



Kısa Zamanlı Fotopletismografi İşaretlerinin En Uygun Frekans Aralığı ile Hipertansiyon Hastalığının Belirlenmesi

Determination of Hypertension Disease with Optimal Frequency Range of Short-Time Photoplethysmography Signals

Tuğba AYDEMİR¹ ve Mehmet ŞAHİN²

Fizik Bölümü
Recep Tayyip Erdoğan Üniversitesi
Rize, Türkiye
tugba_aydemir17@erdogan.edu.tr¹,
mehmet.sahin@erdogan.edu.tr²

Önder AYDEMİR³

Elektrik-Elektronik Mühendisliği
Karadeniz Teknik Üniversitesi
Trabzon, Türkiye
onderaydemir@ktu.edu.tr³

Özetçe—Hipertansiyon, normal kabul edilen tansiyon değerinin yüksek olduğu duruma denir. Bu durum damar içerisinde yer alan kanın, damar duvarına doğru gerçekleştirdiği yüksek basınçla kendini gösterir. Hipertansiyon en fazla beyin, böbrekler, gözler, atardamarlar ve kalbi etkiler. Bundan dolayı toplumda yaygın olan bu hastalığın teşhisi önemlidir. Teşhisi ise günler, haftalar hatta aylar alabilir. Sıklıkla, kişiye tansiyon holteri denilen bir cihaz 24 ya da 48 saat süre ile bağlanır ve kişinin tansiyonu belirli zaman aralıkları ile kaydedilir. Uzman doktorun bu sonuçları değerlendirmesi ile tanı koyulabilmektedir. Son yıllarda, zaman alıcı bu tanı aşamasını hızlandırmak ve akıllı modeller önermek amacıyla çeşitli fizyolojik ölçüm tekniklerinden faydalanılmaktadır. Bu tekniklerden biri de fotopletesmografi (PPG)'dir. Bu çalışmada 2.1 saniyelik kısa zamanlı PPG işaretlerinin en uygun frekans aralıkları kullanılarak kişilerde hipertansiyon hastalığının tespitine yönelik bir model önerilmiştir. Önerilen model 219 kişiye ait PPG verileri ile test edilmiş ve %76.15 oranında sınıflandırma doğruluğu ile hastalık tespiti yapılmıştır. Elde edilen sonuçlar makine öğrenmesine dayalı hipertansiyon teşhisinin etkili bir şekilde kısa zamanlı PPG işaretlerinin 1.4-5.7 Hz frekans aralıkları kullanılarak yapılabileceğini göstermiştir.

Anahtar Kelimeler — fotopletesmografi; hipertansiyon; sınıflandırma; öznelilik çıkarma.

Abstract— Hypertension is the condition where the normal blood pressure is high. This situation is manifested by the high pressure of the blood in the vein towards the vessel wall. Hypertension mostly affects the brain, kidneys, eyes, arteries and heart. Therefore, the diagnosis of this common disease is important. It may take days, weeks or even months for diagnosis. Often a device called a blood pressure holter is connected to the person for 24 or 48 hours and the person's blood pressure is recorded at certain intervals. Diagnosis can be made by the

specialist physician considering these results. In recent years, various physiological measurement techniques have been used to accelerate this time-consuming diagnostic phase and propose intelligent models. One of these techniques is photoplethysmography (PPG). In this study, a model for the detection of hypertension disease in individuals using the optimal frequency ranges of 2.1 second short-time PPG signals was proposed. The proposed model was tested with PPG data of 219 people and the disease was determined with classification accuracy of 76.15%. The results showed that the diagnosis of hypertension based on machine learning can be performed effectively by using frequency ranges of 1.4-5.7 Hz of short time PPG signals.

Keywords — photoplethysmogram; hypertension; classification; feature extraction.

