



Videolardan Kalp Atış Hızı Kestirimi Üzerine Bir İnceleme

Mustafa Korkmaz^{1*}, Saffet Vatansever²

^{1*} Bursa Teknik Üniversitesi, Mekatronik Mühendisliği, Bursa, Türkiye, (ORCID: 0000-0002-1874-1814), mmustafaa.korkmaz@gmail.com

² Bursa Technical University, Mekatronik Mühendisliği, Bursa, Türkiye, (ORCID: 0000-0002-4680-1263), saffet.vatansever@btu.edu.tr

(6th International Symposium on Innovative Approaches in Smart Technologies (ISAS) 2022 – 8-10 December 2022)

(DOI: 10.31590/ejosat.1221945)

ATIF/REFERENCE: Korkmaz, M. & Vatansever, S. (2022). Videolardan Kalp Atış Hızı Tespiti Üzerine Bir İnceleme. *Avrupa Bilim ve Teknoloji Dergisi*, (44), 65-73.

Öz

Kalp atış hızı; kişinin sağlığı, aktivite seviyesi, stres durumu, zindeliği ve benzeri fizyolojik durumları hakkında önemli ipuçları vermektedir. Kalp atış hızı, elektrokardiyogram (EKG) ve nabız oksimetreleriyle ölçülebilir olmakla birlikte, bu cihazlar sürekli temas gerektirdiğinden zamanla rahatsız edici olabilmektedir. Bilgisayarlı görü (computer vision) alanındaki son gelişmeler, bir kişiye elektrot veya nabız oksimetreleri takmanın mümkün veya uygun olmadığı durumlarda, videolardan kişinin kalp atış hızını tespit etmeye olanak sağlamıştır. Uzaktan fotoplethysmografi (rPPG), bir video kamera aracılığıyla derideki hassas renk değişikliklerini yakalayıp, yaşamsal belirtilerin tespit edilmesine imkân sağlayan bir teknolojidir. Son yıllarda yapılan çalışmalar, uzaktan kalp atış hızı tespiti için en uygun bölgenin yüz olduğunu göstermiştir. Bu çalışmada; videolar aracılığıyla kişilerin yüz bölgesinden kalp atış hızı kestirimini nasıl yapılabildiği, kalp atışı hızı kestirimi sürecindeki aşamaların nasıl iyileştirilebileceği ve nasıl daha yüksek doğrulukta kalp atışı hızı tespiti yapılabileceği hakkında literatürdeki mevcut yöntemler incelenerek kapsamlı bir analiz yapılmıştır.

Anahtar Kelimeler: Kalp atış hızı, uzaktan fotoplethysmografi (rPPG), yüz videoları, derin öğrenme.

Heart Rate Estimation from Videos: A Review

Abstract

Heartbeat rate provides important signs about a person's health, activity level, stress level, vitality, and other related physiological conditions. Although electrocardiograms (ECG) and pulse oximeters can be exploited to measure the heart rate, these instruments might become uncomfortable with time due to the requirement for constant contact. Recent advances in computer vision have made it achievable to detect a person's heart rate from videos when it is impossible or impractical to attach electrodes or pulse oximeters to a person. Remote photoplethysmography (rPPG) is a technology that detects vital physiological information by capturing considerably precise color changes in the skin via a video camera. Recent studies have shown that the face is the most appropriate area to use for remote heart rate detection. In this study, a comprehensive analysis has been conducted by investigating the existing methods in the literature on how to estimate the heartbeat rate from a person's face through videos, how to improve the stages in the heart rate estimation process, and hence to improve the accuracy of the estimations.

Keywords: Heartbeat rate, remote photoplethysmography (rPPG), face videos, deep learning.

