bundan dolayı, yüksek sınıflandırma başarımı elde etmek için farklı özniteliklerin birlikte kullanımı (hibrit) söz konusu olabilmektedir. Literatürde en

yaygın öznitelik çıkarma yöntemi olarak Fourier Dönüşümü (Gupta vd, 2022), ortak uzamsal örüntü (Thomas vd., 2022), dalgacık dönüşümü (Aydemir vd., 2021; Aydemir vd., 2020b; Fan vd., 2015), özbağlanım parametreleri (Tavares vd., 2020) ve basitçe hesaplanabilen çarpıklık, ortalama türev ve sıfır geçiş sayısı (Tripathy vd., 2019) olarak dikkat çekmektedir. Çıkarılacak özniteliklerin kullanılabilirliği ve etkinliği ise öznitelik seçimi ile gerçekleştirilmektedir (Prabha vd., 2021). Bu sayede daha az sayıda öznitelik kullanılarak yüksek sınıflandırma doğruluğu elde edilebilmektedir.

### 1.6. Literatür Özeti

Elektroansefalogram (EEG), EKG, magnetoensefalogram ve PPG gibi biyolojik işaretler analiz edilerek, kişiler hakkında tıbbi teşhis amaçlı olarak kullanılan birçok bilgi elde edilebilmektedir. Bu bilgiler tıpta hastalıkların teşhis ve tedavisinde kullanıldığı gibi ayrıca hastanın günlük durumunu kontrol etmek için de kullanılır (Smith ve Abel 1999). Bu biyolojik işaretlerden PPG, mikro-vasküler doku yatağındaki kan hacmi değişikliklerini saptamak için kullanılabilen, acı vermeyen, basit, düşük maliyetli ve müdahalesiz optik bir tekniktir. Bununla birlikte PPG işaretleri son 25 yıldır nabız takibi (Nakajima vd., 1996) yanında solunum hızı ölçümü (Nilsson vd., 2000), kandaki oksijen doygunluğu ölçümü (Aoyagi ve Miyasaka, 2002), kandaki şeker seviyesi ölçümü (Habbu vd., 2019), atrial fibrilasyon tespiti (Conroy vd., 2017), tansiyon ölçümü (He vd., 2014) ve kan dolaşımı takibi (Reisner vd., 2008) gibi kalp ve damarlarla ilgili birçok parametrenin incelenmesinde kullanılmıştır. Bunların yanında vücudun farklı noktalarından eş zamanlı olarak elde edilen PPG işaretlerinin incelenmesi üzerine de çalışmalar yapılmıştır (Allen ve Murray, 2000).

Literatürde PPG ile yapılan çalışmalar incelendiğinde, Kavsaoglu ve arkadaşlarının yaptığı çalışmada PPG işaretleri kullanılarak biyometrik özellik tanıma işlemi gerçekleştirilmiş ve  $k$ -en yakın komşu ( $k$ -EYK) sınıflandırıcısı kullanılarak %94,44 lük başarı oranı elde edilmiştir (Kavsaoglu vd., 2014). Yapılan diğer çalışmada ise Ghosal ve arkadaşları 30 sağlıklı 20 hasta bireyden aldıkları PPG işaretleriyle, kendi kendini düzenleme yöntemini kullanarak sistolik zirve ve desistolik zirve teşhisini sırasıyla %100 ve %95 oranında başarıyla sınıflandırmışlardır (Ghosal ve Gupta, 2016). Fan ve arkadaşlarının yaptığı çalışmada ise PPG sinyallerinden özellik noktaları çıkarılarak geliştirilen dalgacık tabanlı otomatik öğrenme



algoritmasıyla nabız hızı ölçümünün manuel olarak yapılan ölçümlerden daha sağlıklı sonuçlar verdiği gösterilmiştir (Fan vd., 2015). Korkmaz ve arkadaşlarının yaptığı çalışmada ise PPG işaretleri kullanılarak sigara kullanımının, cinsiyet ve açlık-tokluk durumlarının belirlenmesinde k-en yakın komşu sınıflandırıcısı kullanılarak sırasıyla %73,7, %72,8 ve %65,8 oranında bir doğruluk elde etmişlerdir (Korkmaz vd., 2017).

PPG'den başka, özellikle temassız, pratik ve zahmetsizce ölçülebilen, tendeki kan hacmi değişiminden kaynaklanan düşük genlikli renk değişimlerini, kameralar vasıtasıyla gözleme sonucunda elde edilen uzaktan fotopletismografi (*ing.* remote photoplethysmography, rPPG) tekniği de fizyolojik bilgi sağlaması açısından tıp alanında son yıllarda dikkat çeken bir başka uygulamadır. PPG gibi rPPG işaretlerinde de damarlar ve kan dolaşımı ile bilgilere, profesyonel ya da klasik kameralar aracılığıyla, kişilerin uzuvlarından (el, yüz gibi) kaydedilen görüntüler kullanılarak ulaşılabilmektedir (Gangal ve Ozturk, 2018; Verkruysse vd., 2008). Ancak rPPG işaretleri PPG işaretlerine göre gürültüye karşı (hareket/aydınlanma/kuvantalama gürültüsü gibi) daha hassastır. Temassız bir veri alma yöntemi olmasından dolayı oldukça ilgi gören rPPG işaretlerinin daha sağlıklı bir biçimde alınıp işlenmesi için ise çeşitli yöntemler geliştirilmektedir (De Haan ve Van Leest, 2014; Feng vd., 2015; Tarassenko vd., 2014; Wang vd., 2019; Wang vd., 2016).

Nabız sinyalinin elde edilmesinde genellikle yüz bölgesinden termal kameralar veya daha pratik olan renkli kameralar ile birlikte alınan veriler kullanılmıştır (Rubins vd., 2011; Scully vd., 2012; Yu vd., 2012). Nabız hızı ölçülmesinde genellikle renkli görüntünün yeşil renk bileşeninin zamana göre değişimi dikkate alınarak Bağımsız Bileşenler Analizi (Yang vd., 2015), Kör Kaynak Ayırma (Poh vd., 2010; Wedekind vd., 2018) ve Temel Bileşenler Analizi (Poh vd., 2011) gibi karmaşık veri analiz yöntemleri literatürde mevcuttur. Nabız sinyalinin ölçülmesinde genel olarak iki temel yaklaşım kullanılmaktadır. Bunlardan birincisi, bir bant geçiren filtre çıkışından elde edilen sinyalin tepe noktalarının veya sıfır geçişlerinin belirlenmesidir (Poh vd., 2011; Wei vd., 2013). İkincisi ise, frekans analizi yaklaşımıdır (Poh vd., 2010; Sun, 2011). Bu yaklaşımda sinyal bir bant geçiren süzgeçten geçirilir ve frekans uzayında spektrum analizi yapılarak nabız hızı ölçülür.

Kalp yetersizliğinde ve tansiyon hastalığı tespitinde non-invaziv testler ile hastalığa tanı koymak ya da tanıya yardımcı olmak önem arz etmektedir. Zira

günümüzde kullanılan EKG gibi yöntemler hem zahmetli hem de uzun süren bir yöntemdir (Moraes vd., 2018). Bu bakımdan, bu tez çalışmasında ele alınan veri setlerinden biri tansiyon hastalığının PPG gibi kolay elde edilebilir bir yöntemle yüksek doğrulukla tespit edilebilmesine yöneliktir.

### 1.7. Tezin Kapsamı

PPG işaretlerinin sınıflandırılması için kullanılan öznitelik çıkarma yöntemlerinin en yaygın olanlarından biri de dalgacık dönüşümüdür. Zaman-frekans alanındaki sinyalden ayırt edici özelliklerin çıkarılmasının büyük ölçüde ana dalgacık fonksiyonunun seçimine bağlı olduğu iyi bilinmektedir. Bu yöntemin en önemli avantajı kullanılabilecek ana dalgacık sayısının fazla olması ve ölçek parametresinin geniş bir spektrumu kapsayabilmesidir. Ancak bu seçim opsiyonlarının çok olması en uygun ana dalgacık ve ölçek parametresinin belirlenmesinde binlerce kombinasyonun sınanmasını gerektirdiğinden zaman kaybına yol açabilmektedir. En uygun ana dalgacık fonksiyonunu belirlemenin literatürde kesin belirlenmiş bir yolu olmamasına rağmen, genellikle ya ampirik olarak (makine öğrenmesi uygulamalarında doğrulama süreci dahil) ya da önceki deneyimlere göre seçilir. Ana dalgacık fonksiyonunun analiz edilecek sinyale benzerliğinin de araştırmacıya, en yüksek performansı sağlayan uygun ana dalgacığı seçme konusunda ipucu verdiğini belirtmek gerekir. Literatürde, PPG işaretlerinden dalgacık dönüşümü yöntemi ile öznitelikler çıkarılırken bu ana dalgacık belirleme süreçlerinden biri takip edilir ve bir tane en uygun ana dalgacık belirlenir. Bu tez çalışmasında, PPG işaretlerinin sınıflandırılmasında ardışıl ileri ana dalgacık seçim yönteminin öznitelik çıkarma aşamasında sınıflandırıcı performansını arttırabileceği gösterilmiştir. Bu yöntem ile sadece bir ana dalgacık değil farklı ölçek aralıkları ile farklı ana dalgacıkların ardışıl bir şekilde belirlenmesi sağlanmıştır. Önerilen yöntemin kararlılığı literatürde genel kullanıma sunulmuş olan 3 adet güncel veri setine uygulanmıştır. Bu veri setlerinden biri zihinsel iş yükü değerlendirmesi için bir *N*-geri görevi sırasında 22 sağlıklı katılımcıdan kaydedilen PPG verilerini içeren 3 sınıflı (3 ayrı zihinsel iş yükü seviyesi) bir problemdir. Veri setlerinden ikincisi; farklı tansiyon seviyeleri (hipertansiyon ve normal seviyeler) olan kişilerin PPG verilerini içeren 2 sınıflı bir problemdir. Son veri seti ise; yaşları 20 ile 52 arasında olan 7 katılımcının skuat, step ve dinlenme hareketleri yaptığı sırada kaydedilen PPG

iřaretlerini içermektedir. Bu veri seti PPG iřaretleri deęerlendirilerek her bir kiřinin hangi aktiviteyi (skuat, step ve dinlenme aktivitesi) yaptığının tespit edilmesini amaçlayan 3 sınıflı bir problemidir. Bu veri setleri ařaęıda detaylı bir řekilde açıklandıktan sonra, dalgacık dönüşümü yönteminin teorik içerięi ile ardışıl ileri ana dalgacık seçim yöntemi algoritması verilmiştir. Daha sonra bulgular başlıęı altında bu üç veri setine ait sonuçlar sunulmuřtur. Tez çalışmasının son kısmında ise sırasıyla elde edilen sonuçlar, öneriler ve tartışma bölümleri verilmiştir.



## 2. YAPILAN ÇALIŞMALAR

Bu bölümde, tez çalışmasında kullanılan veri setleri Materyal başlığı altında verilirken, kullanılan matematiksel yöntemler ve geliştirilen algoritma Yöntem başlığı altında detaylı bir şekilde açıklanmıştır.


### 2.1. Materyal

Bu tez çalışmasında önerilen yöntemin kararlılığını ve sınıflandırma performansını arttırdığını göstermek için 3 ayrı veri seti sınanmıştır. Aşağıda verilen alt başlıklar altında bu veri setleri detaylı bir şekilde açıklanmaktadır.

#### 2.1.1. Veri Seti 1 Tanıtımı


Veri Seti 1 (VS1) olarak adlandırılan bu veri seti zihinsel iş yükü değerlendirmesi için giyilebilir sensör kullanan bir  $N$ -geri görevi sırasında 22 sağlıklı denekten ( $S_1, S_2, \dots, S_{22}$ ) kaydedilen PPG verilerini içermektedir (Beh vd., 2021). Deneklerin ortalama yaşı 23 ve yaşlarının standart sapması 1.7'dir. Dinlenme seansı olarak adlandırılan deneyden önce her katılımcı bir onam formu imzalamıştır. Daha sonra, her birine deneysel prosedürleri ve öz değerlendirme anketlerinin anlamını açıklayan bir dizi talimat hakkında bilgi verilmiştir.

Dinlenme seansından sonra, farklı zihinsel iş yükü koşullarını ortaya çıkarmak için kullanılan  $N$ -geri görevinin altı alt seansı vardır.  $N$ -geri görevinde, kullanıcının art arda hızla yanıp sönen bir dizi sayının son  $N$  tek basamaklı sayısını ezberlemesi gerekmektedir. Bir uyarı, uyarı numarasından önceki  $n$ 'inci sayı ile aynı olduğunda, denek klavyedeki boşluk çubuğuna basarak yanıt vermelidir.  $N$ 'deki bir artış, görev zorluğunda bir artış anlamına gelmektedir, yani denekler daha fazla sayı ezberlemek ve ezberlenen sırayı değiştirmeye devam etmek zorunda kalmaktadır. Bu nedenle,  $N$ 'yi ayarlamak, farklı seviyelerde zihinsel iş yüklerini ortaya çıkarmaktadır. 0, 2 ve 3 geri olmak üzere üç tür görev yükü bu çalışmada dikkate alınmıştır. 0-geri görevi daha düşük zihinsel iş yükü durumu olarak görülebilirken, 2- ve 3-geri görevleri sırasıyla orta ve daha yüksek zihinsel iş yükü durumları olarak kabul edilmiştir. Bu üç tür görev, toplam altı oturum için dengelenmiş bir sırayla (sırasıyla;  $0 \rightarrow 2 \rightarrow 3 \rightarrow 2 \rightarrow 3 \rightarrow 0$ ) düzenlenmiştir. Deneysel prosedürün akış şeması Şekil 6'da verilmiştir.



**Şekil 6.** İş yüklerinin süre ve sırası

Her görev oturumu sırasıyla 5 dakikalık bir  $N$ -geri görevi ve 2 dakikalık bir NASA-TLX anketi (Rubio vd., 2004; Malakoutikhah vd., 2021) içerir. Önerilen yöntem, veri kümesini 6 saniye (sn), 8 sn ve 10 sn segmentlerine (pencere uzunlukları) bölerek test edilmiştir. Şekil 7'de her sınıf için 8 sn kaydının üç örneği verilmiştir. Bu şekilde, birinci, ikinci ve üçüncü şekiller sırasıyla 0-geri, 2-geri ve 3-geri görevini temsil etmektedir. Dikey eksen genliği temsil ederken, yatay eksen zamanı sn cinsinden ifade etmektedir. Tablo 1, her  $N$ -geri görevi için elde edilen bölümlerin (denemelerin) sayısını göstermektedir. Temel amaç, test setindeki denemeleri 0 geri, 2 geri ve 3 geri görevler olarak kategorize etmektir (sınıflandırmaktır).



**Şekil 7.** Örnek PPG işaretleri: a) 0-geri, b) 2-geri, c) 3-geri görev


**Tablo 1.** Her bir görev için toplam deneme sayıları

| Pencere uzunluğu | 0-Geri Görev | 2- Geri Görev | 3- Geri Görev |
|------------------|--------------|---------------|---------------|
| 6                | 100          | 100           | 100           |
| 8                | 74           | 74            | 74            |
| 10               | 60           | 60            | 60            |

Procomp Infinity olarak isimlendirilen cihaz ve 256 Hz'lik bir örnekleme frekansı ile PPG sinyalleri kaydedilmiştir. Katılımcılar sağ el parmaklarıyla klavyedeki boşluk tuşuna basarken, daha iyi sinyal kalitesi elde etmek için elastik bir bantla sıkıca tutturulmuş sol elin orta parmak ucundan PPG verileri alınmıştır.

### 2.1.2. Veri Seti 2 Tanıtımı


Bu tez çalışmasında kullanılan ikinci veri seti (VS2) araştırmaya etik onayı veren Çin Guilin Halk Hastanesi'nde kaydedilen farklı tansiyon seviyeleri olan kişilerin PPG verilerini içermektedir. Katılımcılar kayıttan önce 10 dakika boyunca rahat bir sandalyede dinlendirilmiştir. Örnekleme frekansı 1 kHz olup, her kişiden her bir parçası 2.1 saniye olan 3 parça veri kaydı yapılmıştır. Veri toplama aşamasına yaşları 21 ile 86 arasında değişen ve %48'i erkek olan 219 kişi katılmıştır. Bunlarda 139'u hipertansiyon hastası iken 80'ninin tansiyonu normaldir. Toplam her biri 2,1 saniye olan 657 PPG veri kaydı yapılmıştır (Liang vd., 2018). Örnek bir PPG işareti Şekil 8'de gösterilmektedir. VS2 için temel amaç; PPG verilerinin 'hipertansiyon hastası' ya da 'sağlıklı' olarak sınıflandırabilmektir.



**Şekil 8.** VS2 için örnek PPG verisi


### 2.1.3. Veri Seti 3 Tanıtımı

Diğer genel kullanıma sunulmuş veri seti (VS3) ise yaşları 20 ile 52 arasında olan 3'ü erkek ve 4'ü kadın olmak üzere toplam 7 katılımcıdan (S1, S2, ..., S7) Şekil 9'da gösterildiği gibi skuat, step hareketleri ve dinlenme durumunda kaydedilen veri setidir (Biagetti vd., 2020). Bu veri seti şu internet adresinden temin edilebilir: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6971339/bin/mmc1.zip> (Biagetti vd. 2020). Tüm katılımcılardan yazılı katılım onam formu alınmıştır. PPG işaretleri kişilerin bileklerine takılmış kablosuz Maxim Integrated MAXREFDES100 cihazı ile 400 Hz'lik örnekleme frekansı ile kaydedilmiştir. Sensör ve cilt yüzeyi arasında sıkı bir bağlantı sağlamak için, mükemmel elastik özelliklere sahip ayarlanabilen özel bir bilek bandı kullanılmıştır.



Şekil 9. Deney prosedürü

Her bir katılımcıya ait skuat, step ve dinlenme hareketleri için 5 oturumda yapılan toplam kayıt süresi sn cinsinden Tablo 2'de verilmiştir. Bu çalışmada bu kayıtlar birbiri ile çakışma olmayacak şekilde bir, iki ve üçer saniyelik parçalara (deneme) ayrılmıştır. Skuat hareketi, step hareketi ve dinlenme durumuna ait üçer PPG denemesi Şekil 10'da gösterilmiştir. Bu şekilde yatay eksen 400 Hz örnekleme frekansı ile alınan örnek indekslerini ve dikey eksen ışık geçirgenliğine dayalı değişen nanoamper (nA) mertebesinde akım değerini ifade etmektedir.