I. GİRİŞ

Örüntü tanıma ve makine/derin öğrenme tıptan mühendisliğe kadar birçok alanda uygulama alanı olan son on yılın popüler konuları arasında yer almaktadır. Özellikle tıp alanında fizyolojik veri toplama tekniklerinin de teknolojik olarak gelişmesi ile örüntü tanıma ve makine/derin öğrenme tabanlı çalışmalar giderek artmaktadır [1].

Fotopletesmografi (PPG) tıp alanında gelişme gösteren fizyolojik verilerden bir tanesidir. 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 [2] yanında solunum hızı ölçümü [3], kandaki oksijen doyumluğu ölçümü [4], kandaki şeker seviyesi ölçümü [5], atrial fibrilasyon tespiti [6], tansiyon ölçümü [7] ve

kan dolaşımı takibi [8] 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 [9]. PPG işaretlerinin ölçüm kolaylığı ve bunlardan elde edilen bilgilerin çeşitliliği gibi sağladığı avantajlardan dolayı biyomedikal uygulamalarda kullanımını giderek yaygınlaşmaktadır. PPG işaretleri elde edilirken birbiriyle eşleşmiş ışık yayan diyot (Light Emitting Diode, LED) ve foto direnç kullanılır [10], [11].

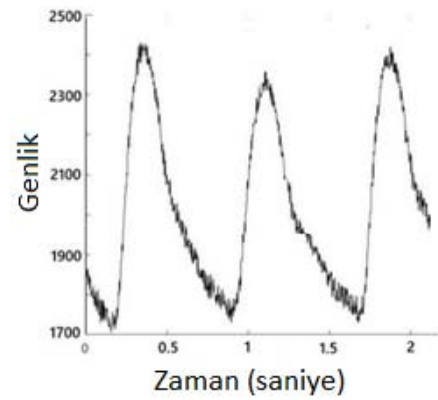
Literatürde PPG ile yapılan çalışmalar incelendiğinde, Kavsaoglu ve arkadaşlarının yaptığı çalışmada PPG işaretleri kullanılarak biyometrik özellik tanıma işlemi gerçekleştirilmiş ve k -en yakın komşu (k -EYK) sınıflandırıcısı kullanılarak %94.44 lük başarı oranı elde edilmiştir [12]. Bu çalışmada kullanılan verilerin verinin bir denemesi 15 periyottur (yaklaşık 15 saniye). İşaretler 2 kHz'te kaydedilmiş ve 0-10 Hz'lik bir filtrelemeye tabi tutulmuştur. Yapılan diğer bir çalışmada ise Ghosal ve arkadaşları 30 sağlıklı ve 20 hasta bireyden aldıkları PPG işaretleriyle, kendi kendini düzenleme haritası yöntemini önererek sistolik zirve ve desistolik zirve teşhisini sırasıyla %100 ve %95 oranında başarıyla sınıflandırmışlardır [13]. Çalışmalarında işaretlerin süresi ve örnekleme frekansı bilgileri verilmemiştir. Pan 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 [14]. Çalışmalarında PPG işaretlerini 15 periyot olarak 1 kHz'lik örnekleme frekansı ile kaydetmişlerdir. Korkmaz ve arkadaşlarının yaptığı çalışmada ise 8 kHz örnekleme frekansı ile 60 saniyelik PPG işaretleri kullanılarak sigara kullanımının, cinsiyet ve açlık-tokluk durumlarının belirlenmesinde k -EYK sınıflandırıcısı kullanılarak sırasıyla %73.7, %72.8 ve %65.8 oranında bir doğruluk elde edilmiştir [15]. Bir başka çalışmada ise Prabhakar ve arkadaşları kardiyovasküler hastalık tespiti için sadece 42 kişiden kaydettikleri 100 Hz'lik örnekleme frekansı ile yaklaşık 7 saniyelik işaretleri kullanmışlar ve %99.48 oranında bir sınıflandırma doğruluğu (SD) elde etmişlerdir [16]. Literatürde yapılan bu ve diğer çalışmalar değerlendirildiğinde PPG'nin en uygun frekans aralığının belirlenmesine yönelik ve kısa zamanlı işaretler kullanılarak hipertansiyon hastalığının belirlenmesinin işlenmediği görülmektedir.