* Sorumlu Yazar: mmustafaa.korkmaz@gmail.com

1. Giriş

Kişilerin sağlık durumlarının takibi, araştırmacıların dikkatini çeken önemli konulardan biridir. Kalp atış hızı, vücut ısısı, solunum hızı, kan oksijen doygunluğu, kalp hızı değişimi ve kan basıncı gibi yaşamsal belirtiler, insan vücudunun fizyolojik ve duygusal durumunu izlemek için kullanılan yaygın işaretlerdir (Cheng ve ark., 2021). Kalp, insan vücudundaki en önemli organlardan biridir. Kalp atış hızındaki anormalliklere, kalbin kan pompalama hareketini kontrol eden normal elektriksel uyarıyı bozan fizyolojik ve patolojik faktörler neden olmaktadır (Hassan ve ark., 2017). Yüksek tansiyon, sigara, ateş, ani stres, ilaçların yan etkileri, uyku apnesi, miyokardit ve yaşlanma gibi etmenler kalp dokularında hasara yol açarak ciddi sağlık sorunlarına sebebiyet verebilmektedir. Kalp atış hızının düzenli takibi, kardiyovasküler sorunların erken tespit edilmesini ve önlenmesini sağlayabilir. Sağlıklı yetişkinlerde kalp atış hızı dakikada 60 ila 100 arasında değişen atım sayısı (bpm) olarak ölçülmektedir (Hassan ve ark., 2017; Sinhal ve ark., 2020). Araştırmacılar kalp atış hızını tespit etmek için çeşitli temaslı ve temassız yöntemler geliştirmişlerdir.

Elektrokardiyogram (EKG) ve nabız oksimetreleri ile kalp atış hızı, tespit edilebilmektedir. Elektrokardiyogram, cilde yerleştirilen elektrotlar aracılığıyla kalbin elektriksel aktivitesindeki voltaj değişikliklerini ölçmektedir. Nabız oksimetreleri ise fotopletismografik (ppg) sinyallerinden faydalanarak ölçüm yapmaktadır (Pagano ve ark., 2022). Fotopletismografi, vücuttaki kan dolaşımından kaynaklanan derideki renk değişimlerinin bir sensör yardımıyla yakalanarak dijitalleştirilmesi işlemidir (YAMAN, 2018). Oksimetreler temel olarak bir ışık kaynağı ve ışık detektöründen oluşan sensör aparatından ibarettir. Ölçüm işlemi, genellikle kulak memesi ya da parmağın sensör aparatının arasına yerleştirilmesi ile gerçekleştirilir. EKG için kullanılan yapışkan jel elektrotlar ile kulak ve parmağa takılan oksimetreler; yaşlılar, bebekler, hastalar, sporcular gibi sürekli kalp atış hızı tespiti gereken gruplar için rahatsız edici olabilmektedir (Bush, 2016).

Uzaktan fotopletismografi (rPPG) kullanarak ciltteki küçük renk değişimlerini veya vücut hareketlerini analiz ederek yüz görüntülerinden ve videolardan kalp atış hızının tespiti son zamanlardaki en önemli araştırma konularından biri olmuştur. Biyosinyallerin uzaktan algılanması, temas gerektiren kalp atış hızı ölçüm araçlarıyla ilişkili kablolu ve dağınıklığı minimuma indirmiştir (Bush, 2016). Sağlık durumu takibi, bulaşıcı hastalıkların kontrolü, biyometrik canlılık tespiti, tele tıp, yeni doğan bebeklerin kontrolü, doğal afetler sırasında hayatta kalanları aramak için ve sporcuların durum takibi gibi konularda videodan kalp atış hızı tespitinden yararlanılabilmektedir (Deng & Kumar, 2020). Bu çalışmada, videolardan kalp atış hızı tespitinde literatürdeki renk yoğunluk temelli ve derin öğrenmeye dayalı teknikler incelenerek, nasıl daha güvenilir kalp atış hızı tahmini yapılabileceği analiz edilmiştir.