**Şekil 10.** PPG örnekleri, (a) dinlenme durumu, (b) skuat hareketi, (c) step hareketi

Tablo 3’te ise PPG işaretlerinin 1, 2 ve 3 saniyelik pencere uzunluğu ile çeşitli örtüşme sürelerine dayalı deneme sayıları verilmiştir. Denemelerin yarısı rastgele olarak eğitim kümesi için diğer yarısı ise test kümesi için gruplandırılmıştır. Bu deneme sayıları dikkate alınarak önerilen yöntem uygulanmıştır. Bu veri seti için PPG işaretlerinin VS1’e göre daha küçük parçalara ayrılmasının temel sebebi harekete dayalı PPG işaretlerinin sınıflandırılması için ayırt ediciliği yüksek özneliliklerin çıkarılabilmesidir. Önerilen yöntemin kısa süreli PPG işaretlerinin bölünme yerlerine bağımlılığının da test edilmesi için bu veri seti için sinyaller belirli süreler için örtüşmeli olarak elde edilmiştir. Bu yaklaşım aynı zamanda daha fazla deneme sayısı elde edilmesini sağlamış bu da sınıflandırıcının daha iyi eğitilmesini olanaklı hale getirmiştir. Buna ek olarak test işleminde de daha fazla denemenin teste tabi tutulmasını sağlamıştır. VS2 için temel amaç PPG verileri ile kişinin skuat hareketi, step hareketi veya dinlenme durumundan hangisinin yaptığının otomatik olarak belirlenmesidir.

**Tablo 2.** Kaydedilen verilerin süresi (sn)

| Kişi | Skuat Hareketi | Step Hareketi | Dinlenme Durumu |
|------|----------------|---------------|-----------------|
| S1   | 311,6          | 443,0         | 3271,7          |
| S2   | 216,8          | 397,6         | 2962,8          |
| S3   | 231,5          | 271,0         | 1323,8          |
| S4   | 212,6          | 269,7         | 1361,9          |
| S5   | 212,6          | 242,0         | 1440,9          |
| S6   | 237,4          | 325,9         | 1402,0          |
| S7   | 266,9          | 254,9         | 1510,7          |



PPG işaretlerinden insan hareketi takibine yönelik çalışmalar arasında bu 3 hareket birlikte daha önce kaydedilerek sınıflandırılmamıştır. İnsan hareket takibi özellikle günlük belirli miktarda egzersiz yapmak isteyen kişiler için yaşlıların uzaktan takibi için veya diyabet gibi hastalıklardan mustarip insanların kullandıkları ilaçların dozlarını günlük yaptıkları egzersiz miktarına göre ayarlamalarını fayda sağlamaktadır. Tezin özgün yanlarından biri de daha önce incelenmeyen PPG veri kümelerinin kullanılmasıdır.

**Tablo 3.** Kullanılan eğitim kümesi deneme sayısı ve test kümesi deneme sayısı

| Hareket  |    | Pencere Uzunluğu |      |      |                |      |      |      |                |      |      |      |      |
|----------|----|------------------|------|------|----------------|------|------|------|----------------|------|------|------|------|
|          |    | 1 sn             |      |      | 2 sn           |      |      |      | 3 sn           |      |      |      |      |
|          |    | Örtüşme Süresi   |      |      | Örtüşme Süresi |      |      |      | Örtüşme Süresi |      |      |      |      |
|          |    | 0                | 0,25 | 0,5  | 0              | 0,25 | 0,5  | 1    | 0              | 0,25 | 0,5  | 1    | 1,5  |
| Dinlenme | S1 | 3268             | 4358 | 6535 | 1633           | 1866 | 2177 | 3263 | 1089           | 1187 | 1304 | 1630 | 2174 |
|          | S2 | 2960             | 3946 | 5918 | 1478           | 1690 | 1970 | 2955 | 986            | 1075 | 1183 | 1477 | 1969 |
|          | S3 | 1321             | 1760 | 2639 | 659            | 752  | 879  | 1316 | 439            | 479  | 527  | 657  | 874  |
|          | S4 | 1360             | 1813 | 2717 | 678            | 775  | 904  | 1355 | 451            | 492  | 541  | 677  | 900  |
|          | S5 | 1438             | 1916 | 2875 | 718            | 820  | 956  | 1433 | 478            | 521  | 573  | 715  | 954  |
|          | S6 | 1399             | 1865 | 2796 | 698            | 797  | 931  | 1394 | 464            | 507  | 558  | 696  | 927  |
|          | S7 | 1509             | 2010 | 3014 | 753            | 859  | 1004 | 1504 | 500            | 547  | 601  | 751  | 1000 |
| Skuat    | S1 | 310              | 411  | 616  | 153            | 175  | 204  | 305  | 101            | 111  | 121  | 152  | 200  |
|          | S2 | 214              | 284  | 426  | 105            | 120  | 141  | 209  | 70             | 76   | 83   | 104  | 137  |
|          | S3 | 228              | 304  | 455  | 113            | 130  | 151  | 223  | 75             | 81   | 89   | 110  | 146  |
|          | S4 | 210              | 279  | 418  | 104            | 118  | 138  | 205  | 68             | 74   | 82   | 101  | 134  |
|          | S5 | 243              | 323  | 484  | 121            | 138  | 161  | 238  | 80             | 87   | 95   | 117  | 156  |
|          | S6 | 235              | 313  | 467  | 116            | 132  | 154  | 230  | 76             | 84   | 92   | 114  | 150  |
|          | S7 | 264              | 352  | 526  | 130            | 149  | 174  | 259  | 86             | 94   | 103  | 129  | 170  |
| Step     | S1 | 442              | 586  | 880  | 221            | 249  | 291  | 437  | 146            | 158  | 175  | 216  | 289  |
|          | S2 | 395              | 527  | 789  | 197            | 224  | 261  | 390  | 130            | 142  | 155  | 193  | 258  |
|          | S3 | 268              | 357  | 535  | 134            | 151  | 177  | 263  | 88             | 95   | 106  | 129  | 173  |
|          | S4 | 267              | 356  | 531  | 132            | 151  | 175  | 262  | 87             | 95   | 104  | 130  | 171  |
|          | S5 | 239              | 318  | 477  | 118            | 135  | 157  | 234  | 78             | 85   | 94   | 116  | 154  |
|          | S6 | 324              | 430  | 644  | 160            | 182  | 212  | 319  | 107            | 116  | 128  | 159  | 210  |
|          | S7 | 253              | 335  | 503  | 126            | 143  | 166  | 248  | 83             | 90   | 98   | 122  | 163  |

## 2.2. Yöntem

### 2.2.1. Dalgacık Dönüşümü

Sinyalleri zaman domeninde (uzayında) analiz etmek sinyal işleme için her zaman yeterli bilgiyi sağlayamayabilir. Bundan dolayı literatürde Fourier Dönüşümü (FD), Laplace Dönüşümü, hızlı FD, Hilbert Dönüşümü, kısa zamanlı FD ve Dalgacık Dönüşümü (DD) gibi birçok dönüşüm yöntemleri önerilmiştir. Bunlar içerisinde FD, sinyal işleme alanında en çok bilinen ve belki de en çok kullanılanıdır. Bu yöntem bir

sinyalin tüm frekans bileşenlerini belirlemek için sinyali zaman uzayından frekans uzayına taşımak için Eşitlik 3'ü kullanır.

$$FD[k] = \frac{1}{N} \sum_{n=0}^{N-1} X[n] e^{-jn2\pi k/N}, \quad k = 0, 1, 2, \dots, N-1 \quad (3)$$


Bu eşitlikte  $X$ ; sinyali ve  $N$  ise sinyalin uzunluğunu temsil etmektedir. FD'nin zaman domeninde ön plana çıkmayan frekans bilgisini sağlaması önemli bir avantaj olsa da özellikle ilgili frekans bileşenlerinin zamanın hangi anında ortaya çıktığı bilgisini vermemesi yani zaman bilgisini içermemesi de bir o kadar önemli bir dezavantaj olarak değerlendirilmektedir (Shi vd., 2020; Gao ve Li, 2021). Bu bakımdan zaman ve frekans bilgisi değişiklik gösteren yani durağan olmayan PPG gibi sinyalleri analiz etmede FD yeterli bir yöntem olmamaktadır. Araştırmacılar bu eksikliği gidermek için sinyali küçük zaman pencerelerine bölüp ve her pencere içine düşen sinyal parçasının FD'sini hesaplama esasına dayanan kısa zamanlı FD yöntemini önermişlerdir (Tao vd., 2009). Bu yaklaşımın önemli bir parametresi doğrudan zaman-frekans çözünürlüğü ile ilişkili olan pencere boyutudur. Bu nedenle, sinyal üzerindeki durağan sinyal parçalarına hemen hemen eşit olmalıdır ancak bilinmeyen durağan olmayan sinyalleri belirlemek zordur. Diğer taraftan kısa zamanlı FD'de pencere boyutu tüm frekans bantları için aynıdır. Bundan dolayı bu yöntem özellikle sinyalin yüksek frekansları için iyi çözünürlük sağlamaz. Literatürde bu dezavantajları içermeyen ve çoklu çözünürlük sağlama özelliklerine sahip DD yöntemi önerilmiştir (Shah ve Lone, 2022; Hoang, 2014). Sağladığı avantajlar ile DD ön işleme (Bos ve Vrieling, 1994), gürültü giderme (Patil, 2015), zaman-frekans görseli sağlama (Pokorski ve Patorski, 2010) ve görüntü sıkıştırma (Geetha vd., 2022) gibi birçok sinyal işleme uygulamalarında kullanılmıştır. Tüm bunların yanında öznelilik çıkarmadaki oldukça iyi performansı nedeniyle DD çeşitli makine öğrenmesi uygulamalarına kritik bir basamak olarak katkıda bulunmaktadır (Bruce vd., 2002; Al Ghayab vd., 2019; Khare vd., 2020). Bu tez çalışmasında yukarıda bahsedilen temel avantajlarından dolayı DD kullanılmış olup, aşağıda bu yöntemin matematiksel olarak nasıl kullanıldığı detaylı bir şekilde açıklanmaktadır.

Dalgacık dönüşümü, ortalaması sıfır olan, ölçek ve kaydırma parametreleri ile

Eşitlik 4'te verildiği gibi öznitelik çıkarılacak  $x(t)$  sinyali üzerinde konvolüsyona tabi tutulan bir işlemdir. Dikkate alınan her bir ölçek ve kaydırma parametresi için bir dalgacık dönüşümü katsayısı (DDK) hesaplanarak bu işlem tamamlanır. Eşitlik 4'te  $n$  ölçek (dalgacığı germe veya sıkıştırma) ve  $m$  ise kaydırma (dalgacığı zaman ekseninde ilerletme) parametresini ifade etmektedir.

$$DDK(m, n) = n^{-1/2} \int_{-\infty}^{+\infty} x(t) \psi\left(\frac{t-m}{n}\right) dt \quad (4)$$

Öznitelik çıkarılacak sinyal ile matematiksel olarak konvolüsyona tabi tutulacak sinyal parçası ( $\psi$ ) ana dalgacık olarak adlandırılır ve  $n$  ve  $m$  parametreleri ile sinyalin zaman ve frekans özelliklerini lokalize etmek için kullanılır. DD'yi uygulamak için bir kısmı Şekil 11'de gösterilen farklı özellik ve kullanım amaçlarına sahip, süresi sınırlı ve ortalama değeri sıfır olan birçok ana dalgacık literatürde önerilmiştir. Taşıdığı özelliklerin doğası gereği dalgacıklar genlik ekseninin pozitif ve negatif yönlerinde salınım yapar ve bu salınım, zaman ekseninde ilerledikçe genlik ekseninde sıfıra oturarak sona erer. Süresinin sınırlı olmasından ötürü bu fonksiyonlara –cık (*ing.* -let) küçültme eki getirilmiştir.



**Şekil 11.** Sık kullanılan bazı ana dalgacık çeşitleri

Dalgacıklar farklı analitik biçimlerde olduklarından her biri için farklı DDK elde edilmektedir. Bu da çıkarılacak öznelikleri ve dolayısıyla da makine öğrenmesinin performansını direkt etkilemektedir. Bundan dolayı dalgacık tipinin seçimi hayati bir aşamadır. En uygun dalgacığın belirlenmesi için literatürde net bir fikir birliği mevcut değildir. Daha çok dalgacıkların performansları karşılaştırılarak en yüksek başarıyı sergileyen bir dalgacık, yöntemle entegre edilmektedir.

### 2.2.2. Öznelik Çıkarma Yöntemleri

Etkin, diğer bir deyişle ayırt ediciliği yüksek öznelikler, sınıflandırma performansını doğrudan ilgilendirdiği için öznelik çıkarma aşaması, örüntü tanıma ve makine öğrenmesi uygulamalarının en önemli aşamalarından biridir. Ham işareti, mümkünse daha düşük boyutlu bir vektör ile temsil etmenin yanında işarete var olan, ancak gizlenmiş ayırt ediciliği ön plana çıkarmak anlamına gelen bu aşama, araştırmacılar için vakit alan da bir safhadır. Bu dezavantajı ortadan kaldırmak için son yıllarda derin öğrenme algoritmaları geliştirilmiştir. Bu algoritmaların başarılı olması çok sayıda örneğe bağlıdır. Bu çalışmada kullanılan veriler tek elektrot ile sınırlı sayıda kaydedildiği için bu algoritmalar yerine *k*-EYK kullanılmıştır.

Bu tez çalışmasında önerilen yöntemin öznitelikleri Eşitlik 4’te matematiksel ifadesi verilen DDK’ların standart sapması ve ortalama değerleri olarak iki boyutludur. Bu öznitelikler sırasıyla Eşitlik 5 ve Eşitlik 6’da verildiği gibi hesaplanır. Sonuç olarak bunlar her bir PPG denemesini temsil edecek öznitelikler olarak çıkarılmıştır.

$$O_{DDK} = \frac{1}{U} \sum_{i=1}^U (DDK)_i \quad (5)$$

$$STD_{DDK} = \sqrt{\frac{1}{U-1} \sum_{i=1}^U ((DDK)_i - (O_{DDK}))^2} \quad (6)$$

Bu eşitliklerde  $O_{DDK}$  dalgacık dönüşümü katsayılarının ortalamasını,  $STD_{DDK}$  dalgacık dönüşümü katsayılarının standart sapmasını ve  $U$  dalgacık dönüşümü katsayılarının sayısını ifade etmektedir.

Önerilen yöntemle ait özniteliklerden başka literatürde sıklıkla kullanılan istatistiksel öznitelikler ve band gücü (BG) öznitelikleri de hesaplanarak karşılaştırma amaçlı sınıflandırma sonuçları elde edilmiştir. İstatistiksel öznitelikler; ortalama değer (OD), standart sapma değeri (SSD), çarpıklık (Ç) ve basıklık (B) olmak üzere 4 adettir ve sırasıyla aşağıdaki gibi hesaplanırlar:

$$OD = \frac{1}{L} \sum_{i=1}^L X_i \quad (7)$$

$$SSD = \sqrt{\frac{1}{L-1} \sum_{i=1}^L [X_i - OD]^2} \quad (8)$$

$$\zeta = \frac{\frac{1}{L} \sum_{i=1}^L (X_i - \bar{X})^3}{\left( \sqrt{\frac{1}{L} \sum_{i=1}^L (X_i - \bar{X})^2} \right)^3} \quad (9)$$

$$B = \frac{\frac{1}{L} \sum_{i=1}^L (X_i - \bar{X})^4}{\left( \frac{1}{L} \sum_{i=1}^L (X_i - \bar{X})^2 \right)^2} \quad (10)$$

Bu eşitliklerde  $X$  bir PPG sinyal denemesini ve  $L$  onun uzunluğunu belirtmektedir. OD; dikkate alınan PPG sinyalinin genliklerinin genel olarak hangi seviyelerde olduğu bilgisini, SSD; dikkate alınan PPG sinyalinin zaman içinde genlik değerlerinin sapma miktarı bilgisini, Ç; dikkate alınan PPG sinyalinin asimetri bilgisini ve B; dikkate alınan PPG sinyalinin içerdiği pik yoğunluğu bilgisini vermektedir. Eğer bir sinyal orta noktasına göre tam simetrik ise (yarım periyot sinüs işareti gibi) bu sinyalin Ç değeri sıfırdır.

Çarpıklık (*ing. Skewness*): Bir sinyalin normal dağılımdan ne kadarlık sapma ile simetrikliğinin bozulduğunu gösteren bir niceliktir. Normal dağılımlı bir sinyalde çarpıklık değeri '0'dır, yani sinyal simetriktir. Negatif çarpıklık katsayısı sağa çarpık, pozitif çarpıklık katsayısı ise sola çarpık bir sinyal dağılımına işaret etmektedir.

Basıklık (*ing. Kurtosis*): Basıklık katsayısı da normal dağılımlı bir sinyalde '0'dır. Bir sinyalin içerdiği pik yoğunluğunu vermektedir. Pozitif basıklık katsayısı sivri bir dağılıma, negatif basıklık katsayısı ise basık bir sinyal dağılımına işaret etmektedir.


Karşılaştırma amacıyla kullanılan özniteliklerden diğeri yukarıda da değinildiği gibi BG'dir. Bu öznitelik Eşitlik 3'te matematiksel hesabı verilen ve tüm frekans bandını kapsayan FD katsayılarını Eşitlik 11'de görüldüğü gibi ilgili frekans aralığında FD katsayılarının genliklerinin karesini alıp bunların toplanmasıyla hesaplanır. Bu eşitlikte  $f_L$  alt kesim frekansını ve  $f_H$  üst kesim frekansını ifade etmektedir.

$$BG = \sum \|FD[k]\|_{f_L}^{f_H} \|^2 \quad (11)$$

### 2.2.3. $k$ -En Yakın Komşuluk Sınıflandırıcısı

Makine öğrenmesi, önceden belirlenen sınıflara ait kaydedilen verilerden çıkarılan öznitelik uzayını kullanarak tahmin yapabilen bir veri modeli oluşturma işlemidir. Diğer bir deyişle makine öğrenmesi işlemi, verilerdeki örüntüyü aramak için örnekler, denemeler, talimatlar, gözlemler gibi eğitim verilerinin seçilen algoritmaya girilmesiyle başlar. Kullanılan algoritmanın performansını test etmek için, test verisi denilen yeni girdi verileri makine öğrenimi algoritmasına eklenerek tahmin etiketleri elde edilir. Bu tahminler eldeki gerçek etiketler ile kıyaslanarak makine öğrenmesi


algoritmasının performansı hesaplanır. Bu aşamalar Şekil 12’de gösterilmiştir. Bu genel çerçeve içerisinde birçok makine öğrenmesi tekniği mevcuttur. Literatürde bunlardan en sık kullanılanları  $k$ -en yakın komşuluk ( $k$ -EYK) bu çalışmada sınıflandırıcı olarak kullanılmıştır.