Literatürde yapılan çalışmalarda farklı frekans aralıkları dikkate alınarak uygulamalar yapılmış olup, en uygun frekans aralığı kısa zamanlı PPG işaretler için bu çalışmada olduğu gibi araştırılmamıştır. Önerilen bu çalışmada alt kesim frekansı 0 Hz'den başlayarak 0.1 Hz'lik adımlarla 9.9 Hz'e kadar, üst kesim frekansı ise 0.1 Hz'den 0.1 Hz aralıklar ile 10 Hz'e kadar değiştirilerek en uygun frekans aralığı aranmıştır. Elde edilen sonuçlara göre kısa zamanlı PPG işaretleri kullanılarak hipertansiyon hastaları %76.15'lik SD ile tespit edilebilmiştir. Önerilen yöntem ile elde edilen detaylı teknikler ve sonuçlar ilerleyen başlıklarda verilmiştir.

II. MATERYAL VE YÖNTEM

A. Verilerin toplanması

Veri toplama işlemi araştırmaya etik onayı veren Çin Guilin Halk Hastanesi'nde gerçekleştirilmiştir. 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 [17]. Örnek bir PPG işareti Şekil 1'de gösterilmektedir.



Şekil 1. Örnek PPG verisi

B. Öznitelik Çıkarma ve Sınıflandırma

Etkin, diğer bir deyişle ayırt ediciliği yüksek öznitelikler sınıflandırma performansını doğrudan ilgilendirdiği için öznitelik 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 [18]. Bu algoritmaların başarılı olması çok sayıda örneğe bağlıdır [19]. Bu çalışmada kullanılan veriler tek elektrot ile sınırlı sayıda kaydedildiği için bu algoritmalar yerine k -EYK ve destek vektör makinaları (DVM) gibi klasik sınıflandırıcı yaklaşımları tercih edilmiştir.

Önerilen yöntemin genel akış şeması Şekil 2'de gösterilmiştir. 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 rastgele alt örnekleme çapraz onaylama yöntemi ile eğitilir. Test aşamasında ise test kümesinden çıkarılan öznitelikler eğitilen sınıflandırıcı ile hipertansiyon/sağlıklı şeklinde sınıflandırılır. Band geçiren filtre Şekil 3'te 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.

Bu çalışmada PPG işaretlerinden toplam band gücü (TBG), özbağlanım parametreleri, türevin standart sapması (T_σ) ve sıfır geçiş sayısı (SGS) öznelik olarak çıkarılmıştır. TBG için ayrık Fourier dönüşümü katsayıları (AFDK) kullanılmıştır. AFDK Eşitlik 1'de verildiği gibi hesaplanmıştır.

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


AFDK hesaplanmış işarete ait TBG,

$$TBG = \sum \left\| AFDK[k] \right\|_{f_L}^{f_H}{}^2 \quad (2)$$

eşitliği ile hesaplanmıştır. Burada $AFDK[k] \Big|_{f_L}^{f_H}$, alt kesim frekansı (f_L) ve üst kesim frekansı (f_H) arasında kalan AFDK'yı ifade etmektedir.



Şekil 2. Akış şeması



Şekil 3. Band geçiren filtre [7]

Özbağlanım model parametreleri bir işaretin geçmişe bağlı değerlerini kullanarak gelecekteki durumunu kestirmeye yarayan lineer bir modeldir. Kurulacak modelin genellikler p olarak gösterilen bir derecesi ve oluşturulan modelin, esas işaret ile arasındaki hatayı tanımlayan $e(n)$ parametresi bulunur. Derecesi p olan özbağlanım modeli Eşitlik 3'te verilmektedir. Bu çalışmada sınıflandırıcı eğitimi aşamasında en uygun model parametresi 5 olarak bulunmuştur. Özbağlanım katsayıları Matlab 2010a'da ar fonksiyonu kullanılarak elde edilmiştir.