2. Uzaktan Fotopletismografi (rPPG)

Uzaktan Fotopletismografi (rPPG) genel olarak, kalbin kan pompalama döngüsüyle ciltte gerçekleşen küçük renk değişimlerinin bir sensör veya kamera ile yakalanıp analiz edilerek dolaşım sistemiyle alakalı bilgilerin elde edilmesine dayanan bir çalışma alanıdır. rPPG yöntemlerinde, temas tabanlı

PPG sinyali elde etmede kullanılan ışık yayan diyot ortam aydınlatmasıyla, algılayıcı sensör ise bir dijital kamerayla (örneğin, web kamerası, standart RGB kamera, yakın kızılötesi kamera), değiştirilmektedir. Deri altındaki kan damarlarının hacimsel değişikliklerini ölçmek için bir ışık kaynağı ve kamera kullanılmaktadır. Dokunun aydınlatılması ile kan akışından yansıyan veya iletilen ışık yoğunluğundaki küçük değişiklikler kamera tarafından yakalanarak, rPPG sinyali elde edilmektedir (Shao ve ark., 2021; Sun & Thakor, 2016).



Şekil 1. Ciltten yansıyan PPG sinyalinin kamera tarafından yakalanması (Wang, 2017).

Kalp döngüsü sırasında, hemoglobin konsantrasyonundaki küçük değişiklikler, kan damarları tarafından emilen ışık miktarında dalgalanmalara neden olarak cilt yoğunluğu değerlerinde değişikliklere neden olur (Swinehart, 1962). Hemoglobinin, yeşil rengi kırmızıya göre daha iyi emmektedir. Ayrıca yeşil renk dokularda daha iyi ilerleyebilmektedir. Bu sebeple yeşil renk, diğer renklere göre daha güçlü PPG sinyalleri elde etmeye imkan sağlamaktadır. (Tamura ve ark., 2014). rPPG yöntemi ile cildin epidermis katmanındaki speküler ve hipodermisteki difüzyon yansıma bileşenleri arasındaki kontrast ölçülmektedir. Deriden yansıyan kırmızı, mavi ve yeşil renk kanalları uygun bir hesaplama yaklaşımı kullanılarak fizyolojik bir sinyal elde edilmektedir. (Premkumar & Hemanth, 2022).


Kalbin kasılması ve gevşemesi esnasında damarlarda farklı durumlar gözlenir. Kalbin vücuda kanı pompalaması ile damarlardan geçen kan miktarı artar, ışık miktarı ise azalır. Kalbin gevşemesi sırasında ise damarlardan geçen kan miktarı azalır, ışık miktarı ise artar (Elgendi, 2012). Tipik bir PPG sinyali; kemik, kas ve deriden geçen ve kan damarlarından geçen olmak üzere iki ayrı bileşenden oluşmaktadır (Aydemir, 2019). Kan damarlarından geçen sinyalin yükseltilmesi, istenen bilginin çıkarılmasında kritik rol oynamaktadır (Aydemir, 2019).

3. Kalp Atış Hızı Tespit Süreci

Videolardan kalp atış hızının elde edilme süreci Şekil 2'deki blok diyagramda özetlenmiştir. Ayrıca bu süreçte kullanılan renk yoğunluk temelli ve derin öğrenme tabanlı tekniklerinin analiz ve incelemesi yapılmıştır. Kalp atış hızı kestirim süreci; Analiz Bölgesi (ROI) tespiti, Pletismografik Sinyal Çıkarımı ve Kalp Atış Hızı Tahmini olarak 3 ana aşamaya ayrılmış ve her aşamada kullanılan yöntemler Şekil 2'de incelenmiştir.

Bir kamera, damarlardaki kan hacmi değişimiyle insan cildinden kalp atış hızını yakalayabilir ve optik spektrumun farklı bölgelerini örnekleyerek kırmızı, yeşil ve mavi işlenmemiş sinyal izleri üretebilir. Bu ham sinyaller daha sonra fizyolojik bilgi içeren bir pletismografi sinyali elde etmek için işlenmektedir. Genel olarak, videolardan kalp atış hızı ölçümü

için uzaktanfotopletismografide kullanılan teknikler literatürdeki kullanım sıklığına göre renk yoğunluk temelli ve derin öğrenme tabanlı yöntemler olarak 2 kısımda açıklanabilir.