**Şekil 12.** Makine öğrenmesi modelinin aşamaları

Cover ve Hart (1967) tarafından önerilen  $k$ -EYK yöntemi, en genel hali ile bir test denemesinin eğitim kümesine ait öznitelik vektörlerine olan uzaklıkların hepsini hesaplayarak bu test denemesi özniteliklerine en yakın  $k$  tane eğitim denemesini dikkate alarak sınıflandırma işlemini gerçekleştirir. Bu yöntem anlaşılması ve uygulaması kolay olduğu kadar örüntü sınıflandırmada etkili ve makine öğrenme algoritmaları arasında en popüler olanların başında gelmektedir (Konovalenko ve Ludwig, 2022; Kivrak vd., 2021). Özellikle, istenildiğinde eğitim aşamasına ihtiyaç duymaması, basit, analitik olarak takip edilebilir, gürültülere karşı dayanıklı olması, çoklu sınıflandırma problemlerine karşı uygun ve başarılı olması gibi avantajları ile de araştırmacılar tarafından tercih edilmektedir. Bunlara karşın; öznitelik uzayındaki örnek sayısının artması ile işlem yükünün artması ve yüksek bellek gereksinimine ihtiyaç duyması bu yöntemin dikkat çekici dezavantajları arasında sayılabilir. Dikkate alınan  $k$  örnek oylama usulüne göre değerlendirilir ve test denemesinin sınıfına karar

verilir. Matematiksel olarak açıklamak gerekirse  $k$ -EYK algoritmasında eğitim setine ait her bir denemenin  $n$  tane öznitelik ile temsil edildiği varsayılın. Bu  $n$  boyutlu özniteliklerin uzayda bir noktayı temsil edecek biçimde tüm eğitim denemeleri  $n$  boyutlu bir uzayda tutulur. Sınıfı (etiketi) bilinmeyen bir test denemesi ele alındığında eğitim denemelerine uygulanan aynı öznitelik çıkarma yaklaşımı ile  $n$  boyutlu öznitelik vektörü elde edilir ve eğitim öznitelik uzayına yerleştirilir. Bu test öznitelik noktasına, eğitim kümesinden en yakın  $k$  tane öznitelik noktası belirlenerek test denemesine ait etiket çoğunluk oylamasına göre atanır. Bu genel işleyiş iki boyutlu ve iki sınıflı bir problemi temsil eden Şekil 13'te  $k=3$  alınarak özetlenmektedir. Bu şekilde kareler (Sınıf 1) ve daireler (Sınıf 2) eğitim kümesine ait öznitelik uzayını temsil ederken, yıldız etiketi belirlenmek istenen test denemesi öznitelik noktasını göstermektedir. Test noktasına 1'i Sınıf 1'den ve 2'si Sınıf 2'den olacak şekilde en yakın 3 nokta belirlenmiştir. Çoğunluk oylamasına göre Sınıf 2 daha fazla olduğu için bu test denemesi Sınıf 2 olarak etiketlenir.



Şekil 13.  $k$ -EYK'nın genel işleyişi

$k$ -EYK sınıflandırıcısının performansı için en kritik parametreler  $k$  ve noktalar arasındaki uzaklığın ölçülme tekniğidir. Bu çalışmada en uygun  $k$  parametresi eğitim kümesi üzerinde gerçekleştirilen ve aşağıda detaylı bir şekilde açıklanan *birini-dışarda-bırak çapraz onaylama* yaklaşımı ile 1 ile 20 arasında aranmıştır. Test denemesinin, eğitim denemelerine olan uzaklığı ise Eşitlik 12'de verildiği gibi



Euclidean ölçütüne göre hesaplanmıştır.

$$d_e(A_i, B_i) = \sqrt{\sum_{i=1}^m (f_m(A_i) - g_m(B_i))^2} \quad (12)$$

Bu eşitlikte  $m$ ,  $A_i$ , ve  $B_i$  sırasıyla komşu sayısını,  $A$  vektöründeki boyut sayısını ve  $B$  vektöründeki boyut sayısını göstermektedir. Diğer taraftan  $f_m(A_i)$  ve  $g_m(B_i)$  ise sırasıyla  $A_i$ 'nin  $m$ . komşusunun değerini ve  $B_i$ 'nin  $m$ . komşusunun değerini göstermektedir. Bu tez çalışmasında sınıflandırma performansı Eşitlik 13'te verildiği gibi doğru sınıflandırılan deneme sayısının (DSDS) toplam deneme sayısına (TDS) bölünüp 100 ile çarpılması ile yüzde cinsinden hesaplanmıştır.

$$SD = \frac{DSDS}{TDS} \cdot 100 \quad (13)$$

#### 2.2.4. Sınıflandırıcı Eğitimi

Sınıflandırıcıların en uygun parametrelerinin belirlenmesi işlemi eğitim kümesi kullanılarak gerçekleştirilir. Bunun için çapraz onaylama teknikleri yaygın olarak kullanılır. Rastgele alt örnekleme, K-küme çapraz onaylama ve birini dışarıda bırak çapraz onaylama olmak üzere 3 çeşit çapraz onaylama tekniği vardır. Bunlar birbirlerine benzerlikler içerse de temel farklılıkları eğitim kümesinin çapraz onaylama için bölünme şeklidir. Rastgele örneklemede; eğitim kümesi, alt eğitim kümesi ve doğrulama kümesi olmak üzere sadece ikiye bölünürken, K-küme çapraz onaylamada; K tane kümeye bölünür ve K-1 tane küme alt eğitim kümesi olarak belirlenirken 1 küme ise doğrulama kümesi olarak belirlenir. Birini-dışarıda-bırak çapraz onaylama yönteminde ise eğitim kümesinden sadece 1 tanesi onaylama olarak seçilirken geri kalanlar alt eğitim kümesi olarak belirlenir. Bu üç yöntemin kendilerine ait avantaj ve dezavantajları vardır. Bu tez çalışmasında '*birini-dışarıda-bırak çapraz onaylama tekniği*' eğitim verisini en geniş biçimde kullanabilme avantajından dolayı tercih edilmiştir (Cheng ve Lee, 2001). Burada eğitim verisini en geniş biçimde kullanabilmeden kasıt, sınıflandırıcı eğitiminde en iyi öğrenme yollarından birinin

daha fazla sayıda eğitim örneğini dikkate alma olduğu esasına dayanan öğrenme kümesinin büyük tutulmasıdır. Şekil 14’te birini-dışarıda-bırak çapraz onaylama modeli açıklanmıştır.




Şekil 14. Birini-dışarıda-bırak çapraz onaylama modeli

Bu şekilde de görüldüğü gibi  $n$  tane eğitim örneği içeren bir eğitim kümesi için  $n$  tane model oluşturulur ve her bir modelde 1 eğitim örneği onaylama için diğerleri alt eğitim kümesi olarak değerlendirilir. Her bir modelde sınıflandırıcı parametresinin olası değerleri sınanır. Tüm modeller test edildikten sonra sınıflandırıcı parametresinin çoğunlukla hangi değeri için daha yüksek performans elde edilmiş ise o değer sınıflandırıcının en uygun parametresi olarak belirlenmiş olur. Literatürde bu işleme ‘sınıflandırıcı eğitimi’ adı verilir.

#### 2.2.5. Ardışıl İleri Ana Dalgacık Seçim Yöntemi ile Öznitelik Çıkarma

Öznitelik çıkarma işlemi, sinyallerde var olan gizlenmiş bilgiyi ön plana çıkarmaya çalışan bir çeşit dönüşümdür denilebilir. Öyle ki, bu bilgi sınıflar arası farklılığı ön plana çıkarmalıdır. Bu tez çalışmasında, literatürde yaygın kullanımı olan dalgacık dönüşümü algoritması ile en uygun ana dalgacık kombinasyonunu belirlemek için ardışıl ileri seçim yaklaşımı yöntemi önerilmiştir. Eşitlik 5 ve Eşitlik 6’da verildiği gibi DD katsayılarının ortalama ve standart sapma değerleri hesaplanmış ve bunlar her bir PPG denemesini temsil edecek öznitelikler olarak çıkarılmıştır.



Şekil 15. Ardışıl ileri ana dalgacık seçim yöntemi akış şeması

Literatürde dalgacık dönüşümü öznelik çıkarmak için yaygın olarak kullanılsa da ardışıl ileri ana dalgacık seçim (AİADS) yöntemine dayalı en uygun ana dalgacık kombinasyonları ile öznelikler çıkarılmamıştır. AİADS bu işlemi ana

dalgacıları teker teker seçim kümesine ekleyerek belirler. Bu tez çalışmasında Morlet (morl), Meksika Şapkası (mexh), Haar (haar), Meyer (meyr), Daubechies1 (db1), Daubechies2 (db2), Daubechies3 (db3), Symlet2 (sym2), Symlet3 (sym3), Symlet4 (sym4), Coiflets2 (coif2), Coiflets3 (coif3), Coiflets4 (coif4), Gaus1 (gaus1), Gaus2 (gaus2) ve Gaus3 (gaus3) ana dalgacıları ile AİADS yöntemi uygulanmıştır. Şekil 15'te akış şeması da verilen önerilen yöntemin işlem adımları şöyledir:

Adım 1: Tekil kullanımda en yüksek sınıflandırma doğruluğu veren ana dalgacık belirlenir.

Adım 2: Adım 1'de bulunan ana dalgacık ile birlikte kullanılıp sınıflandırma doğruluğunu en fazla arttıran ana dalgacık belirlenir ve Adım 3'e geçilir. Adım 1'de hesaplanan sınıflandırma doğruluğunda artış olmaz ise Adım 1'deki ana dalgacık en iyi kombinasyondur.

Adım 3: Bir önceki adımda belirlenen ana dalgacıklar ile birlikte kullanılıp sınıflandırma doğruluğu en fazla artıran ana dalgacık belirlenir ve Adım 4'e geçilir. Bir önceki adımda hesaplanan sınıflandırma doğruluğunda artış olmaz ise bir önceki adımdaki ana dalgacıklar en iyi kombinasyon olarak belirlenir.

Adım 4: Ardışıl ileri yaklaşım tüm ana dalgacıklar test edilene kadar Adım 3 tekrarlanır.

AİADS yöntemi  $k$ -EYK sınıflandırıcısı ile test edilmiştir. Bu yöntem eğitim kümesi üzerinde uygulanmış ve test kümesi üzerinde sınanmıştır.


### 3. BULGULAR

Yukarıda açıklanan veri seti ve yöntemler kullanılarak elde edilen bulgular aşağıda alt başlıklar halinde şekil ve tablolar ile karşılaştırmalı olarak sunulmuştur.

#### 3.1. Veri Seti 1’den Elde Edilen Bulgular

Veri seti 1 ile 3 ayrı zihinsel iş yükü seviyesinin sınıflandırılması amaçlanmıştır. Bu veri seti için 6 sn, 8 sn ve 10 sn’lik PPG segmentleri dikkate alınarak elde edilen sonuçlar Tablo 4, Tablo 5 ve Tablo 6’da verilmiştir. Bu tablolarda İ; iterasyon sayısını, SD; sınıflandırma doğruluğunu, D; ana dalgacığı ve Ö; belirlenen ölçek aralığını ifade etmektedir. Ayrıca önerilen yöntemin etkinliğini göstermek için, 6 sn, 8 sn ve 10 sn için Şekil 16, Şekil 17 ve Şekil 18’de, son elde edilen SD performansından ilk iterasyonun çıkarılmasıyla hesaplanan artış oranları verilmiştir.

6 sn’lik PPG sinyallerinin sonuçları için en yüksek SD %69,33 ile Katılımcı 10 için elde edilirken, en düşük performans Katılımcı 8 için %51,33 olarak hesaplanmıştır. Tüm denekler için ortalama SD %60,91 olarak elde edilmiştir. db1, sym2 ve sym3 hiçbir zaman seçilmezken, morl dalgacığı etkin ana dalgacık olarak 11 kez seçilmiştir. Ayrıca Şekil 16’ya göre, önerilen yöntemle 15 katılımcı için SD performansı artarken, Katılımcı 16 için maksimum artışın %8,67 olduğu ve ortalama sınıflandırma artışının %3,11 olduğu görülmüştür.



Şekil 16. 6 sn’lik PPG verileri için artış oranları

**Tablo 4.** 6 sn'lik PPG verilerine ait AİADS sonuçları

| İ | SD    | D          | Ö      | SD    | D          | Ö      | SD    | D          | Ö       |
|---|-------|------------|--------|-------|------------|--------|-------|------------|---------|
| 5 |       |            |        | 62,00 | coif3      | 10-30  |       |            |         |
| 4 |       |            |        | 60,67 | gaus3      | 26-98  |       |            |         |
| 3 |       |            |        | 58,00 | gaus1      | 26-98  | 56,67 | db2        | 10-50   |
| 2 |       |            |        | 56,67 | mexh       | 30-70  | 55,33 | coif3      | 34-54   |
| 1 | 66,67 | gaus2      | 62-70  | 55,33 | gaus2      | 38-102 | 54,00 | db3        | 22-62   |
|   |       | <b>S1</b>  |        |       | <b>S2</b>  |        |       | <b>S3</b>  |         |
| 2 | 62,00 | haar       | 14-30  |       |            |        |       |            |         |
| 1 | 60,67 | gaus2      | 10-30  | 68,00 | mexh       | 38-82  | 55,33 | coif2      | 42-110  |
|   |       | <b>S4</b>  |        |       | <b>S5</b>  |        |       | <b>S6</b>  |         |
| 4 | 53,33 | haar       | 10-26  |       |            |        |       |            |         |
| 3 | 52,67 | morl       | 14-18  |       |            |        | 67,33 | meyr       | 10-66   |
| 2 | 51,33 | gaus2      | 62-82  |       |            |        | 66,67 | gaus1      | 14-58   |
| 1 | 50,00 | coif1      | 22-54  | 51,33 | coif1      | 42-106 | 64,67 | sym4       | 22-66   |
|   |       | <b>S7</b>  |        |       | <b>S8</b>  |        |       | <b>S9</b>  |         |
| 5 | 69,33 | morl       | 10-14  |       |            |        |       |            |         |
| 4 | 68,00 | haar       | 42-74  |       |            |        |       |            |         |
| 3 | 66,67 | gaus2      | 22-74  | 60,67 | db3        | 18-34  |       |            |         |
| 2 | 66,00 | coif1      | 10-18  | 56,67 | morl       | 78-98  | 58,00 | db2        | 18-42   |
| 1 | 62,00 | mexh       | 30-34  | 54,67 | mexh       | 18-106 | 54,00 | gaus3      | 106-110 |
|   |       | <b>S10</b> |        |       | <b>S11</b> |        |       | <b>S12</b> |         |
| 4 |       |            |        |       |            |        | 65,33 | morl       | 14-86   |
| 3 |       |            |        |       |            |        | 63,33 | sym4       | 10-54   |
| 2 |       |            |        |       |            |        | 61,33 | gaus1      | 10-54   |
| 1 | 53,33 | db3        | 26-34  | 54,00 | meyr       | 62-110 | 59,33 | meyr       | 70-74   |
|   |       | <b>S13</b> |        |       | <b>S14</b> |        |       | <b>S15</b> |         |
| 5 |       |            |        | 57,33 | coif3      | 10-14  |       |            |         |
| 4 | 68,00 | db3        | 10-26  | 56,00 | meyr       | 10-14  | 63,33 | db2        | 10-14   |
| 3 | 66,00 | gaus1      | 62-86  | 55,33 | haar       | 10-58  | 62,67 | meyr       | 10-42   |
| 2 | 62,67 | meyr       | 70-102 | 54,00 | morl       | 14-86  | 60,00 | morl       | 94-110  |
| 1 | 59,33 | morl       | 50-86  | 53,33 | gaus2      | 30-106 | 57,33 | mexh       | 58-74   |
|   |       | <b>S16</b> |        |       | <b>S17</b> |        |       | <b>S18</b> |         |
| 4 | 58,00 | gaus2      | 14-86  |       |            |        |       |            |         |
| 3 | 56,67 | meyr       | 38-46  |       |            |        | 56,00 | mexh       | 14-94   |
| 2 | 56,00 | morl       | 14-18  |       |            |        | 55,33 | morl       | 10-14   |
| 1 | 54,67 | sym4       | 86-102 | 67,33 | morl       | 38-74  | 54,00 | meyr       | 62-78   |
|   |       | <b>S19</b> |        |       | <b>S20</b> |        |       | <b>S21</b> |         |
| 3 | 64,67 | morl       | 10-22  |       |            |        |       |            |         |
| 2 | 63,33 | mexh       | 50-74  |       |            |        |       |            |         |
| 1 | 60,00 | gaus2      | 26-102 |       |            |        |       |            |         |
|   |       | <b>S22</b> |        |       |            |        |       |            |         |

8 sn PPG sinyallerinin sonuçlarında, Katılımcı 1, Katılımcı 5 ve Katılımcı 9 için en yüksek SD %72,97 olarak elde edilirken, en düşük performans Katılımcı 12 için %52,25 olarak hesaplanmıştır. Tüm denekler için ortalama SD %64,37 olarak elde edilmiştir. sym2, sym3 ve gaus2 hiç seçilmezken, morl dalgacığı 12 kez etkin ana

dalgacık olarak seçilmiştir. Ayrıca Şekil 17'ye göre önerilen yöntemle 19 katılımcı için SD performansları artırılırken Denek 15 ve Denek 16 için maksimum artış %10,81 olarak sağlanmış ve ortalama sınıflandırma artışının %3,69 olduğu görülmüştür.