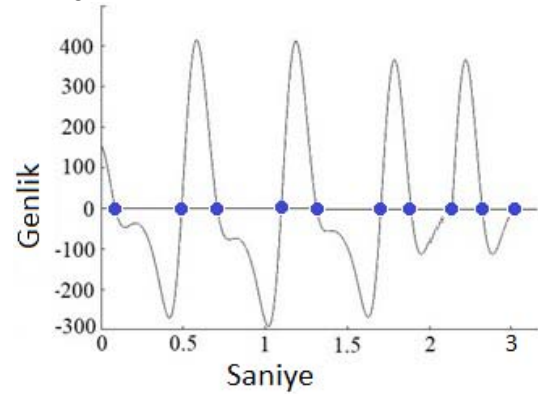
$$x(n) = -\sum_{k=1}^p a(k)x(n-k) + e(n) \quad (3)$$

Türev alma işlemi mevcut örnek değerini bir sonraki örnekten çıkartarak Eşitlik 4'te verildiği gibi hesaplanmıştır. Elde edilen Bu türev işaretinin (T) standart sapması ise Eşitlik 5 ile elde edilmiştir.

$$T = \sum_{n=1}^{L-1} x(n+1) - x(n) \quad (4)$$

$$T_\sigma = \sqrt{\frac{\sum (T - \bar{T})^2}{L_T - 1}} \quad (5)$$

SGS bir işaretin x eksenini kesme sayısı olarak ifade edilir. Örneğin Şekil 4'te 1.4-5.7 Hz'lik bir band geçiren filtre uygulanmış PPG işareti için sıfır geçiş noktaları mavi noktalar ile gösterilmiştir [7]. Bu işaret için SGS 10 olarak hesaplanmıştır. Burada band geçiren filtreleme işleminde ortalama değer (DC değeri) ham işaretten çıkartıldığını belirtmek gerekir.



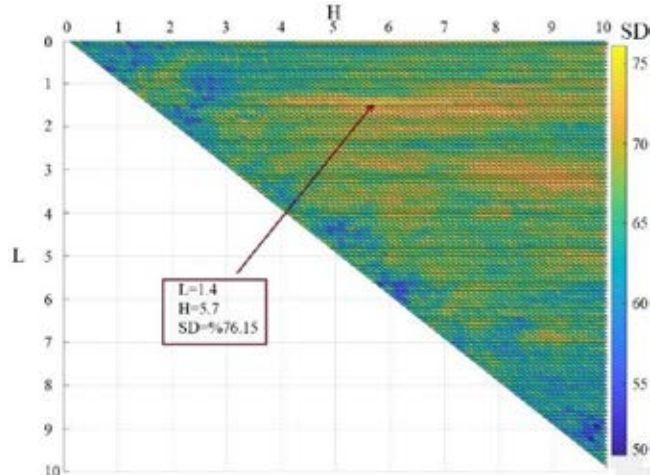
Şekil 4. Sıfır geçiş sayısı

Çıkarılan öznelikler literatürde örüntü tanıma ve makine öğrenmesi uygulamalarında sıklıkla kullanılan ve başarılı sonuçlar veren DVM ve k -EYK sınıflandırıcıları ile sınıflandırılmıştır. Kişilerin ilk iki parça veri kaydı eğitim verisi, son parça veri kayıtları ise test verisi olarak seçilmiştir. DVM için radyal tabanlı çekirdek kullanılmış olup, bu sınıflandırıcının en uygun sigma parametresi 0.2 ile 2.5 arasında 0.2 adımlarla sınıflandırıcı eğitimi aşamasında taranmıştır. Benzer biçimde k -EYK için en uygun en yakın komşu parametresi k ise 1 ile 25 arasında birer adımla taranmıştır. Yukarıda da belirtildiği gibi rastgele alt örnekleme çapraz onaylama yöntemi ile en uygun sınıflandırıcı parametreleri sınıflandırıcı eğitimi aşamasında belirlenmiştir.