Şekil 2. Kalp Atış Hızı Tespit Süreci Blok Diyagramı.

Renk yoğunluk temelli yöntem, giriş video karelerinin işlenmesine yönelik denetimsiz bir yaklaşımdır. İlk olarak, giriş videosunun her karesinden bir analiz bölgesi (ROI) tespit edilir ve ardından kırmızı, yeşil ve mavi kanalların uzamsal olarak ortalaması alınarak işlenmemiş sinyal izleri oluşturulur. Bu izler daha sonra fotopletismografik sinyali elde etmek için farklı sinyal işleme teknikleriyle işlenir. Son olarak zaman veya frekans bölgesi analizleri yapılarak kalp atış hızı tespit edilmeye çalışılır. rPPG araştırmasının biçimlendirici dönemi, 2008 yılında Verkruysse ve meslektaşlarının, ortam ışığı altında bir denegin yüzünün video kayıtlarının kalp atış hızını ölçmek için yeterince zengin bir sinyal içerdiğini göstermeleriyle başlamıştır (Rouast ve ark., 2018; Verkruysse ve ark., 2008).

Literatürdeki son trendler, kalp atış hızı ölçümünde geleneksel temassız yöntemlerin performansını iyileştirmek için derin öğrenme yöntemlerini kullanmaktadır. Son zamanlarda geliştirilen derin öğrenme tabanlı yöntemler, geleneksel renk yoğunluk temelli yöntemlere göre daha umut verici sonuçlar göstermektedir (Premkumar & Hemanth, 2022). Öğrenme tabanlı yöntemler, kalp atış hızını doğrudan video girişinden tespit edebilmekte ya da sistemin rPPG mekanizmasını baştan öğrenebilmektedir. Derin öğrenme modelleri için gerekli veri kümeleri, RGB kameralar kullanılarak toplanır. Derin öğrenmeye dayalı yöntemler, renk yoğunluk temelli ve derin öğrenme yöntemlerinin kombinasyonu ve rPPG sinyalinin uçtan uca herhangi manuel bir adım olmadan elde edilmesi olarak iki kategoride değerlendirilebilir. Bu iki yöntemde de derin öğrenme tabanlı yaklaşımlar kullanıldığı için çalışmamızda ikisini de derin öğrenme tabanlı yaklaşımın içerisinde inceleyeceğiz.

3.1. Yüz Algılama ve Takibi

rPPG işlemlerinin ilk aşaması video görüntüsünden yüz bölgesinin tespit edilmesidir. Çalışmaların çoğunda, bir makine öğrenmesi yaklaşımına dayanan Viola-Jones algoritması kullanılarak otomatik olarak yüz algılama gerçekleştirilmiştir. Yüz algılama için kullanılan diğer popüler algoritmalar; dlib (Kazemi & Sullivan, 2014), mtcnn (Zhang ve ark., 2016) ve Kanade-Lucas-Tomasi yaklaşımı (Rautaray & Agrawal, 2012) yüksek doğruluğa sahiptir.

3.2. Analiz Bölgesi (ROI) Tespiti

Görüntüde yüz bölgesi tespit edildikten sonra genel algoritmanın doğruluğu ve güvenilirliği üzerinde doğrudan bir etkisi olduğundan, uygun bir ilgi bölgesi (ROI) seçilmesi ve yüzün belli bir alanının analiz edilmesi diğer zorlu adımdır. ROI, algoritma için ham sinyal sağlayan pikselleri içeren bir video karesi içindeki alandır.