**Tablo 5.** 8 sn'lik PPG verilerine ait AİADS sonuçları

| İ | SD    | D          | Ö      | SD    | D          | Ö      | SD    | D          | Ö      |
|---|-------|------------|--------|-------|------------|--------|-------|------------|--------|
| 3 | 72,97 | db2        | 14-18  |       |            |        |       |            |        |
| 2 | 72,07 | morl       | 10-38  | 62,16 | coif1      | 34-74  | 57,65 | meyr       | 10-14  |
| 1 | 71,17 | mexh       | 18-102 | 59,45 | mexh       | 14-22  | 54,95 | morl       | 58-66  |
|   |       | <b>S1</b>  |        |       | <b>S2</b>  |        |       | <b>S3</b>  |        |
| 4 | 63,06 | meyr       | 10-30  |       |            |        |       |            |        |
| 3 | 62,16 | coif3      | 86-98  |       |            |        |       |            |        |
| 2 | 59,45 | morl       | 26-50  | 72,97 | gaus3      | 82-98  | 58,55 | meyr       | 10-14  |
| 1 | 58,55 | haar       | 42-58  | 72,07 | mexh       | 18-74  | 53,15 | gaus3      | 62-82  |
|   |       | <b>S4</b>  |        |       | <b>S5</b>  |        |       | <b>S6</b>  |        |
| 5 |       |            |        |       |            |        | 72,97 | db3        | 10-94  |
| 4 |       |            |        |       |            |        | 72,07 | mexh       | 38-106 |
| 3 |       |            |        |       |            |        | 71,17 | meyr       | 54-94  |
| 2 |       |            |        | 60,36 | db3        | 10-34  | 68,47 | morl       | 50-58  |
| 1 | 55,85 | coif3      | 34-50  | 57,65 | mexh       | 42-90  | 65,76 | haar       | 22-66  |
|   |       | <b>S7</b>  |        |       | <b>S8</b>  |        |       | <b>S9</b>  |        |
| 3 |       |            |        | 65,76 | db3        | 14-26  |       |            |        |
| 2 | 68,47 | haar       | 10-14  | 62,16 | meyr       | 78-110 | 52,25 | morl       | 14-26  |
| 1 | 66,67 | mexh       | 34-50  | 59,46 | morl       | 82-110 | 51,35 | coif1      | 10-102 |
|   |       | <b>S10</b> |        |       | <b>S11</b> |        |       | <b>S12</b> |        |
| 4 |       |            |        |       |            |        | 70,27 | meyr       | 30-62  |
| 3 | 66,67 | morl       | 18-38  |       |            |        | 66,67 | haar       | 10-102 |
| 2 | 64,86 | sym4       | 10-98  |       |            |        | 63,96 | morl       | 78-98  |
| 1 | 62,16 | meyr       | 50-54  | 54,95 | coif3      | 38-74  | 59,46 | mexh       | 10-90  |
|   |       | <b>S13</b> |        |       | <b>S14</b> |        |       | <b>S15</b> |        |
| 4 | 72,07 | db3        | 10-30  | 62,16 | haar       | 14-18  |       |            |        |
| 3 | 71,17 | haar       | 14-30  | 61,26 | meyr       | 14-18  | 67,57 | coif1      | 10-22  |
| 2 | 67,57 | gaus1      | 22-86  | 57,66 | db2        | 34-58  | 66,67 | morl       | 58-86  |
| 1 | 61,26 | morl       | 70-78  | 56,76 | coif3      | 22-78  | 65,76 | mexh       | 58-78  |
|   |       | <b>S16</b> |        |       | <b>S17</b> |        |       | <b>S18</b> |        |
| 3 | 60,36 | morl       | 10-26  | 72,07 | db3        | 10-98  | 64,86 | meyr       | 10-26  |
| 2 | 59,46 | gaus1      | 22-82  | 71,17 | db1        | 42-50  | 63,96 | mexh       | 66-110 |
| 1 | 57,66 | coif3      | 82-102 | 69,37 | haar       | 10-62  | 59,46 | haar       | 34-66  |
|   |       | <b>S19</b> |        |       | <b>S20</b> |        |       | <b>S21</b> |        |
| 1 | 62,16 | morl       | 54-58  |       |            |        |       |            |        |
|   |       | <b>S22</b> |        |       |            |        |       |            |        |

10 sn PPG sinyallerinin sonuçlarında Katılımcı 20 için en yüksek SD %76,67 olarak elde edilirken, en düşük performans Katılımcı 12 için %53,33 olarak hesaplanmıştır. Tüm katılımcılar için ortalama SD %65,76 olarak elde edilmiştir. sym2, sym3, coif2 ve gaus1 hiç seçilmezken, morl dalgacığı 13 kez etkin ana dalgacık


olarak seçilmiştir. Ayrıca Şekil 18'e göre önerilen yöntemle 20 katılımcının SD performansları artırılırken Katılımcı 14 ve Katılımcı 16 için maksimum artış %7,78, ortalama sınıflandırma artışı ise %3,59 olarak elde edilmiştir.

**Tablo 6.** 10 sn'lik PPG verilerine ait AİADS sonuçları

| İ | SD    | D          | Ö      | SD    | D          | Ö      | SD    | D          | Ö      |
|---|-------|------------|--------|-------|------------|--------|-------|------------|--------|
| 4 |       |            |        | 67,78 | db2        | 74-98  |       |            |        |
| 3 |       |            |        | 66,67 | haar       | 62-74  |       |            |        |
| 2 | 75,56 | db3        | 46-74  | 63,33 | morl       | 10-62  |       |            |        |
| 1 | 73,33 | gaus2      | 74-86  | 62,22 | coif1      | 10-14  | 54,45 | db3        | 34-46  |
|   |       | <b>S1</b>  |        |       | <b>S2</b>  |        |       | <b>S3</b>  |        |
| 3 |       |            |        |       |            |        | 55,56 | morl       | 10-14  |
| 2 | 68,89 | db2        | 10-90  | 73,33 | sym4       | 54-102 | 54,45 | gaus3      | 62-90  |
| 1 | 64,45 | db3        | 26-54  | 72,22 | gaus3      | 10-14  | 53,33 | mexh       | 18-94  |
|   |       | <b>S4</b>  |        |       | <b>S5</b>  |        |       | <b>S6</b>  |        |
| 3 |       |            |        |       |            |        | 75,56 | morl       | 22-54  |
| 2 | 56,67 | morl       | 10-34  | 62,22 | morl       | 10-86  | 73,33 | mexh       | 46-74  |
| 1 | 55,56 | meyr       | 18-42  | 57,78 | gaus2      | 82-94  | 68,89 | meyr       | 22-54  |
|   |       | <b>S7</b>  |        |       | <b>S8</b>  |        |       | <b>S9</b>  |        |
| 3 |       |            |        | 70,00 | meyr       | 18-22  |       |            |        |
| 2 | 73,33 | morl       | 10-14  | 68,89 | mexh       | 14-82  | 53,33 | coif3      | 10-42  |
| 1 | 70,00 | mexh       | 14-66  | 65,56 | morl       | 90-94  | 52,22 | sym4       | 18-82  |
|   |       | <b>S10</b> |        |       | <b>S11</b> |        |       | <b>S12</b> |        |
| 5 |       |            |        |       |            |        | 67,78 | db1        | 22-42  |
| 4 |       |            |        |       |            |        | 65,56 | morl       | 18-62  |
| 3 |       |            |        | 61,11 | db2        | 14-42  | 64,45 | mexh       | 26-42  |
| 2 | 58,89 | mexh       | 16-106 | 56,67 | meyr       | 46-66  | 62,22 | meyr       | 46-66  |
| 1 | 55,56 | gaus2      | 62-110 | 53,33 | mexh       | 78-110 | 61,11 | haar       | 14-34  |
|   |       | <b>S13</b> |        |       | <b>S14</b> |        |       | <b>S15</b> |        |
| 3 | 75,56 | mexh       | 10-86  |       |            |        | 68,89 | morl       | 58-70  |
| 2 | 74,45 | gaus2      | 50-106 | 58,89 | sym4       | 26-50  | 67,78 | meyr       | 42-102 |
| 1 | 67,78 | morl       | 66-86  | 57,78 | db2        | 18-50  | 65,56 | mexh       | 58-70  |
|   |       | <b>S16</b> |        |       | <b>S17</b> |        |       | <b>S18</b> |        |
| 4 |       |            |        | 76,67 | meyr       | 10-14  |       |            |        |
| 3 | 60,00 | meyr       | 10-34  | 75,56 | mexh       | 98-110 | 65,56 | coif1      | 14-22  |
| 2 | 58,89 | haar       | 50-86  | 73,33 | db3        | 10-38  | 62,22 | haar       | 10-34  |
| 1 | 57,78 | morl       | 74-110 | 72,22 | morl       | 46-58  | 58,89 | morl       | 54-94  |
|   |       | <b>S19</b> |        |       | <b>S20</b> |        |       | <b>S21</b> |        |
| 1 | 66,67 | coif1      | 50-74  |       |            |        |       |            |        |
|   |       | <b>S22</b> |        |       |            |        |       |            |        |




### Artış oranı (%)




**Şekil 17.** 8 sn'lik PPG verileri için artış oranları

Önerilen yöntemin başarısını ortaya koymak için istatistiksel öznitelikler ve band gücü öznitelikleri ile VS1 ayrı ayrı sınıflandırma işlemine tabi tutulmuştur. İstatistiksel özniteliklere ait sonuçlar 6 sn, 8 sn ve 10 sn'lik sinyal parçaları için Şekil 19, Şekil 20 ve Şekil 21'de verilmiştir. 6 sn'lik istatistiksel öznitelik sonuçlarına göre SD'ler %44,13 (S3 katılımcısı için) ile %75,76 (S16 katılımcısı için) değişmektedir. Tüm katılımcıların SD ortalamaları ise %58,64'tür. Bu şekilde de görüldüğü gibi S3, S6, S12 ve S14 katılımcıları için SD'ler %50'nin de altındadır.

### Artış oranı(%)




**Şekil 18.** 10 sn'lik PPG verileri için artış oranları



**Şekil 19.** İstatistiksel özniteliklerin 6 sn'lik segment sonuçları


Şekil 20'de verilen 8 sn'lik istatistiksel öznitelik sonuçlarına göre SD'ler %46,31 (S3 katılımcısı için) ile %73,87 (S16 katılımcısı için) değişmektedir. Tüm katılımcıların SD ortalamaları ise %59,15'tir. Bu şekilde de görüldüğü gibi S3, S6, S12, S14 ve S19 katılımcıları için SD'ler %50'nin de altındadır.



**Şekil 20.** İstatistiksel özniteliklerin 8 sn'lik segment sonuçları


Şekil 21'de verilen 10 sn'lik istatistiksel öznitelik sonuçlarına göre SD'ler %43,33 (S14 katılımcısı için) ile %80 (S16 katılımcısı için) değişmektedir. Tüm

katılımcıların SD ortalamaları ise %60,05'tir. Bu şekilde de görüldüğü gibi S3, S6, S14 ve S19 katılımcıları için SD'ler %50'nin de altındadır. İstatistiksel özniteliklere ait sonuçlar kendi içinde karşılaştırıldığında en yüksek performansın 10 sn'lik PPG segmentleri için elde edildiği görülmektedir. Bu değer önerilen yöntemin performansından %5,71 daha düşüktür. Benzer şekilde 6 sn'lik segmentlere göre önerilen yöntem %2,27 daha yüksek performans sağlarken, 8 sn'lik segmentler için %5,22 daha yüksek performans sağlamıştır.




**Şekil 21.** İstatistiksel özniteliklerin 10 sn'lik segment sonuçları

BG özniteliğine ait sonuçlar 6 sn, 8 sn ve 10 sn'lik sinyal parçaları için Şekil 22, Şekil 23 ve Şekil 24'te verilmiştir. 6 sn'lik BG öznitelik sonuçlarına göre SD'ler %35,15 (S12 katılımcısı için) ile %52,85 (S10 katılımcısı için) değişmektedir. Tüm katılımcıların SD ortalamaları ise %43,17'dir. Bu şekilde de görüldüğü gibi sadece S10 kişisine ait SD performansı %50'nin üzerindedir. Önerilen yöntemin 6 sn'lik segment sonuçları ile ortalama SD düzeyinde karşılaştırma yapıldığında önerilen yöntemin %17,74 daha yüksek performans sağladığı görülmektedir.




**Şekil 22.** Band gücü özniteliklerin 6 sn'lik segment sonuçları

8 sn'lik BG öznitelik sonuçlarına göre SD'ler %43,24 (S14 katılımcısı için) ile %70,20 (S20 katılımcısı için) değişmektedir. Tüm katılımcıların SD ortalamaları ise %54,79'dur. Bu şekilde de görüldüğü gibi S3, S6, S8, S12, S13 ve S14 katılımcıları için SD performansları %50'nin altındadır. Önerilen yöntemin 8 sn'lik segment sonuçları ile ortalama SD düzeyinde karşılaştırma yapıldığında önerilen yöntemin %9,59 daha yüksek performans sağladığı görülmektedir.



**Şekil 23.** Band gücü özniteliklerin 8 sn'lik segment sonuçları

10 sn'lik BG öznitelik sonuçlarına göre SD'ler %36,08 (S12 katılımcısı için) ile %52,05 (S10 katılımcısı için) değişmektedir. Tüm katılımcıların SD ortalamaları ise %43,14'tür. Bu şekilde de görüldüğü gibi 6 sn'lik sonuçlarda olduğu gibi sadece S10 kişisine ait SD performansı %50'nin üzerindedir. Önerilen yöntemin 10 sn'lik segment sonuçları ile ortalama SD düzeyinde karşılaştırma yapıldığında önerilen yöntemin %22,62 daha yüksek performans sağladığı görülmektedir.



Şekil 24. Band gücü özniteliklerin 10 sn'lik segment sonuçları


### 3.2. Veri Seti 2'den Elde Edilen Bulgular

Veri seti 2 ile tansiyon hastalığının PPG işaretleri ile tespit edilmesi amaçlanmış olup, sınıflandırma işlemi ile tansiyon hastası ya da sağlıklı (tansiyon hastası değil) olarak etiketleme (sınıflandırma) yapılmıştır. Veri seti sadece 2,1 sn'lik segmentler halinde kaydedildiği için PPG işaretlerinin alt segmentleri analiz edilmemiştir. Ancak, AİADS yöntemi için DDK'lerin SSD ve OD hesaplanarak bu veri seti için öznitelik olarak dikkate alınmıştır. Aşağıda bu değerlere ait AİADS sonuçları tablolar halinde verilmiştir. Bu tabloda  $k$ ;  $k$ -EYK sınıflandırıcısının tespit edilen  $k$  değerini ifade etmektedir. Tablo 7'de verilen tüm DDK'lerden hesaplanan özniteliklerin birlikte kullanımı bulgularına göre 2 iterasyona sonucunda %73,39 SD performansı elde edilmiştir. Bu 2 iterasyon sırasıyla gaus2 dalgacığı 61-73 ölçek aralığı ve mexh dalgacığı 1-41 ölçek aralığı kombinasyonlarından oluşmaktadır.

**Tablo 7.** VS2 için elde edilen AİADS sonuçları

| Öznitelik | SD    | k  | D     | Ö     |
|-----------|-------|----|-------|-------|
| OD+SSD    | 72,20 | 10 | gaus2 | 61-73 |
|           | 73,39 | 9  | mexh  | 1-41  |


Önerilen yöntemin başarısını ortaya koymak için yukarıda da değinildiği gibi literatürde sık kullanılan öznitelikler elde edilerek de VS2 test edilmiştir. VS2, Şekil 8’de de görüldüğü gibi yüksek frekanslı gürültüye maruz kalmıştır. Adil bir kıyaslama yapabilmek adına PPG işaretleri öncelikle band geçiren süzgeçten geçirilmiş ardından öznitelik çıkarma aşamasına geçilmiştir. Bu aşamadaki genel akış şeması Şekil 25’te gösterilmiştir.



**Şekil 25.** Band geçiren filtreye dayalı akış şeması


Veri seti öncelikle belirlenen alt kesim frekansı (L) ve üst kesim frekansına (H) göre band geçiren filtreden geçirilir. Daha sonra eğitim ve test seti olarak 2 parçaya bölünür ve öznitelikler çıkarılır. Sınıflandırıcılar eğitim setine dayalı öznitelik vektörleri ve K-küme çapraz onaylama yöntemi ile eğitilir. Test aşamasında ise test kümesinden çıkarılan öznitelikler eğitilen sınıflandırıcı ile hipertansiyon/sağlıklı şeklinde sınıflandırılır. Band geçiren filtre Şekil 26’da gösterildiği gibi  $H > L$  olmak

üzere 0-10 Hz aralığında 0,1 Hz çözünürlükte L ve H noktaları ile daralma/genişleme ve kaydırma ile ilgili aralıktaki tüm olası band geçiren filtreler test edilmektedir. En yüksek test SD sağlayan noktalar en uygun band geçiren filtre parametreleri (L ve H) olarak belirlenmiştir.



Şekil 26. Band geçiren filtre


Bu aşamada kısa zamanlı PPG işaretlerinin hipertansiyon hastalığının tespiti için kullanılabilecek en uygun frekans aralıkları tespit edilerek BG ve istatistiksel öznitelikler çıkarılmıştır. *k*-EYK sınıflandırıcısı için 0-10 Hz aralığında olası tüm band geçiren filtreler için elde edilen sonuçlar sırasıyla Şekil 27’de gösterilmektedir. Bu şekilde sonuçlar renk kodlaması ile verilmiş olup, koyu mavi görüntüdeki en düşük, açık sarı ise en yüksek SD elde edilen noktaları göstermektedir. Köşegenin alt kısmı  $L > H$  bölgeleri olduğu için bu bölgelerde SD hesaplanmamıştır. Elde edilen sonuçlara göre hipertansiyon hastalığının kısa zamanlı PPG ile en uygun 3,2-5,7 Hz bandı için %72,02 SD elde edilmiştir. En düşük doğruluklar 0-3 Hz ve 8-10 Hz aralıkları içerisine düşen olası band geçiren filtreler için elde edildiği yine verilen sonuçlarda görülmektedir.



**Şekil 27.** *k-EYK* için olası tüm band geçiren filtreleme sonuçları

VS2 istatistiksel öznitelikler ile de sınıflandırılmış ve elde edilen sonuçlar Şekil 28’de gösterilmiştir. Bu şekilde yatay eksen uygulanan band geçiren süzgeç sayısını (toplam 1275 süzgeç aralığı) ve düşey eksen uygulanan her bir band geçiren süzgece karşılık düşen SD’leri göstermektedir. Band geçiren süzgeç 0,2 Hz çözünürlükle 0-10 Hz aralığında taranmıştır. Buna göre en yüksek sınıflandırma performansı 669 (3-7,8 Hz), 696 (3,2-6,4 Hz) ve 812 (4-4,4 Hz) sıradaki band geçiren süzgeçlerle %72,02 olarak hesaplanmıştır. En düşük performans ise 1248. band geçiren süzgeç olarak uygulanan 8,6-8,8 Hz’lik süzgeç ile %58,26 olarak hesaplanmıştır. Elde edilen bu sonuçlara önerilen yöntem hem BG hem de istatistiksel öznitelik sonuçlarından %1,37 daha yüksektir.