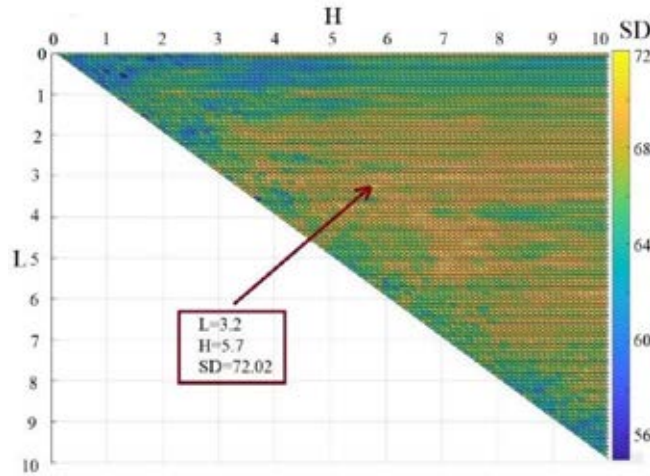
III. SONUÇLAR

Bu çalışmada kısa zamanlı PPG işaretlerinin hipertansiyon hastalığının tespiti için kullanılabilir en uygun frekans aralıkları tespit edilmiştir. DVM ve k -EYK sınıflandırıcıları için 0-10 Hz aralığında olası tüm band geçiren filtreler için elde edilen sonuçlar sırasıyla Şekil 5 ve Şekil 6'da gösterilmektedir. Bu şekillerde 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 1.4-5.7 Hz bandı kullanılarak DVM sınıflandırıcısı ile %76.15 oranında tespit edilebilmiştir. k -EYK

sınıflandırıcısı ile ise 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 içerisinde düşen olası band geçiren filtreler için elde edildiği yine Şekil 5 ve Şekil 6'da verilen sonuçlarda görülmektedir.



Şekil 5. DVM için olası tüm band geçiren filtreleme sonuçları



Şekil 6. k-EYK için olası tüm band geçiren filtreleme sonuçları

IV. BULGULAR

Bu çalışmada önerilen yöntemle kısa zamanlı PPG işaretleri ile hipertansiyon hastalığının tespitinin yapılabileceği gösterilmiştir. Bunun için DVM sınıflandırıcısı ile elde edilen en uygun frekans aralığının 1.4-5.7 Hz olduğu anlaşılmaktadır. Diğer taraftan PPG işaretlerini temsil etmek için TBG, özbağlanım parametreleri, $T\sigma$ ve SGS özniteliklerinin kullanılabilceği gösterilmiştir.

Bu çalışmada PPG işaretlerinin en yüksek sınıflandırma doğruluğu sağlayan frekans aralığı, 0-10 Hz içerisinde 0.1 Hz çözünürlükle düşen 5056 olası band geçiren filtre değerlendirilmiştir. Bu sonuçların renk kodlaması ile temsil edilmesi tüm sonuçları hızlı bir şekilde değerlendirilmesine imkan vermektedir. Gelecek çalışmalarda karınca kolonisi ve

parçacık sürü optimizasyonu gibi sezgisel yöntemler test edilerek önerilen yöntemle karşılaştırma yapılacaktır.