3.2.1. Renk Yoğunluk Temelli Yaklaşım

Kalbin kanı pompalaması ile, tendeki renk değişimi literatürdeki çeşitli çalışmalarla doğrulanmıştır (Verkruysse ve ark., 2008). Bu değişim çıplak gözle görülemez de, kameralar tarafından kolayca yakalanabilmektedir. Özellikle görüntülerdeki insan yüzleri analiz edilerek tendeki renk değişim bilgisine ulaşılabilmektedir. Bununla birlikte yüz bölgesindeki bazı alanlar diğer kısımlara göre bu bilgiyi daha güçlü taşımaktadır. Literatürdeki çalışmalar, alın ve yanak bölgelerinin bu bilgiyi taşıyan en hassas bölgeler olduğunu göstermiştir (Meinzer ve ark., 2013). ROI nin tespiti, en önemli PPG bilgisine sahip bir piksel kümesini bulur ve bu piksellerin uzamsal olarak ortalaması alınarak pletismografi sinyali elde edilir (Kwon ve ark., 2015). Birçok araştırmacı, yüzün diğer bölgelerine kıyasla kas hareketlerine daha az duyarlı oldukları için (ElMaghraby ve ark., 2014) alın ve yanaklarını en önemli ROI alanları olarak seçmiştir. Kişi hareketinin neden olduğu gürültü, sinyali rPPG için işe yaramaz hale getirebilir. Bu nedenle, ROI takibinin amacı, ROI'de bulunan piksellerin kişi hareketinden bağımsız bir cilt bölgesine ait olmasını sağlamaktır.


3.2.2 Derin Öğrenme Tabanlı Yaklaşım

Giriş sinyali, bir dijital kamera tarafından kaydedilen orijinal videodur. Bu nedenle, alakasız arka plan bilgilerini yok saymak için yüz algılama veya cilt segmentasyonu gereklidir. Ayrıca, alın ve yanaklar gibi bazı spesifik cilt bölgeleri daha güçlü sinyaller içerir ve genellikle ROI olarak seçilmektedir (Meinzer ve ark., 2013). Bu bölümde, daha etkili sinyal çıkarımı sağlamak için kullanılan derin öğrenme tabanlı sinyal optimizasyon yöntemlerinden birkaçı incelenmektedir.

Tang ve arkadaşları, konvolüsyonel sinir ağı (CNN) ve kamera tabanlı uzaktan fotopletismografi (rPPG) yöntemlerini birleştirerek yaptıkları çalışmada, cilt tespiti için bir 2D CNN oluşturulmuş ve özel bir video veritabanı üzerinde eğitmiştir (Tang ve ark., 2018). Yaygın olarak kullanılan diğer üç aşamalı cilt algılama yöntemiyle (yani yüz algılama, yüz izleme ve cilt sınıflandırması) karşılaştırıldığında, burada kullanılan CNN yöntemi, cilt algılamayı tek bir adımda gerçekleştirerek, izleme olasılığını arttırılabileceğine odaklanmıştır. CNN-rPPG yöntemi ile düşük maliyetli kamera kullanarak, herhangi bir yüz veya cilt bölgesinden biyosinyalleri çıkararak kalp atış hızı izlenebilmektedir.

Sabokrou ve arkadaşlarının gerçekleştirdiği çalışmada kalp atış hızı tahmin yöntemlerinin genel performansının, büyük ölçüde analiz bölgesinin belirlenmesi ve temsiline bağlı olduğu belirtilmiştir (Sabokrou ve ark., 2021). Analiz Bölgesini (ROI), yüz hareket ve ifade değişikliklerine karşı daha güçlü ve ten rengindeki farklılıkları dikkate alarak temsil etmeyi amaçlamışlardır. Doğru bir kalp atış hızı hesabı için, derin öğrenme yöntemleri kullanılarak analiz bölgesinin (ROI) iyileştirilmesi hedeflenmiştir. Önerilen yöntem Back-End (BE) ve Front-End (FE) olarak iki kısımdan oluşmaktadır. BE kısmı FE' nin çıktısını giriş olarak alarak kalp atış hızını tahmin