**Şekil 28.** VS2 için istatistiksel öznitelik sonuçları

### 3.3. Veri Seti 3 için Elde Edilen Bulgular

Bu tez çalışmasında önerilen yöntemin geçerliliğini ispatlamak için kişilerin skuat, step hareketleri ve dinlenme durumunda kaydedilen PPG veri seti de kullanılmıştır. Bu veri seti içeriği genel anlamı ile insan faaliyeti izleme (*ing.* human activity monitoring) olarak da bilinmektedir. Çalışmada yalnızca 1 sn, 2 sn ve 3 sn pencere uzunluğu PPG segmentleri kullanılarak pencere uzunlukları, örtüşmeyen ve çeşitli örtüşen zaman periyotları ile ele alınmıştır. Önerilen yöntemin veri seti içerisindeki geçerliliği ise diğer veri setlerinde olduğu gibi literatürde bu alanda sıklıkla kullanılan BG ve istatistiksel öznitelikler kullanılarak ispatlanmıştır. Elde edilen sonuçlar kişi bazlı olarak aşağıda tablolar halinde verilmiştir. Tablo 8, Tablo 9 ve Tablo 10'da VS3'te S1 kişinin 1 sn, 2 sn ve 3 sn'lik pencere uzunluklarına (segmentlerine) ait örtüşme olmayan ve farklı örtüşme uzunluklarına ait AİADS sonuçları verilmiştir. Bu sonuçlardan da görüldüğü gibi 1 sn'lik segment için en yüksek SD performansı %81,19 olarak 0,25 sn'lik örtüşme ve mexh, morl ve haar dalgacıklarından oluşan 3 iterasyonla hesaplanmıştır. En düşük performans ise %79,06 olarak örtüşme olmadığı durumda 2 iterasyonla hesaplanmıştır. 2 sn'lik segment için en yüksek SD performansı %81,36 olarak yine 0,25 sn'lik örtüşme ile hesaplanmıştır. En düşük performans ise %78,60 olarak yine örtüşme olmadığı durumda hesaplanmıştır. 2 sn'lik sonuçlara dikkat çeken önemli noktalardan biri ana dalgacık olarak ya morl ya da meyr seçilmiştir. 3 sn'lik segment için en yüksek SD performansı %83,18 olarak 0,25 sn'lik örtüşme ve meyr dalgacığı ile tek iterasyonla hesaplanmıştır.

En düşük performans ise %81,16 olarak 1 sn'lik örtüşme durumunda yine tek iterasyonla hesaplanmıştır.

**Tablo 8.** S1 kişinin 1 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD    | k  | D     | Ö     |
|---------------------|---|-------|----|-------|-------|
| Örtüşme yok         | 1 | 78,06 | 12 | mexh  | 33-49 |
|                     | 2 | 79,06 | 12 | coif1 | 1-33  |
| 0,25 sn'lik örtüşme | 1 | 79,92 | 19 | mexh  | 1-65  |
|                     | 2 | 80,93 | 18 | morl  | 33-49 |
|                     | 3 | 81,19 | 18 | haar  | 1-17  |
| 0,5 sn'lik örtüşme  | 1 | 78,12 | 12 | mexh  | 33-49 |
|                     | 2 | 80,72 | 5  | morl  | 17-65 |
|                     | 3 | 80,98 | 5  | sym2  | 1-17  |

**Tablo 9.** S1 kişinin 2 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD    | k  | D    | Ö     |
|---------------------|---|-------|----|------|-------|
| Örtüşme yok         | 1 | 78,60 | 18 | morl | 1-33  |
| 0,25 sn'lik örtüşme | 1 | 81,07 | 20 | morl | 33-97 |
|                     | 2 | 81,36 | 19 | meyr | 1-17  |
| 0,5 sn'lik örtüşme  | 1 | 78,93 | 18 | morl | 33-49 |
|                     | 2 | 79,95 | 14 | meyr | 33-49 |
| 1 sn'lik örtüşme    | 1 | 79,36 | 4  | morl | 1-17  |

**Tablo 10.** S1 kişinin 3 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD    | k  | D    | Ö     |
|---------------------|---|-------|----|------|-------|
| Örtüşme yok         | 1 | 81,73 | 16 | morl | 1-81  |
|                     | 2 | 82,23 | 10 | haar | 17-49 |
| 0,25 sn'lik örtüşme | 1 | 83,18 | 9  | meyr | 1-17  |
| 0,5 sn'lik örtüşme  | 1 | 81,86 | 8  | morl | 1-33  |
| 1 sn'lik örtüşme    | 1 | 81,16 | 14 | mexh | 33-49 |
|                     | 1 | 81,03 | 14 | mexh | 1-17  |
| 1,5 sn'lik örtüşme  | 2 | 81,28 | 20 | morl | 17-65 |
|                     | 3 | 81,54 | 14 | haar | 1-17  |

Tablo 11, Tablo 12 ve Tablo 13'te VS3'te S2 kişinin 1 sn, 2 sn ve 3 sn'lik pencere uzunluklarına ait AİADS sonuçları verilmiştir. Bu sonuçlardan da görüldüğü gibi 1 sn'lik segment için en yüksek SD performansı %99,40 olarak örtüşme olmayan durumda ve morl dalgacığı ile tek iterasyonla hesaplanmıştır. En düşük performans ise %98,90 olarak 0,5 sn'lik örtüşme durumda 2 iterasyonla hesaplanmıştır. 2 sn'lik

segment için en yüksek SD performansı %100 olarak örtüşme olmayan durumda 2 iterasyonla hesaplanmıştır. En düşük performans ise %98,94 olarak tek iterasyonla 0,5 sn'lik örtüşme durumunda hesaplanmıştır. 3 sn'lik segment için tüm örtüşme durumlarında sadece tek iterasyon oluşmuş ve en yüksek SD performansı %100 olarak 0,25 sn'lik ve 1 sn'lik örtüşme durumlarında hesaplanmıştır. En düşük performans ise %98,49 olarak 0,5 sn'lik örtüşme durumunda yine tek iterasyonla hesaplanmıştır. S2 için SD performansları genel olarak %100 seviyelerine yakın olduğundan çoğunlukla tek iterasyonla sonuca ulaşıldığı görülmektedir.

**Tablo 11.** S2 kişinin 1 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD    | k  | D    | Ö    |
|---------------------|---|-------|----|------|------|
| Örtüşme yok         | 1 | 99,40 | 1  | morl | 1-97 |
| 0,25 sn'lik örtüşme | 1 | 98,96 | 1  | mexh | 1-81 |
| 0,5 sn'lik örtüşme  | 1 | 98,00 | 5  | meyr | 1-49 |
|                     | 2 | 98,90 | 13 | morl | 1-17 |

**Tablo 12.** S2 kişinin 2 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD     | k | D    | Ö    |
|---------------------|---|--------|---|------|------|
| Örtüşme yok         | 1 | 99,60  | 7 | meyr | 1-17 |
|                     | 2 | 100,00 | 1 | morl | 1-17 |
| 0,25 sn'lik örtüşme | 1 | 98,94  | 7 | morl | 1-17 |
| 0,5 sn'lik örtüşme  | 1 | 99,40  | 4 | mexh | 1-65 |
| 1 sn'lik örtüşme    | 1 | 99,40  | 3 | morl | 1-17 |
|                     | 2 | 99,60  | 1 | meyr | 1-49 |

**Tablo 13.** S2 kişinin 3 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD     | k | D     | Ö     |
|---------------------|---|--------|---|-------|-------|
| Örtüşme yok         | 1 | 99,39  | 3 | sym2  | 1-81  |
| 0,25 sn'lik örtüşme | 1 | 100,00 | 3 | mexh  | 1-49  |
| 0,5 sn'lik örtüşme  | 1 | 98,49  | 1 | mexh  | 1-33  |
| 1 sn'lik örtüşme    | 1 | 100,00 | 1 | coif1 | 1-49  |
| 1,5 sn'lik örtüşme  | 1 | 99,69  | 1 | haar  | 65-81 |

Tablo 14, Tablo 15 ve Tablo 16'da VS3'te S3 kişinin 1 sn, 2 sn ve 3 sn'lik pencere uzunluklarına ait AİADS sonuçları verilmiştir. Bu sonuçlardan da görüldüğü gibi 1 sn'lik segment için en yüksek SD performansı %83,33 olarak 0,25 sn'lik örtüşme durumda ve sırasıyla mexh ve gauss dalgacıkları ile 2 iterasyonla

hesaplanmıştır. En düşük performans ise %81,81 olarak 0,5 sn'lik örtüşme durumda 3 iterasyonla hesaplanmıştır. 2 sn'lik segment için en yüksek SD performansı %87,10 olarak yine 0,25 sn'lik örtüşme durumunda sırasıyla meyr ve morl ana dalgacıkları ile 2 iterasyonla hesaplanmıştır. En düşük performans ise %82,72 olarak tek iterasyonla örtüşme olmayan durumda sym2 ana dalgacığı ile hesaplanmıştır. 3 sn'lik segment için tüm örtüşme durumlarında sadece tek iterasyon oluşmuş ve en yüksek SD performansı coif1 ana dalgacığı ile %86,13 olarak 0,25 sn'lik örtüşme durumunda hesaplanmıştır. En düşük performans ise %84,13 olarak örtüşme olmayan durumda yine tek iterasyonla gaus1 ana dalgacığı ile hesaplanmıştır.

**Tablo 14.** S3 kişinin 1 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD    | k  | D     | Ö     |
|---------------------|---|-------|----|-------|-------|
| Örtüşme yok         | 1 | 81,93 | 5  | sym2  | 1-49  |
|                     | 2 | 82,20 | 10 | morl  | 1-49  |
|                     | 3 | 82,72 | 9  | coif1 | 33-97 |
| 0,25 sn'lik örtüşme | 1 | 82,75 | 8  | mexh  | 81-97 |
|                     | 2 | 83,33 | 10 | gaus1 | 17-49 |
| 0,5 sn'lik örtüşme  | 1 | 81,41 | 16 | gaus1 | 17-81 |
|                     | 2 | 81,68 | 5  | haar  | 49-97 |
|                     | 3 | 81,81 | 5  | db1   | 1-17  |

**Tablo 15.** S3 kişinin 2 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD    | k  | D     | Ö     |
|---------------------|---|-------|----|-------|-------|
| Örtüşme yok         | 1 | 82,72 | 13 | sym2  | 1-65  |
| 0,25 sn'lik örtüşme | 1 | 86,18 | 5  | meyr  | 33-97 |
|                     | 2 | 87,10 | 6  | morl  | 1-17  |
| 0,5 sn'lik örtüşme  | 1 | 82,68 | 6  | gaus1 | 65-97 |
|                     | 2 | 83,07 | 6  | mexh  | 17-97 |
|                     | 3 | 83,47 | 6  | sym2  | 49-65 |
| 1 sn'lik örtüşme    | 1 | 83,78 | 9  | gaus1 | 1-81  |
|                     | 2 | 84,04 | 11 | sym2  | 49-65 |

**Tablo 16.** S3 kişinin 3 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD    | k  | D     | Ö     |
|---------------------|---|-------|----|-------|-------|
| Örtüşme yok         | 1 | 84,13 | 12 | gaus1 | 33-65 |
| 0,25 sn'lik örtüşme | 1 | 86,13 | 4  | coif1 | 1-81  |
| 0,5 sn'lik örtüşme  | 1 | 84,77 | 10 | morl  | 33-97 |
| 1 sn'lik örtüşme    | 1 | 84,87 | 9  | gaus1 | 17-81 |
| 1,5 sn'lik örtüşme  | 1 | 84,62 | 19 | gaus1 | 33-49 |

Tablo 17, Tablo 18 ve Tablo 19'da VS3'te S4 kişinin 1 sn, 2 sn ve 3 sn'lik pencere uzunluklarına ait AİADS sonuçları verilmiştir. Bu tablolardan da görüldüğü gibi 1 sn'lik segment için en yüksek SD performansı %98,99 olarak 0,25 sn'lik örtüşme durumunda ve mexh dalgacığı ile tek iterasyonla hesaplanmıştır. En düşük performans ise %97,86 olarak örtüşme olmayan durumda yine tek iterasyonla hesaplanmıştır. 2 sn'lik segment için en yüksek SD performansı %99,46 olarak örtüşme olmayan durumda ve morl ana dalgacığı ile tek iterasyonla hesaplanmıştır. En düşük performans ise %98,10 olarak iki iterasyonla 0,25 sn'lik örtüşme durumunda hesaplanmıştır. 3 sn'lik segment için tüm örtüşme durumlarında sadece tek iterasyon oluşmuş ve en yüksek SD performansı %100 olarak örtüşme olmayan durumda hesaplanmıştır. En düşük performans ise %99,25 olarak 0,25 sn'lik örtüşme durumunda yine tek iterasyonla hesaplanmıştır. S4 için SD performansları genel olarak %100 seviyelerine yakın olduğundan çoğunlukla tek iterasyonla sonuca ulaşıldığı görülmektedir. Benzer durum S2 kişisi içinde ortaya çıktığı yukarıda belirtilmişti. Bu kişi için dikkat çeken bir diğer önemli husus çoğunlukla mexh ve morl ana dalgacıklarının seçilmiş olmasıdır.

**Tablo 17.** S4 kişinin 1 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD    | k | D    | Ö     |
|---------------------|---|-------|---|------|-------|
| Örtüşme yok         | 1 | 97,86 | 8 | morl | 1-17  |
| 0,25 sn'lik örtüşme | 1 | 98,99 | 3 | mexh | 1-17  |
|                     | 1 | 98,11 | 5 | mexh | 1-97  |
| 0,5 sn'lik örtüşme  | 2 | 98,38 | 5 | meyr | 17-49 |
|                     | 3 | 98,52 | 5 | morl | 65-81 |

**Tablo 18.** S4 kişinin 2 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | <i>i</i> | SD    | <i>k</i> | <i>D</i> | Ö    |
|---------------------|----------|-------|----------|----------|------|
| Örtüşme yok         | 1        | 99,46 | 5        | morl     | 1-17 |
| 0,25 sn'lik örtüşme | 1        | 97,63 | 1        | morl     | 1-17 |
|                     | 2        | 98,10 | 4        | mexh     | 1-81 |
| 0,5 sn'lik örtüşme  | 1        | 98,78 | 4        | morl     | 1-17 |
| 1 sn'lik örtüşme    | 1        | 98,63 | 18       | morl     | 1-33 |
|                     | 2        | 98,90 | 4        | sym2     | 1-65 |

**Tablo 19.** S4 kişinin 3 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | <i>i</i> | SD     | <i>k</i> | <i>D</i> | Ö     |
|---------------------|----------|--------|----------|----------|-------|
| Örtüşme yok         | 1        | 100,00 | 1        | mexh     | 1-73  |
| 0,25 sn'lik örtüşme | 1        | 99,25  | 6        | mexh     | 1-65  |
| 0,5 sn'lik örtüşme  | 1        | 99,31  | 5        | mexh     | 1-97  |
| 1 sn'lik örtüşme    | 1        | 99,45  | 20       | mexh     | 1-97  |
| 1,5 sn'lik örtüşme  | 1        | 99,58  | 3        | coif1    | 49-97 |

Tablo 20, Tablo 21 ve Tablo 22'de VS3'te S5 kişinin 1 sn, 2 sn ve 3 sn'lik pencere uzunluklarına ait AİADS sonuçları verilmiştir. Bu sonuçlardan da görüldüğü gibi 1 sn'lik segment için en yüksek SD performansı %85,36 olarak örtüşme olmayan durumda ve sırasıyla coif1 ve morl ana dalgacıkları ile 2 iterasyonla hesaplanmıştır. En düşük performans ise %83,89 olarak 0,5 sn'lik örtüşme durumunda tek iterasyonla hesaplanmıştır. 2 sn'lik segment için en yüksek SD performansı %87,71 olarak örtüşme olmayan durumda sırasıyla mexh, morl, gaus1 ve meyr ana dalgacıkları ile 4 iterasyonla hesaplanmıştır. En düşük performans ise %83,90 olarak iki iterasyonla 0,25 sn'lik örtüşme durumunda morl ve sym2 ana dalgacıkları ile hesaplanmıştır. 3 sn'lik segment için en yüksek SD performansı mexh, morl, sym2, meyr ve haar ana dalgacıkları ile %85,71 olarak 1 sn'lik örtüşme durumunda 5 iterasyonla hesaplanmıştır. En düşük performans ise %81,54 olarak 0,25 sn'lik örtüşme durumunda iki iterasyonla sym2 ve morl ana dalgacıkları ile hesaplanmıştır.

**Tablo 20.** S5 kişinin 1 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD    | k | D     | Ö     |
|---------------------|---|-------|---|-------|-------|
| Örtüşme yok         | 1 | 84,53 | 6 | coif1 | 49-97 |
|                     | 2 | 85,36 | 6 | morl  | 1-17  |
|                     | 1 | 83,54 | 6 | coif1 | 81-97 |
|                     | 2 | 83,96 | 4 | mexh  | 33-65 |
| 0,25 sn'lik örtüşme | 3 | 84,17 | 4 | haar  | 49-81 |
|                     | 4 | 84,38 | 4 | morl  | 1-33  |
|                     | 5 | 84,58 | 4 | meyr  | 1-17  |
| 0,5 sn'lik örtüşme  | 1 | 83,89 | 7 | coif1 | 65-97 |

**Tablo 21.** S5 kişinin 2 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD    | k  | D     | Ö     |
|---------------------|---|-------|----|-------|-------|
| Örtüşme yok         | 1 | 86,03 | 8  | mexh  | 1-97  |
|                     | 2 | 86,59 | 6  | morl  | 17-97 |
|                     | 3 | 87,15 | 3  | gaus1 | 65-81 |
|                     | 4 | 87,71 | 3  | meyr  | 1-49  |
| 0,25 sn'lik örtüşme | 1 | 83,42 | 7  | morl  | 49-65 |
|                     | 2 | 83,90 | 8  | sym2  | 1-17  |
| 0,5 sn'lik örtüşme  | 1 | 85,77 | 18 | sym2  | 1-33  |
|                     | 1 | 83,85 | 9  | mexh  | 17-81 |
| 1 sn'lik örtüşme    | 2 | 84,70 | 7  | morl  | 49-65 |
|                     | 3 | 84,99 | 7  | meyr  | 1-17  |

**Tablo 22.** S5 kişinin 3 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD    | k  | D    | Ö     |
|---------------------|---|-------|----|------|-------|
| Örtüşme yok         | 1 | 83,90 | 16 | meyr | 1-81  |
| 0,25 sn'lik örtüşme | 1 | 80,77 | 6  | sym2 | 1-81  |
|                     | 2 | 81,54 | 6  | morl | 1-17  |
| 0,5 sn'lik örtüşme  | 1 | 83,80 | 6  | morl | 1-81  |
|                     | 2 | 84,51 | 5  | haar | 1-17  |
|                     | 1 | 82,86 | 5  | mexh | 65-97 |
| 1 sn'lik örtüşme    | 2 | 84,00 | 5  | morl | 65-81 |
|                     | 3 | 84,57 | 5  | sym2 | 49-65 |
|                     | 4 | 85,14 | 5  | meyr | 1-97  |
|                     | 5 | 85,71 | 5  | haar | 1-49  |
|                     | 1 | 84,48 | 7  | morl | 65-97 |
| 1,5 sn'lik örtüşme  | 2 | 84,91 | 8  | meyr | 17-33 |
|                     | 3 | 85,35 | 5  | mexh | 1-33  |

Tablo 23, Tablo 24 ve Tablo 25'te VS3'te S6 kişinin 1 sn, 2 sn ve 3 sn'lik pencere uzunluklarına ait AİADS sonuçları verilmiştir. Bu sonuçlardan da görüldüğü gibi 1 sn'lik segment için en yüksek SD performansı %74,37 olarak 0,5 sn'lik örtüşme durumunda ve sırasıyla gaus1, morl, meyr, haar ve db1 ana dalgacıkları ile 5 iterasyonla hesaplanmıştır. En düşük performans ise %73,94 olarak 0,25 sn'lik örtüşme durumunda 3 iterasyonla hesaplanmıştır. 2 sn'lik segment için en yüksek SD performansı %75,23 olarak örtüşme olmayan durumda sırasıyla gaus1, mexh, sym2 ve morl ana dalgacıkları ile 4 iterasyonla hesaplanmıştır. En düşük performans ise %73,01 olarak iki iterasyonla 0,5 sn'lik örtüşme durumunda gaus1 ve sym2 ana dalgacıkları ile hesaplanmıştır. 3 sn'lik segment için en yüksek SD performansı gaus1, meyr ve haar ana dalgacıkları ile %78,74 olarak 0,5 sn'lik örtüşme durumunda 3 iterasyonla hesaplanmıştır. En düşük performans ise %73,68 olarak 1,5 sn'lik örtüşme durumunda tek iterasyonla gaus1 ana dalgacığı ile hesaplanmıştır.