KAYNAKLAR

- [1] Yang, Chengming, et al. "Using PPG signals and wearable devices for atrial fibrillation screening." *IEEE Trans. on Ind. Electronics* (2019).
- [2] Riaz, F., Azad, M. A., Arshad, J., Imran, M., Hassan, A., & Rehman, S. (2019). Pervasive blood pressure monitoring using Photoplethysmogram (PPG) sensor. *Future Generation Computer Systems*, 98, 120-130.
- [3] Nilsson L, Johansson A and Kalman S 2000 Monitoring of respiratory rate in postoperative care using a new photoplethysmographic technique *J. Clin. Monit. Comput.* 16 309–15
- [4] Aoyagi T, Miyasaka K. Pulse oximetry: its invention, contribution to medicine, and future tasks. *Anesth Analg.* 2002 Jan;94(1 Suppl):S1-3.
- [5] Habbu, Shradha & Dale, Manisha & Ghongade, Rajesh. (2019). Estimation of blood glucose by non-invasive method using photoplethysmography. *Sādhanā*. 44. 10.1007/s12046-019-1118-9.
- [6] Conroy, Thomas & Guzman, Jairo & Hall, Burr & Tsouri, Gill R & Couderc, Jean-Phillippe. (2017). Detection of atrial fibrillation using an earlobe photoplethysmographic sensor. *Physiological Measurement*. 38. 10.1088/1361-6579/aa8830.
- [7] Aydemir T., Sahin M., Aydemir O., Determination of hypertension disease using chirp z-transform and statistical features of optimal band-pass filtered short-time photoplethysmography signals, *Biomedical Physics & Engineering Express*, doi: 10.1088/2057-1976/abc634
- [8] Reisner, Andrew & Shaltis, Phillip & McCombie, Devin & Asada, Harry. (2008). Reisner A, Shaltis PA, McCombie D, Asada HH. Utility of the photoplethysmogram in circulatory monitoring. *Anesthesiology*. 108. 950-8. 10.1097/ALN.0b013e31816c89e1.
- [9] Fong, M. W. K., et al., "SVR ensemble-based continuous blood pressure prediction using multi-channel photoplethysmogram", *Com. in bio. & medicine*, 113, 103392, 2019.
- [10] B. Hertzman, "The Blood Supply of Various Skin Areas as Estimated by the Photoelectric Plethysmograph," *Am. J. Physiol.*, vol. 124, pp. 328-340, 1938.
- [11] T. Trafford and K. Lafferty, "What Does Photoplethysmography Measure," *Med. Biol. Eng. Comput.*, vol. 22, no. 5, pp. 479-480, Sept.1984.
- [12] R. Kavsaoğlu, K. Polat, and M. R. Bozkurt, "A Novel Feature Ranking Algorithm for Biometric Recognition with PPG Signal," *Computer in Biology and Medicine*, vol. 49, pp. 1-14, 2014.
- [13] P. Ghosal and G. Rajarshi, "Classification of Photoplethysmogram Signal Using Self Organizing Map," *IEEE International Conference on Research in Computational Intelligence and Communication Networks*, pp. 114-118, 2015.
- [14] P. Fan, H. Peiyu and L. Shangven, "Feature extraction of photoplethysmography signal using wavelet aproch," 2015 IEEE Conference on Digital Signal Processing, pp. 283-286, Singapore, 2015.
- [15] O. E. Korkmaz, Ö. Aydemir ve M. Öztürk, "Fotoplethysmografi işaretleri kullanılarak sigara kullanımının, cinsiyet ve aklık-tokluk durumunun belirlenmesi," *IEEE 25. Sinyal İşleme ve İletişim Uygulamaları Kurultayı*, pp. 1-4, Antalya, 15-18 Mayıs 2017.
- [16] Prabhakar, S. K., Rajaguru, H., & Lee, S. W. "Metaheuristic-Based Dimensionality Reduction and Classification Analysis of PPG Signals for Interpreting Cardiovascular Disease". *IEEE Access*, 7, 165181-165206, 2019.
- [17] Liang, Y., Chen, Z., Liu, G., & Elgendi, M., "A new, short-recorded photoplethysmogram dataset for blood pressure monitoring in China", *Scientific data*, 5, 180020, 2018.
- [18] Sirinukunwattana, K., Shan e Ahmed Raza, Tsang, Y. W., Snead, D. R., Cree, I. A., & Rajpoot, N. M., "Locality sensitive deep learning for detection and classification of nuclei in routine colon cancer histology images", *IEEE Trans. Med. Imaging*, 35(5), 1196-1206, 2016.
- [19] Wu, H., & Prasad, S., "Semi-supervised deep learning using pseudo labels for hyperspectral image classification", *IEEE Transactions on Image Processing*, 27(3), 1259-1270, 2017.