**Tablo 23.** S6 kişinin 1 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD    | k  | D     | Ö     |
|---------------------|---|-------|----|-------|-------|
| Örtüşme yok         | 1 | 71,27 | 8  | gaus1 | 17-49 |
|                     | 2 | 73,08 | 4  | coif1 | 33-65 |
|                     | 3 | 73,98 | 4  | meyr  | 17-33 |
| 0,25 sn'lik örtüşme | 1 | 72,74 | 10 | gaus1 | 49-81 |
|                     | 2 | 73,42 | 8  | sym2  | 49-97 |
|                     | 3 | 73,94 | 6  | morl  | 33-97 |
| 0,5 sn'lik örtüşme  | 1 | 72,55 | 7  | gaus1 | 49-65 |
|                     | 2 | 73,12 | 8  | morl  | 33-81 |
|                     | 3 | 73,92 | 6  | meyr  | 65-81 |
|                     | 4 | 74,26 | 6  | haar  | 65-97 |
|                     | 5 | 74,37 | 6  | db1   | 1-17  |



**Tablo 24.** S6 kişinin 2 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD    | k  | D     | Ö     |
|---------------------|---|-------|----|-------|-------|
| Örtüşme yok         | 1 | 72,48 | 4  | gaus1 | 17-65 |
|                     | 2 | 73,85 | 1  | mexh  | 33-49 |
|                     | 3 | 74,77 | 1  | sym2  | 49-97 |
|                     | 4 | 75,23 | 1  | morl  | 17-81 |
| 0,25 sn'lik örtüşme | 1 | 70,97 | 7  | gaus1 | 33-65 |
|                     | 2 | 72,98 | 4  | mexh  | 17-97 |
|                     | 3 | 73,39 | 3  | coif1 | 17-65 |
|                     | 4 | 73,79 | 4  | sym2  | 1-97  |
| 0,5 sn'lik örtüşme  | 1 | 70,93 | 6  | gaus1 | 49-97 |
|                     | 2 | 73,01 | 3  | sym2  | 65-81 |
| 1 sn'lik örtüşme    | 1 | 71,26 | 11 | gaus1 | 65-97 |
|                     | 2 | 73,33 | 6  | mexh  | 17-33 |
|                     | 3 | 73,56 | 6  | morl  | 1-49  |

**Tablo 25.** S6 kişinin 3 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD    | k  | D     | Ö     |
|---------------------|---|-------|----|-------|-------|
| Örtüşme yok         | 1 | 75,34 | 11 | gaus1 | 65-97 |
|                     | 2 | 76,71 | 8  | meyr  | 1-65  |
|                     | 3 | 77,40 | 8  | coif1 | 17-33 |
| 0,25 sn'lik örtüşme | 1 | 72,15 | 1  | gaus1 | 17-49 |
| 0,5 sn'lik örtüşme  | 1 | 77,01 | 16 | gaus1 | 33-49 |
|                     | 2 | 77,59 | 15 | meyr  | 33-81 |
|                     | 3 | 78,74 | 15 | haar  | 1-33  |
| 1 sn'lik örtüşme    | 1 | 73,73 | 3  | gaus  | 17-33 |
|                     | 2 | 74,19 | 3  | morl  | 1-17  |
| 1,5 sn'lik örtüşme  | 1 | 73,68 | 4  | gaus1 | 17-33 |

Tablo 26, Tablo 27 ve Tablo 28'de VS3'te S7 kişinin 1 sn, 2 sn ve 3 sn'lik pencere uzunluklarına ait AİADS sonuçları verilmiştir. Bu sonuçlardan da görüldüğü gibi 1 sn'lik segment için en yüksek SD performansı %85,01 olarak 0,5 sn'lik örtüşme durumunda ve sırasıyla mexh, coif3, gaus2, meyr ve morl ana dalgacıkları ile 5 iterasyonla hesaplanmıştır. En düşük performans ise %84,46 olarak örtüşme olmayan durumda 4 iterasyonla hesaplanmıştır. 2 sn'lik segment için en yüksek SD performansı %81,82 olarak 0,5 sn'lik örtüşme durumunda sırasıyla morl, gaus1, sym4 ve coif2 ana dalgacıkları ile 4 iterasyonla hesaplanmıştır. En düşük performans ise %77,49 olarak iki iterasyonla örtüşme olmayan durumda gaus2 ve haar ana dalgacıkları ile hesaplanmıştır. 3 sn'lik segment için en yüksek SD performansı mexh, coif3, sym4 ve

gaus3 ana dalgacıkları ile %79,68 olarak 1 sn'lik örtüşme durumunda 4 iterasyonla hesaplanmıştır. En düşük performans ise %76 olarak 0,5 sn'lik örtüşme durumunda iki iterasyonla mexh ve gaus2 ana dalgacı ile hesaplanmıştır.

**Tablo 26.** S7 kişinin 1 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD    | k | D     | Ö     |
|---------------------|---|-------|---|-------|-------|
| Örtüşme yok         | 1 | 82,90 | 3 | mexh  | 53-73 |
|                     | 2 | 83,94 | 6 | gaus3 | 45-69 |
|                     | 3 | 84,20 | 6 | db3   | 17-81 |
|                     | 4 | 84,46 | 6 | meyr  | 1-21  |
| 0,25 sn'lik örtüşme | 1 | 81,25 | 6 | gaus2 | 53-97 |
|                     | 2 | 83,40 | 5 | mexh  | 21-29 |
|                     | 3 | 84,18 | 3 | gaus3 | 69-73 |
|                     | 4 | 84,57 | 3 | meyr  | 21-97 |
| 0,5 sn'lik örtüşme  | 1 | 83,44 | 8 | mexh  | 53-65 |
|                     | 2 | 84,22 | 6 | coif3 | 89-97 |
|                     | 3 | 84,62 | 5 | gaus2 | 33-69 |
|                     | 4 | 84,75 | 4 | meyr  | 85-89 |
|                     | 5 | 85,01 | 4 | morl  | 25-61 |

**Tablo 27.** S7 kişinin 2 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD    | k  | D     | Ö     |
|---------------------|---|-------|----|-------|-------|
| Örtüşme yok         | 1 | 75,92 | 5  | gaus2 | 29-49 |
|                     | 2 | 77,49 | 4  | haar  | 33-89 |
| 0,25 sn'lik örtüşme | 1 | 75,80 | 5  | mexh  | 33-81 |
|                     | 2 | 78,54 | 5  | coif2 | 53-57 |
| 0,5 sn'lik örtüşme  | 1 | 78,26 | 11 | morl  | 73-81 |
|                     | 2 | 79,05 | 5  | gaus1 | 1-65  |
|                     | 3 | 81,42 | 3  | sym4  | 9-97  |
|                     | 4 | 81,82 | 3  | coif2 | 5-65  |
| 1 sn'lik örtüşme    | 1 | 76,19 | 10 | haar  | 41-45 |
|                     | 2 | 78,04 | 8  | gaus2 | 85-97 |
|                     | 3 | 79,37 | 9  | meyr  | 49-97 |

**Tablo 28.** S7 kişinin 3 sn'lik pencere uzunluğu duruma ait AİADS Sonuçları

| Örtüşme Durumu      | İ | SD    | k | D     | Ö     |
|---------------------|---|-------|---|-------|-------|
| Örtüşme yok         | 1 | 76,38 | 3 | mexh  | 37-65 |
|                     | 2 | 77,95 | 5 | coif2 | 89-97 |
|                     | 3 | 78,74 | 5 | coif1 | 81-97 |
| 0,25 sn'lik örtüşme | 1 | 75,91 | 6 | db2   | 29-89 |
|                     | 2 | 76,64 | 6 | coif2 | 57-97 |
| 0,5 sn'lik örtüşme  | 1 | 75,33 | 7 | mexh  | 49-69 |
|                     | 2 | 76,00 | 7 | gaus2 | 73-93 |
| 1 sn'lik örtüşme    | 1 | 75,94 | 4 | mexh  | 37-61 |
|                     | 2 | 78,08 | 4 | coif3 | 57-85 |
|                     | 3 | 79,14 | 4 | sym4  | 21-77 |
|                     | 4 | 79,68 | 4 | gaus3 | 1-65  |
| 1,5 sn'lik örtüşme  | 1 | 75,90 | 4 | gaus2 | 61-81 |
|                     | 2 | 79,11 | 6 | sym4  | 69-81 |
|                     | 3 | 79,52 | 6 | morl  | 1-25  |

Tüm kişilerin tüm örtüşme durumlarına ait SD performanslarının ortalaması Tablo 29'da verilmiştir. Bu tabloya göre en yüksek ortalama SD 1 sn'lik segmentte 0,25 sn'lik örtüşme durumu için %86,51 olarak elde edilmiştir. Diğer durumlar için de genelde ortalama SD'ler %86 civarında olduğu görülmektedir.

**Tablo 29.** VS3'ün ortalama AİADS sonuçları

| Örtüşme Durumu      | 1 sn'lik segment | 2 sn'lik segment | 3 sn'lik segment |
|---------------------|------------------|------------------|------------------|
| Örtüşme yok         | 86,12            | 85,89            | 86,54            |
| 0,25 sn'lik örtüşme | 86,51            | 85,96            | 85,56            |
| 0,5 sn'lik örtüşme  | 86,21            | 86,03            | 86,24            |
| 1 sn'lik örtüşme    | -                | 85,69            | 86,44            |
| 1,5 sn'lik örtüşme  | -                | -                | 86,29            |

Daha önce ifade edildiği üzere önerilen yöntemin geçerliliğini ortaya koymak için BG öznitelikleriyle de VS3 sınanmıştır. Tablo 30, Tablo 31 ve Tablo 32'de sırasıyla 1 sn, 2 sn ve 3 sn'lik PPG segmentlerine ait sınıflandırma sonuçları verilmiştir. Bu tabloların son sütununda her bir örtüşme durumu için Kişilerin ortalama SD performansları sunulmuştur. 1 sn'lik sınıflandırma sonuçlarına göre en yüksek SD performansı S4 için 0,25 sn'lik örtüşme durumunda %98,31 olarak hesaplanmıştır. Kişilerin ortalama performansları ise örtüşme olmayan durum ve 0,25 sn'lik örtüşme durumuna göre %80,16 iken, 0,5 sn'lik örtüşme durumu için ortalama SD %80,20 olarak

hesaplanmıştır. S2 ve S4 kişilerin SD sonuçları %95'ten yüksek iken en düşük performans yaklaşık %60 performans ile S6 kişisi için elde edilmiştir. Ortalama SD'lerin en yüksek değerleri dikkate alındığında önerilen yöntemin 1 sn'lik pencere uzunluğu için %6,31 daha yüksek performans sergilediği görülmektedir.

**Tablo 30.** 1 sn'lik pencere uzunluğu duruma ait band gücü öznitelikleri sonuçları

| Örtüşme Durumu      | S1    | S2    | S3    | S4    | S5    | S6    | S7    | O     |
|---------------------|-------|-------|-------|-------|-------|-------|-------|-------|
| Örtüşme yok         | 77,09 | 95,22 | 80,56 | 97,81 | 78,93 | 60,26 | 71,25 | 80,16 |
| 0,25 sn'lik örtüşme | 77,00 | 95,12 | 80,21 | 98,31 | 79,11 | 59,08 | 72,31 | 80,16 |
| 0,5 sn'lik örtüşme  | 77,07 | 95,24 | 80,17 | 97,94 | 78,60 | 60,11 | 72,24 | 80,20 |

BG özniteliklerinin 2 sn'lik pencere uzunluğu sonuçları da 1 sn'lik sonuçlarla paralellik göstermektedir. En yüksek performans %98,32 olarak yine S4 için 0,5 sn'lik örtüşme durumunda elde edilmiştir. Tüm örtüşme durumları için ortalama SD performansları %80,60 civarındadır. Benzer şekilde en düşük performans yine S6 için %60 civarında hesaplanmıştır. Ortalama SD'lerin en yüksek değerleri dikkate alındığında önerilen yöntemin 2 sn'lik pencere uzunluğu için %5,35 daha yüksek performans sergilediği görülmektedir.

**Tablo 31.** 2 sn'lik pencere uzunluğu duruma ait band gücü öznitelikleri sonuçları

| Örtüşme Durumu      | S1    | S2    | S3    | S4    | S5    | S6    | S7    | O     |
|---------------------|-------|-------|-------|-------|-------|-------|-------|-------|
| Örtüşme yok         | 78,17 | 95,07 | 80,73 | 97,55 | 80,78 | 60,82 | 71,23 | 80,62 |
| 0,25 sn'lik örtüşme | 77,48 | 95,61 | 81,17 | 98,12 | 79,75 | 59,41 | 72,57 | 80,59 |
| 0,5 sn'lik örtüşme  | 77,93 | 95,00 | 81,20 | 98,32 | 80,75 | 59,86 | 71,67 | 80,68 |
| 1 sn'lik örtüşme    | 77,52 | 95,20 | 80,78 | 98,30 | 80,31 | 60,17 | 72,40 | 80,67 |

BG özniteliklerinin 3 sn'lik pencere uzunluğu sonuçlarına göre SD performanslarının yaklaşık %0,5 civarında artış sağlandığı görülmektedir. En yüksek SD performansı S4'in 1 sn'lik örtüşme durumu için %98,78 olarak hesaplanmıştır. En düşük performans ise S6 için %62,39 olarak örtüşme olmadığı durumda hesaplanmıştır. Ortalama SD'lere göre en yüksek değer 0,25 sn'lik örtüşme durumu için %81,97 olarak elde edilmiştir. Ortalama SD'lerin en yüksek değerleri dikkate alındığında önerilen yöntemin 3 sn'lik pencere uzunluğu için %4,57 daha yüksek performans sergilediği görülmektedir.

**Tablo 32.** 3 sn'lik pencere uzunluđu duruma ait band g¼c¼ ¼znitelikleri sonuřları

| rt¼řme Durumu      | S1    | S2    | S3    | S4    | S5    | S6    | S7    | O     |
|---------------------|-------|-------|-------|-------|-------|-------|-------|-------|
| rt¼řme yok         | 78,75 | 94,96 | 80,27 | 98,60 | 81,22 | 62,39 | 72,04 | 81,18 |
| 0,25 sn'lik rt¼řme | 79,27 | 95,05 | 81,49 | 98,64 | 82,65 | 64,05 | 72,66 | 81,97 |
| 0,5 sn'lik rt¼řme  | 78,01 | 95,78 | 82,11 | 98,55 | 81,23 | 62,87 | 72,40 | 81,56 |
| 1 sn'lik rt¼řme    | 78,69 | 95,32 | 81,83 | 98,78 | 82,00 | 63,75 | 71,76 | 81,73 |
| 1,5 sn'lik rt¼řme  | 78,64 | 95,33 | 81,61 | 98,68 | 81,93 | 63,98 | 72,85 | 81,86 |

Daha ¼nce ifade edildiđi ¼zere ¼nerilen y¼ntemin geęerliliđini ortaya koymak ięin istatistiksel ¼znitelikleriyle de VS3 sınanmıřtır. Tablo 33, Tablo 34 ve Tablo 35'te sırasıyla 1 sn, 2 sn ve 3 sn'lik PPG segmentlerine ait sınıflandırma sonuřları verilmiřtir. Bu tabloların son s¼tununda her bir rt¼řme durumu ięin Kiřilerin ortalama SD performansları sunulmuřtur. 1 sn'lik sınıflandırma sonuřlarına g¼re en y¼ksek SD performansı S4 ięin 0,25 sn'lik rt¼řme durumunda %98,38 olarak hesaplanmıřtır. Kiřilerin ortalama performansları ise rt¼řme olmayan durum, 0,25 sn'lik rt¼řme ve 0,5 sn'lik rt¼řme durumu ięin sırasıyla %83,76, %84,41 ve %84,63 olarak elde edilmiřtir. S2 ve S4 kiřilerin SD sonuřları %95'ten y¼ksek iken en d¼ř¼k performans yaklařık %73 performans ile S6 kiřisi ięin elde edilmiřtir. Ortalama SD'lerin en y¼ksek deđerleri dikkate alındıđında ¼nerilen y¼ntemin 1 sn'lik pencere uzunluđu ięin %1,88 daha y¼ksek performans sergilediđi g¼r¼lmektedir.

**Tablo 33.** 1 sn'lik pencere uzunluđu duruma ait istatistiksel ¼zniteliklerin sonuřları

| rt¼řme Durumu      | S1    | S2    | S3    | S4    | S5    | S6    | S7    | O     |
|---------------------|-------|-------|-------|-------|-------|-------|-------|-------|
| rt¼řme yok         | 78,05 | 95,46 | 82,37 | 97,74 | 81,22 | 72,90 | 78,61 | 83,76 |
| 0,25 sn'lik rt¼řme | 78,69 | 95,21 | 82,21 | 98,38 | 83,28 | 73,56 | 79,55 | 84,41 |
| 0,5 sn'lik rt¼řme  | 79,19 | 95,28 | 82,50 | 98,02 | 82,60 | 74,35 | 80,46 | 84,63 |

İstatistiksel ¼zniteliklerinin 2 sn'lik pencere uzunluđu sonuřları da 1 sn'lik sonuřlarla paralellik g¼stermektedir. En y¼ksek performans %98,37 olarak yine S4 ięin 1 sn'lik rt¼řme durumunda elde edilmiřtir. T¼m rt¼řme durumları ięin ortalama SD performansları %84 civarındadır. En d¼ř¼k performans ise S7 ięin yaklařık %75 olarak hesaplanmıřtır. Ortalama SD'lerin en y¼ksek deđerleri dikkate alındıđında ¼nerilen y¼ntemin 2 sn'lik pencere uzunluđu ięin %1,51 daha y¼ksek performans sergilediđi g¼r¼lmektedir.

**Tablo 34.** 2 sn'lik pencere uzunluđu duruma ait istatistiksel  zniteliklerin sonu ları

|  rt şme Durumu      | S1    | S2    | S3    | S4    | S5    | S6    | S7    | O     |
|---------------------|-------|-------|-------|-------|-------|-------|-------|-------|
|  rt şme yok         | 78,01 | 95,18 | 82,72 | 97,58 | 79,94 | 76,65 | 74,37 | 83,49 |
| 0,25 sn'lik  rt şme | 78,40 | 95,46 | 84,15 | 98,18 | 81,83 | 75,46 | 74,16 | 83,95 |
| 0,5 sn'lik  rt şme  | 78,92 | 95,17 | 82,17 | 98,10 | 81,84 | 77,60 | 75,32 | 84,16 |
| 1 sn'lik  rt şme    | 78,97 | 95,46 | 83,42 | 98,37 | 81,43 | 78,12 | 75,86 | 84,52 |

İstatistiksel  zniteliklerinin 3 sn'lik pencere uzunluđu sonu larına g re SD performanslarının yaklaşık %1 civarında artış sađlandığı g r lmektedir. En y ksek SD performansı S4'in  rt şme olmayan durumu i in %99,02 olarak hesaplanmıřtır. En d ř k performans ise S7 i in %73,13 olarak 1 sn'lik  rt şme durumunda hesaplanmıřtır. Ortalama SD'lere g re en y ksek deđer 1,5 sn'lik  rt şme durumu i in %84,99 olarak elde edilmiřtir. Ortalama SD'lerin en y ksek deđerleri dikkate alındığında  nerilen y ntemin 3 sn'lik pencere uzunluđu i in %1,55 daha y ksek performans sergilemiřtir.

**Tablo 35.** 3 sn'lik pencere uzunluđu duruma ait istatistiksel  zniteliklerin sonu ları

|  rt şme Durumu      | S1    | S2    | S3    | S4    | S5    | S6    | S7    | O     |
|---------------------|-------|-------|-------|-------|-------|-------|-------|-------|
|  rt şme yok         | 79,72 | 95,70 | 81,63 | 99,02 | 81,65 | 82,57 | 73,23 | 84,79 |
| 0,25 sn'lik  rt şme | 80,91 | 95,14 | 83,43 | 98,61 | 82,08 | 79,56 | 74,42 | 84,88 |
| 0,5 sn'lik  rt şme  | 79,24 | 95,48 | 83,81 | 98,17 | 80,99 | 78,91 | 73,73 | 84,33 |
| 1 sn'lik  rt şme    | 79,49 | 95,73 | 84,68 | 98,45 | 80,60 | 79,33 | 73,13 | 84,49 |
| 1,5 sn'lik  rt şme  | 80,31 | 95,46 | 83,87 | 98,72 | 82,22 | 80,53 | 73,84 | 84,99 |

#### 4. TARTIŞMA VE SONUÇLAR

Bu tez çalışmasında optiğin bir uygulama sahası olan PPG işaretlerinin örüntü tanıma ve makine öğrenmesi teknikleri ile birlikte kullanımı gerçekleştirilmiştir. Özellikle, farklı durumlar için kaydedilmiş PPG işaretlerinin yüksek performans ile sınıflandırılması için bu işaretleri en iyi temsil edebilecek özneliliklerin sadece bir ana dalgacık ve ona ait ölçek parametreleri ile değil birden fazla ana dalgacığın belirlenen en uygun ölçek parametreleri ile çıkarılabileceği ortaya koyulmuştur. Önerilen yöntem ardışıl olarak dikkate alınan ana dalgacıklardan en yüksek sınıflandırma doğruluğu sağlayan kombinasyonu bulma esasına dayanmaktadır. Yöntemin geçerliliğini ve kararlılığını test etmek için 3 ayrı veri seti sınanmıştır. Genel olarak her veri seti için yüksek sınıflandırma performans artışı sağlanmıştır. Buna karşın eğitim setleri üzerinde en uygun ana dalgacık kombinasyonu ve ana dalgacıklara ait ölçek parametreleri belirlenmesi binlerce olasılığın sınanmasını gerektirdiğinden bu aşama çok zaman alıcıdır. Ancak, eğitim aşamasında en uygun parametreler belirlendikten sonra test aşaması milisaniyeler mertebesinde kısa sürmektedir.

Tez çalışmasında kullanılan VS1 ile zihinsel iş yükü seviyelerinin PPG işaretleri kullanılarak otomatik tespit edilmesi gerçekleştirilmiştir. Zihinsel iş yükü, bilişsel bir görevi başarıyla gerçekleştirmek veya gözler, kulaklar, cilt ve burun gibi duyu organlarından gelen bilgileri işlemek için ek kaynaklara ihtiyaç duyar. Ek kaynakların gerekliliği, bir görevin işleme verimliliğini ve performansını azaltabilir. Dolayısıyla, zihinsel iş yükünün değerlendirilmesinin, bir konunun çalışma verimliliğini artırmak için uygun bir çalışma ortamı sağlayabileceği söylenebilir. Bu tez çalışmasında, bir *N*-geri görevin zihinsel iş yükünün 3 seviyesini yalnızca PPG sinyallerinden sınıflandırmak için ardışıl bir ileri ana dalgacık seçim yöntemi önerilmiştir. Önerilen yaklaşım, her konu için 30 dakikalık bir PPG sinyal kaydından oluşan MAUS veri setinin PPG sinyallerine başarıyla uygulandı. Elde edilen SD sonuçları, yalnızca bir ana dalgacık kullanmak yerine, etkili bir ana dalgacık kombinasyonu seçmenin zihinsel iş yükü düzeylerinin sınıflandırılmasını arttırdığını göstermiştir. 6 sn, 8 sn ve 10 sn'lik PPG sinyal segmentleri ile yapılan çalışmalar dikkate alınan sinyalin süresi ne kadar uzun olursa, sınıflandırma performansının o kadar iyi olduğunu kanıtladı. En yüksek SD, Kişi 20 (S20) için 10 sn'lik PPG sinyalleri için %76,67 idi. Ayrıca, 10 sn'lik PPG sinyallerinin ortalama SD'si, 6 sn'lik ve 8 sn'lik

sinyal segmentlerinden sırasıyla %4,85 ve %1,39 daha yüksekti.

Elde edilen sonuçlar ayrıca, DD katsayılarının ortalama ve standart sapmasının, zihinsel iş yükünü sınıflandırmak için öznitelik olarak kullanılabileceğini göstermiştir. Diğer bir önemli sonuç da, Morlet en seçici dalgacık iken, Symlet 2 ve Symlet 3'ün tüm deneylerde hiçbir zaman seçilmediği idi. Dolayısıyla Morlet'in diğerlerine göre zihinsel iş yükünü tespit etmede daha ayırt edici özellikler sunabileceği söylenebilir. Önerilen yöntemin, EEG ve EKG gibi geleneksel zihinsel iş yükü değerlendirme tekniklerine harika bir alternatif olacağı düşünülmektedir.

Önerilen yöntemin geçerliliği göstermek için kullanılan VS2 ile tansiyon hastası kişiler ile sağlıklı kişilerin sadece PPG işaretleri kullanılarak yüksek SD ile tespit edilebileceği gösterilmiştir. PPG işaretleri sadece 2,1 sn uzunluğunda olmasına rağmen önerilen AİADS yöntemi ile %73,39 SD elde edilmiştir. Bu oran bu kısalıkta kullanılan diğer PPG işaretlerine dayalı SD performanslarından ve literatürde PPG işaretleri için kullanılan BD ve istatistiksel öznitelik sonuçlarından daha yüksektir. Önerilen yöntemin klinik uygulamalarda önemli rol oynayacağı düşünülmektedir. Dolayısıyla bu bilgisayar destekli hipertansiyon teşhisi, zaman alan teşhis aşamasını önemli ölçüde hızlandırabilir ve doktorlar ve hemşireler dahil olmak üzere sağlık personelinin iş yükünü azaltabilir. Bu nedenle hipertansiyon için otomatik tanı ve uyarı sistemi, hastalığın erken ve doğru taranması ve tedavisi için gerekli bir unsurdur. Ayrıca önerilen teknik non-invaziv ve kurulum maliyeti düşük olduğundan kullanımda çok pratik olabilir.

Bu tez çalışmasında kullanılan VS3 ise insan faaliyeti izleme amacıyla kaydedilen PPG veri setidir. PPG işaretleri ile insan faaliyeti izleme çalışmasının amacı, yaygın olarak kullanılan hareket sensörlerini değiştirmek değil, PPG sinyallerinin insan aktivitesi tanımda nasıl kullanılabileceğine dair alternatif bir yol sunmak olduğu belirtilmelidir. Örneğin, PPG tabanlı yaklaşım, jiroskoplar veya diğer sensörler mevcut olmadığında insan faaliyetlerini izlemek için kullanılabilir. Kalp atış hızlarının izlenmesine ve kardiyovasküler ve hipertansiyon hastalıkları gibi çeşitli aterosklerotik patolojilerin erken taranmasına ek olarak, bu yaklaşım aynı zamanda insan aktivitesi bilgileri de sağlayabileceği gösterilmiştir. Ayrıca, PPG işaretleri ile elde edilen başarılı sonuçlar, insan faaliyetleri tanıma doğruluğunu artırmak için PPG sensörlerinin diğer sensörlerle birlikte hibrit yaklaşımlarda da kullanılabileceğini



göstermiştir.

İnsan faaliyeti izleme kapsamında skuat, step hareketleri ile dinlenme durumları 1 sn, 2 sn ve 3 sn'lik PPG sinyal parçaları dikkate alınarak sınıflandırılmış ve 7 katılımcı için elde edilen ortalama SD performansları sırasıyla %86,51, %86,03 ve %86,54'tür. Bu tez çalışması bilindiği kadarıyla bu hareketlerin tanınmaya çalışıldığı ilk çalışma olup literatürde sıklıkla kullanılan BG ve istatistiksel özniteliklere ait SD performanslarından daha yüksektir.

Bu tez çalışmasında 3 farklı PPG veri seti AİADS yönteminin kararlılığı için kullanılmıştır. Yönteme ait en uygun parametreler her bir veri setinin eğitim kümesinden elde edilmiştir. Bu aşamada eğitim kümesinin büyüklüğüne göre 1-8 saat arasında parametre belirleme süresi geçmiştir. Eğitim süresinin kısaltılabilmesi için arı kolonisi ve parçacık sürü optimizasyonu gibi doğadan esinlenen meta-sezgisel yöntemler kullanılabilir. Her ne kadar parametreler eğitim belirlendikten sonra test aşaması milisaniyeler mertebesinde zaman alsa da eğitim aşamasının kısaltılması da önerilen yöntemin geliştirilebileceği bir saha olarak görülmektedir.

Önerilen yöntemde Morlet (morl), Meksika Şapkası (mexh), Haar (haar), Meyer (meyr), Daubechies1 (db1), Daubechies2 (db2), Daubechies3 (db3), Symlet2 (sym2), Symlet3 (sym3), Symlet4 (sym4), Coiflets2 (coif2), Coiflets3 (coif3), Coiflets4 (coif4), Gaus1 (gaus1), Gaus2 (gaus2) ve Gaus3 (gaus3) ana dalgacıkları olmak üzere 16 farklı ana dalgacık dikkate alınarak en uygun ana dalgacık kombinasyonu elde edilmiştir. Dalgacık dönüşümünde bu 16 farklı ana dalgacıktan başka Shannon, biortogonal ve Ricker gibi ana dalgacıklarda vardır. Hatta Daubechies, Coiflets ve Gaus ana dalgacıklarının bu tez çalışmasında dikkate alınandan daha fazla sayıda alt çeşidi de mevcuttur. Elde edilen sınıflandırma performanslarının geliştirilebilmesi için dikkate alınan ana dalgacık sayısı arttırılabilir. Bu şekilde en uygun ana dalgacık kombinasyonunun bulunma süresi daha da artacaktır. Bunun önüne geçilebilmesi için yüksek performanslı yeni nesil bilgisayarlar kullanılabilir.

Önerilen yöntemin önemli bir parametresi ana dalgacıkların ölçekleridir. Her bir ana dalgacık için en uygun ölçek aralığı 1 ile 100 arasında 4 adım büyüklüğü ile aranmıştır. Adım büyüklüğü daha küçük seçilerek daha fazla ölçek kombinasyonu test edilebilir ve sınıflandırma performansları yine arttırılabilir. Bu tez çalışmasında kullanılan bilgisayarın donanımsal kapasitesi nedeniyle adım büyüklüğü 4 seçilmiştir.

Ancak yüksek performanslı bir bilgisayar ile hem adım büyüklüğü küçültülüp daha yüksek çözünürlükle ölçek aralığı tespit edilebilir hem de dikkate alınan ölçek bandı 1-100 arası değil 1-200 gibi daha geniş seçilebilir. Bu seçimde yine sınıflandırma performansını arttırabilir. Ölçek parametresi ile ilgili diğer bir husus ise bir ana dalgacık için sadece bir ölçek aralığı değil birden fazla da ölçek aralığı etkin öznitelikler belirlenebilmesine katkı sunabilir. Örneğin bir ana dalgacık için sadece 1-50 arası dalgacık dönüşümü öznitelikleri değil hem 1-41 hem de 21-81 arası ölçek öznitelikleri birlikte etkin öznitelik uzayı oluşturabilir.

PPG işaretlerinin bir noktadan kaydedilmesi pratiklik açısından tercih edilen bir yaklaşımdır ve avantajlı bir durum olduğu söylenebilir. Yapılan uygulamanın hassasiyetine göre (kalp krizinin PPG ile otomatik tespit edilmesi gibi) hatanın önemli sonuçlar doğuracağı çalışmalarda vücudun birden fazla noktasından PPG işaretleri kaydedilip daha etkin öznitelik uzayı elde edilebilir. Örneğin ayak parmaklarından, kulak memesinden veya el parmaklarından aynı anda PPG işaretleri kaydedilip bu uzuvlardaki mikrovasküler doku yatağındaki kan hacmi değişimlerinin sayısal işaret işleme yöntemleri ile değerlendirilmesi daha yüksek sınıflandırma doğruluğu sağlayabilir. Tabi, böyle bir kayıt sistemi birden fazla noktada kayıt gerektirdiği için hem pratikliği düşürecek hem de kanallar arasındaki senkronizasyon problemini beraberinde getirecektir. Bu açıdan değerlendirildiğinde tek noktadan kaydedilen PPG işaretlerinin değerlendirildiği ve yüksek sınıflandırma doğruluğu elde edilen bu tez çalışmasının kullanıcılara oldukça pratiklik sağlayacağı düşünülmektedir.

Her ne kadar optik tabanlı bir uygulama olsa da PPG işaretleri vücut hareketlerinden olumsuz etkilenmektedir. Bu da PPG işaretlerinin gürültü bir şekilde kaydedilmesine ve sayısal işaret işleme aşamasında (öznitelik çıkarma aşaması da denilebilir) etkin özniteliklerinde elde edilememesine neden olabilmektedir. Bu tür sorunların önüne geçmek için ön işleme aşamasında filtreleme ile PPG işaretleri gürültüden arındırılabilir. Önerilen tez çalışmasında dalgacık dönüşümü esaslı algoritma ölçek parametreleri ile en etkin band aralığını dikkate aldığı için kendi içinde aynı zamanda bir filtreleme de yapmaktadır. Bu açıdan önerilen yöntemin önemli bir avantaja sahip olduğu da söylenebilir. Dalgacık dönüşümü kullanılmayan yöntemlerde filtreleme aşaması dikkate alınması gereken önemli bir safha olduğu söylenebilir.

Bu tez çalışmasında önerilen yöntemin sınıflandırıcısı olarak hızlı ve başarılı

bir algoritma olmasından dolayı *k*-EYK kullanılmıştır. Eğitim aşamasının zaman alıcı olmasından dolayı destek vektör makineleri ve yapay sinir ağları gibi sınıflandırıcılar test edilmemiştir. Kullanılan *k*-EYK sınıflandırıcısı ile birlikte hızlı bir bilgisayar ile diğer sınıflandırıcılar da test edilebilir. Elde edilen sonuçlara göre önerilen AİADS yöntemine başka bir sınıflandırıcı da monte edilebilir.

Zihinsel iş yükünün tespiti dikkat isteyen birçok kritik meslekte (pilotluk, kaptanlık, otobüs şoförlüğü gibi) çok elzemdir. Bu tez çalışmasında giyilebilir bir sistemle PPG işaretlerinin kaydedilip zihinsel iş yükü seviyesinin tespit edilebileceği gösterilmiştir. Laboratuvar ortamında yapılan bu kayıtlar N-geri görevi deneyi ile değil de bir mesleği icra etme anında kaydedilip önerilen yöntem böyle bir veri setine uygulanabilir. Sadece meslekler için değil öğrenciler için de zihinsel iş yükü tespiti öğrenme sürecinin planlanması açısından çok değerlidir. Önerilen yöntem ders esnasında giderek zihinsel olarak yorulan öğrencilerden kaydedilecek PPG verilerine de uygulanıp farklı bir uygulama sahası için gerçekleştirilebilir.

Kişilerin günlük aktivitesinin belirlenmesi, ebeveynlerin çocuklarını takip etmeleri, kişinin kendi günlük hareketlerinin dökümünü elde etmesi, şeker hastalarının günlük hareket miktarlarına göre insülin miktarlarını ayarlamaları, diyet yapanlar için günlük hareket dökümünün elde edilmesi ve yaşlıların günlük eğersizlerini yapıp yapmadıklarını otomatik tespit edilmesi gibi birçok açıdan kullanılabilir. Bu tez çalışmasında skuat, step hareketi ile dinlenme durumlarında kaydedilen PPG işaretlerinin yüksek doğrulukla sınıflandırılması günlük insan aktivitelerinin sadece PPG işaretleri kullanılarak takip edilebileceğini göstermiştir. Dikkate alınan bu hareket grupları yukarıda bahsedilen uygulamalara özel bir veri setine uygulanabilir. Önerilen yöntemin 3 farklı veri seti ile kararlılığının test edilmesi ile farklı günlük aktiviteler esnasında da kaydedilen PPG işaretlerinin aktivite takip için kullanılabilme potansiyeli olduğunu göstermektedir.

Kan basıncı, kişiler için zaman zaman hayati bir dolaşım sistemi bilgisidir. Farklı ölçüm teknikleri ile kan basıncı ölçülebilmektedir. EKG bu tekniklerden en etkin olanı olsa da pratiklik açısından diğer tekniklere göre dezavantajlı durumdadır. Bu dezavantaja göre önerilen PPG ile tansiyon ölçümü literatürde görece başarılı olarak sunulmuştur. Bu tez çalışmasında kişilerin tansiyon seviyeleri yerine tansiyon hastası olup olmadığı otomatik olarak tespit edilmiştir. Dikkate alınan veri seti 2,1

sn'lik veri parçalarına sahip olduğundan elde edilen sınıflandırma doğruluğu çok yüksek olmasa da bu uzunlukta kullanılan PPG verileri için iyi bir performans olduğu söylenebilir. Yine de, daha uzun süreli PPG verileri ile kişilerin tansiyon hastası olup olmadığının tespiti daha yüksek sınıflandırma doğruluğu ile tespit edilebileceği düşünülmektedir. Bu özellikle, tez çalışmasında kullanılan diğer uzun veri setlerindeki yüksek sınıflandırma doğruluklarının elde edilmiş olmasından da anlaşılmaktadır.

Bu tez çalışmasında önerilen AIADS yöntemi, farklı bakış açısı ile kaydedilen PPG işaretlerine uygulanmış ve yüksek sınıflandırma doğrulukları elde edilmiştir. Çalışmanın avantajları ve dezavantajları ile öneriler bu başlık altında sunulmuştur. Bu öneriler gelecek çalışmalar olarak değerlendirilebileceği gibi tez çalışmasını okuyan araştırmacılara da çalışma sahası fikirleri vermektedir. Bu açıdan bu tez çalışmasının okurlara katkı sunma potansiyelinin büyük olduğu düşünülmektedir.

## KAYNAKÇA

- Allen, J. ve Murray, A. (2000). Similarity in bilateral photoplethysmographic peripheral pulse wave characteristics at the ears, thumbs and toes. *Physiological measurement*, 21(3), 369.
- Al Ghayab, H. R., Li, Y., Siuly, S. ve Abdulla, S. (2019). A feature extraction technique based on tunable Q-factor wavelet transform for brain signal classification. *Journal of neuroscience methods*, 312, 43-52.
- Aoyagi, T. ve Miyasaka, K. (2002). Pulse oximetry: its invention, contribution to medicine, and future tasks. *Anesthesia and analgesia*, 94(1 Suppl), S1-3.
- Aydemir, T., Şahin, M. ve Aydemir, O. (2021). Sequential forward mother wavelet selection method for mental workload assessment on N-back task using photoplethysmography signals. *Infrared Physics & Technology*, 119, 103966.
- Aydemir, T., Şahin, M. ve Aydemir, O. (2020a). A New Method for Activity Monitoring Using Photoplethysmography Signals Recorded by Wireless Sensor. *Journal of Medical and Biological Engineering*, 40(6), 934-942.
- Aydemir, T., Sahin, M. ve Aydemir, O. (2020b). Determination of hypertension disease using chirp z-transform and statistical features of optimal band-pass filtered short-time photoplethysmography signals. *Biomedical Physics & Engineering Express*, 6(6), 065033.
- Beh, W. K. ve Wu, Y. H. (2021). MAUS: A Dataset for Mental Workload Assessment on N-back Task Using Wearable Sensor. *arXiv preprint arXiv:2111.02561*.
- Biagetti, G., Crippa, P., Falaschetti, L., Saraceni, L., Tiranti, A. ve Turchetti, C. (2020). Dataset from PPG wireless sensor for activity monitoring. *Data in brief*, 29, 105044.
- Bos, M. ve Vrieling, J. A. M. (1994). The wavelet transform for preprocessing IR spectra in the identification of mono-and di-substituted benzenes. *Chemometrics and intelligent laboratory systems*, 23(1), 115-122.
- Bruce, L. M., Koger, C. H. ve Li, J. (2002). Dimensionality reduction of hyperspectral data using discrete wavelet transform feature extraction. *IEEE Transactions on geoscience and remote sensing*, 40(10), 2331-2338.
- Cabitza, F., Rasoini, R. ve Gensini, G. F. (2017). Unintended consequences of machine learning in medicine. *Jama*, 318(6), 517-518.
- Cheng, C. B. ve Lee, E. S. (2001). Fuzzy regression with radial basis function network. *Fuzzy Sets and Systems*, 119(2), 291-301.
- Chu, C. S., Lee, N. P., Adeoye, J., Thomson, P. ve Choi, S. W. (2020). Machine

- learning and treatment outcome prediction for oral cancer. *Journal of Oral Pathology & Medicine*, 49(10), 977-985.
- Conroy, T., Guzman, J. H., Hall, B., Tsouri, G. ve Couderc, J. P. (2017). Detection of atrial fibrillation using an earlobe photoplethysmographic sensor. *Physiological measurement*, 38(10), 1906.
- Cover, T. ve Hart, P. (1967). Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1), 21-27.
- De Haan, G. ve Van Leest, A. (2014). Improved motion robustness of remote-PPG by using the blood volume pulse signature. *Physiological measurement*, 35(9), 1913.
- De Trefford, J. ve Lafferty, K. (1984). What does photoplethysmography measure?. *Medical and biological engineering and computing*, 22(5), 479-480.
- Dou, W., Morrow, A., Iemi, L. ve Samaha, J. (2022). Pre-stimulus alpha-band phase gates early visual cortex responses. *NeuroImage*, 253, 119060.
- Elaziz, M. A., Hosny, K. M., Salah, A., Darwish, M. M., Lu, S. ve Sahlol, A. T. (2020). New machine learning method for image-based diagnosis of COVID-19. *Plos one*, 15(6), e0235187.
- Emmert-Streib, F. ve Dehmer, M. (2018). A machine learning perspective on Personalized Medicine: an automatized, comprehensive knowledge base with ontology for pattern recognition. *Machine Learning and Knowledge Extraction*, 1(1), 149-156.
- Fan, P., Peiyu, H., Shangwen, L. ve Wenfeng, D. (2015, July). Feature extraction of photoplethysmography signal using wavelet approach. In *2015 IEEE International Conference on Digital Signal Processing (DSP)* (pp. 283-286). IEEE.
- Fatima, M. ve Pasha, M. (2017). Survey of machine learning algorithms for disease diagnostic. *Journal of Intelligent Learning Systems and Applications*, 9(01), 1.
- Feng, L., Po, L. M., Xu, X., Li, Y. ve Ma, R. (2014). Motion-resistant remote imaging photoplethysmography based on the optical properties of skin. *IEEE Transactions on Circuits and Systems for Video Technology*, 25(5), 879-891.
- Gangal, O. B. ve Öztürk, M. (2018, May). Real-time pulse counting using palm images. In *2018 26th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). Ieee.
- Gao, W. B. ve Li, B. Z. (2021). Octonion Short-Time Fourier Transform for Time-Frequency Representation and Its Applications. *IEEE Transactions on Signal Processing*, 69, 6386-6398.

- Gaur, P., Gupta, H., Chowdhury, A., McCreadie, K., Pachori, R. B. ve Wang, H. (2021). A sliding window common spatial pattern for enhancing motor imagery classification in EEG-BCI. *IEEE Transactions on Instrumentation and Measurement*, 70, 1-9.
- Geetha, V., Anbumani, V., Parameshwaran, R. ve Gomathi, S. (2022). Savitzky Golay and KPCA based Optimal Discrete Wavelet Transform Architecture for Image Compression. *Microprocessors and Microsystems*, 104511.
- Ghosal, P. ve Gupta, R. (2015, November). Classification of photoplethysmogram signal using self organizing map. In *2015 IEEE International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN)* (pp. 114-118). IEEE.
- Gupta, V., Mittal, M., Mittal, V. ve Chaturvedi, Y. (2022). Detection of R-peaks using fractional Fourier transform and principal component analysis. *Journal of Ambient Intelligence and Humanized Computing*, 13(2), 961-972.
- Habbu, S., Dale, M. ve Ghongade, R. (2019). Estimation of blood glucose by non-invasive method using photoplethysmography. *Sāadhanā*, 44(6), 1-14.
- He, X., Goubran, R. A. ve Liu, X. P. (2014). Secondary peak detection of PPG signal for continuous cuffless arterial blood pressure measurement. *IEEE Transactions on Instrumentation and Measurement*, 63(6), 1431-1439.
- Henrique, B. M., Sobreiro, V. A. ve Kimura, H. (2019). Literature review: Machine learning techniques applied to financial market prediction. *Expert Systems with Applications*, 124, 226-251.
- Hoang, V. D. (2014). Wavelet-based spectral analysis. *TrAC Trends in Analytical Chemistry*, 62, 144-153.
- Jonathan, E. ve Leahy, M. (2010). Investigating a smartphone imaging unit for photoplethysmography. *Physiological measurement*, 31(11), N79.
- Kavsaoğlu, A. R., Polat, K. ve Bozkurt, M. R. (2014). A novel feature ranking algorithm for biometric recognition with PPG signals. *Computers in biology and medicine*, 49, 1-14.
- Khare, S. K., Bajaj, V. ve Sinha, G. R. (2020). Adaptive tunable Q wavelet transform-based emotion identification. *IEEE transactions on instrumentation and measurement*, 69(12), 9609-9617.
- Kinnunen, H., Rantanen, A., Kenttä, T. ve Koskimäki, H. (2020). Feasible assessment of recovery and cardiovascular health: accuracy of nocturnal HR and HRV assessed via ring PPG in comparison to medical grade ECG. *Physiological measurement*, 41(4), 04NT01.

- Kivrak, M., Guldogan, E. ve Colak, C. (2021). Prediction of death status on the course of treatment in SARS-COV-2 patients with deep learning and machine learning methods. *Computer methods and programs in biomedicine*, 201, 105951.
- Konovalenko, I. ve Ludwig, A. (2022). Generating decision support for alarm processing in cold supply chains using a hybrid k-NN algorithm. *Expert Systems with Applications*, 190, 116208.
- Korkmaz, O. E., Aydemir, Ö. ve Öztürk, M. (2017, May). Detection of smoking, gender and starvation-satiety using photoplethysmogram signals. In *2017 25th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- Kourtiti, K., Pele, M. M. M., Nijkamp, P. ve Pele, D. T. (2021). Safe cities in the new urban world: A comparative cluster dynamics analysis through machine learning. *Sustainable Cities and Society*, 66, 102665.
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S. ve Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8), 2674.
- Liang, Y., Chen, Z., Liu, G. ve Elgendi, M. (2018). A new, short-recorded photoplethysmogram dataset for blood pressure monitoring in China. *Scientific data*, 5(1), 1-7.
- Malakoutikhah, M., Kazemi, R., Rabiei, H., Alimohammadlou, M., Zare, A. ve Hassanipour, S. (2021). Comparison of mental workload with N-Back test: A new design for NASA-task load index questionnaire. *International Archives of Health Sciences*, 8(1), 7.
- Moraes, J. L., Rocha, M. X., Vasconcelos, G. G., Vasconcelos Filho, J. E., De Albuquerque, V. H. C. ve Alexandria, A. R. (2018). Advances in photoplethysmography signal analysis for biomedical applications. *Sensors*, 18(6), 1894.
- Myszczyńska, M. A., Ojamies, P. N., Lacoste, A., Neil, D., Saffari, A., Mead, R., ... & Ferraiuolo, L. (2020). Applications of machine learning to diagnosis and treatment of neurodegenerative diseases. *Nature Reviews Neurology*, 16(8), 440-456.
- Nakajima, K., Tamura, T. ve Miike, H. (1996). Monitoring of heart and respiratory rates by photoplethysmography using a digital filtering technique. *Medical engineering & physics*, 18(5), 365-372.
- Nilsson, L., Johansson, A. ve Kalman, S. (2000). Monitoring of respiratory rate in postoperative care using a new photoplethysmographic technique. *Journal of clinical monitoring and computing*, 16(4), 309-315.
- Osswald, P. V., Mustafa, S. K., Kaa, C., Obst, P., Friedrich, M., Pfeil, M., ... & Witt,



- G. (2020). Optimization of the production processes of powder-based additive manufacturing technologies by means of a machine learning model for the temporal prognosis of the build and cooling phase. *Production Engineering*, 14(5), 677-691.
- Patil, R. (2015). Noise reduction using wavelet transform and singular vector decomposition. *Procedia Computer Science*, 54, 849-853.
- Poh, M. Z., McDuff, D. J. ve Picard, R. W. (2010). Non-contact, automated cardiac pulse measurements using video imaging and blind source separation. *Optics express*, 18(10), 10762-10774.
- Poh, M. Z., McDuff, D. J. ve Picard, R. W. (2011). Advancements in noncontact, multiparameter physiological measurements using a webcam. *IEEE transactions on biomedical engineering*, 58(1), 7-11.
- Pokorski, K. ve Patorski, K. (2010). Visualization of additive-type moiré and time-average fringe patterns using the continuous wavelet transform. *Applied optics*, 49(19), 3640-3651.
- Prabha, A., Yadav, J., Rani, A. ve Singh, V. (2021). Design of intelligent diabetes mellitus detection system using hybrid feature selection based XGBoost classifier. *Computers in Biology and Medicine*, 136, 104664.
- Raj, M. P., Swaminarayan, P. R., Saini, J. R. ve Parmar, D. K. (2015). Applications of pattern recognition algorithms in agriculture: a review. *International Journal of Advanced Networking and Applications*, 6(5), 2495.
- Reisner, A., Shaltis, P. A., McCombie, D., Asada, H. H., Warner, D. S. ve Warner, M. A. (2008). Utility of the photoplethysmogram in circulatory monitoring. *The Journal of the American Society of Anesthesiologists*, 108(5), 950-958.
- Rodriguez-Labra, J. I., Kosik, C., Maddipatla, D., Narakathu, B. B. ve Atashbar, M. Z. (2021). Development of a PPG Sensor Array as a Wearable Device for Monitoring Cardiovascular Metrics. *IEEE Sensors Journal*, 21(23), 26320-26327.
- Rubins, U., Upmalis, V., Rubenis, O., Jakovels, D. ve Spigulis, J. (2011). Real-time photoplethysmography imaging system. In *15th Nordic-Baltic Conference on Biomedical Engineering and Medical Physics (NBC 2011)* (pp. 183-186). Springer, Berlin, Heidelberg.
- Rubio, S., Díaz, E., Martín, J. ve Puente, J. M. (2004). Evaluation of subjective mental workload: A comparison of SWAT, NASA-TLX, and workload profile methods. *Applied psychology*, 53(1), 61-86.
- Scully, C. G., Lee, J., Meyer, J., Gorbach, A. M., Granquist-Fraser, D., Mendelson, Y. ve Chon, K. H. (2011). Physiological parameter monitoring from optical

- recordings with a mobile phone. *IEEE Transactions on Biomedical Engineering*, 59(2), 303-306.
- Shah, F. A. ve Lone, W. Z. (2022). Quadratic-phase wavelet transform with applications to generalized differential equations. *Mathematical Methods in the Applied Sciences*, 45(3), 1153-1175.
- Shi, J., Zheng, J., Liu, X., Xiang, W. ve Zhang, Q. (2020). Novel short-time fractional Fourier transform: theory, implementation, and applications. *IEEE Transactions on Signal Processing*, 68, 3280-3295.
- Smith, J. O. ve Abel, J. S. (1999). Bark and ERB bilinear transforms. *IEEE Transactions on speech and Audio Processing*, 7(6), 697-708.
- Sun, Y., Azorin-Peris, V., Kalawsky, R., Hu, S., Papin, C. ve Greenwald, S. E. (2012). Use of ambient light in remote photoplethysmographic systems: comparison between a high-performance camera and a low-cost webcam. *Journal of biomedical optics*, 17(3), 037005.
- Tanveer, M., Richhariya, B., Khan, R. U., Rashid, A. H., Khanna, P., Prasad, M. ve Lin, C. T. (2020). Machine learning techniques for the diagnosis of Alzheimer's disease: A review. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 16(1s), 1-35.
- Tao, R., Li, Y. L. ve Wang, Y. (2009). Short-time fractional Fourier transform and its applications. *IEEE Transactions on Signal Processing*, 58(5), 2568-2580.
- Tarassenko, L., Villarroel, M., Guazzi, A., Jorge, J., Clifton, D. A. ve Pugh, C. (2014). Non-contact video-based vital sign monitoring using ambient light and auto-regressive models. *Physiological measurement*, 35(5), 807.
- Tavares, T., Nogueira, M., Rosário, D., Santos, A. ve Cerqueira, E. (2020). Traffic model based on autoregression for ppg signals in wearable networks. *IEEE Networking Letters*, 2(2), 49-53.
- Thomas, K. P., Guan, C., Lau, C. T., Vinod, A. P. ve Ang, K. K. (2009). A new discriminative common spatial pattern method for motor imagery brain-computer interfaces. *IEEE Transactions on Biomedical Engineering*, 56(11), 2730-2733.
- Tozlu, B. H., Şimşek, C., Aydemir, O. ve Karavelioglu, Y. (2021). A High performance electronic nose system for the recognition of myocardial infarction and coronary artery diseases. *Biomedical Signal Processing and Control*, 64, 102247.
- Tripathy, R. K., Bhattacharyya, A. ve Pachori, R. B. (2019). A novel approach for detection of myocardial infarction from ECG signals of multiple electrodes. *IEEE Sensors Journal*, 19(12), 4509-4517.

- Verkruyse, W., Svaasand, L. O. ve Nelson, J. S. (2008). Remote plethysmographic imaging using ambient light. *Optics express*, 16(26), 21434-21445.
- Wang, W., Den Brinker, A. C., Stuijk, S. ve De Haan, G. (2016). Algorithmic principles of remote PPG. *IEEE Transactions on Biomedical Engineering*, 64(7), 1479-1491.
- Wang, W., den Brinker, A. C. ve De Haan, G. (2019). Discriminative signatures for remote-PPG. *IEEE Transactions on Biomedical Engineering*, 67(5), 1462-1473.
- Wedekind, D., Kleyko, D., Osipov, E., Malberg, H., Zaunseder, S. ve Wiklund, U. (2018). Robust methods for automated selection of cardiac signals after blind source separation. *IEEE Transactions on Biomedical Engineering*, 65(10), 2248-2258.
- Wei, X., Chen, W. ve Li, X. (2021). Exploring the financial indicators to improve the pattern recognition of economic data based on machine learning. *Neural Computing and Applications*, 33(2), 723-737.
- Yang, L., Liu, M., Dong, L., Zhao, Y. ve Liu, X. (2015). Motion-compensated non-contact detection of heart rate. *Optics Communications*, 357, 161-168.
- Yu, S., Hu, S., Azorin-Peris, V., Chambers, J. A., Zhu, Y. ve Greenwald, S. E. (2011). Motion-compensated noncontact imaging photoplethysmography to monitor cardiorespiratory status during exercise. *Journal of biomedical optics*, 16(7), 077010.
- Zhang, B., Chai, C., Yin, Z. ve Shi, Y. (2021). Design and implementation of an EEG-based learning-style recognition mechanism. *Brain Sciences*, 11(5), 613.