etmektedir. FE bölümünde ise ROI tespiti ve iyileştirilmesi (Şekil 3) yapılp ppg sinyalleri elde edilmektedir. Gerçekçi durumlarda, özellikle yüz hareketinin fazla olduğu veya yüzün bazı kısımlarının görünmediği durumlarda ROI'yi tespit etmek zordur. Bu nedenle doğru ve hızlı nesne algılaması için Receptive Field Block (RFB) derin ağı (Receptive Field Block Net for Accurate and Fast Object Detection) tercih edilmiştir. Tespit edilen ROI nin kalitesini arttırmak için çekişmeli üretici ağ (GAN) tarzı bir modül hazırlanmıştır. Yöntemin gerçekçi koşullarda verimli bir şekilde çalışabileceğini göstermek için HR-D veri setini sunmuşlardır. HR-D ve MAHNOB veri kümeleri üzerindeki sonuçlarla, yöntemlerinin gerçek zamanlı bir yöntem olarak çalışabileceğini ve ortalama kalp atış hızını diğer çalışmalardan daha iyi tahmin ettiklerini belirtmişlerdir.



Şekil 3. Yüksek kaliteli ROI tespiti için kullanılan Deep-HR Mimarisi (Sabokrou ve ark., 2021) .

3.3 Pletismografik Sinyal Çıkarımı

Sinyal çıkarma, uzaktan kalp atış hızı ölçüm hattındaki en önemli kısımdır. Temel amacı, kalp atış hızı tahmini için videolardan rPPG sinyalini çıkarmaktır. Daha iyi kalp atış hızı tahmini için çıkarılan rPPG sinyalinin iyileştirilmesi, tahmin doğruluğunu arttırmaya yönelik önemli bir yaklaşımdır (Cheng ve ark., 2021). Sinyal kestiriminde istenmeyen piksel bölgelerinin hesaba katılması sinyalin doğruluğunu olumsuz yönde etkilemektedir. İstenmeyen bu piksel bölgeleri; deneyin hareketi sonucu ROI bölgesinde kayma, kamera sensör gürültüsü ve görüntü sıkıştırılması olmak üzere üç temel etmenden kaynaklanmaktadır (Li ve ark., 2014).

3.3.1 Renk Yoğunluk Temelli Yaklaşım

Sinyali olumsuz etkileyen durumların, rPPG sinyali hesaplaması yapılmadan önce filtrenmesi ve boyut indirgeme işleminin yapılması gerekmektedir.

Filtreleme, kalp atış hızı frekans bilgisine dayalı olarak ham sinyal işaretlerine dijital filtrelerin uygulandığı süreçtir. Boyut indirgeme uygulamadan önce, iyi bir sinyal-gürültü (SNR) oranı elde etmek için ham sinyaller üzerinde bir filtreleme işlemi gerçekleştirilmelidir. Amaç, sinyal-gürültü oranını artırmak ve böylece tahmini pletismografik sinyalin kalitesini iyileştirmektir (Premkumar & Hemanth, 2022). İşlenmemiş sinyal; öznenin hareketine, aydınlatma değişikliklerine ve diğer faktörlere bağlı olarak istenmeyen gürültü içerebilir (Rouast ve ark., 2018). Hem istenmeyen yüksek hem de düşük frekanslı gürültü, bant geçiren filtreleme kullanılarak ortadan kaldırılabılır. Bu, insan kalp atış hızı için uygun olan frekans bandına ilişkin bir varsayımı gerektirir. 0.7 Hz-4 Hz yaygın bir bant seçimi olup, bu da dakikada 42 ile 240 vuruş (bpm) arasında bir kalp atım hızına karşılık gelir (Bush, 2016). Filtrelenen sinyal, pletismografik sinyal tespiti için doğrudan kullanılabilir (Bousefsaf ve ark., 2013). Poh ve arkadaşlarının yaptığı çalışmaya göre (M. Poh ve ark., 2010) yeşil kanal sinyali diğer kanallara kıyasla daha fazla PPG bilgisi içerir. Bununla birlikte, kırmızı ve mavi kanallar da bazı tamamlayıcı bilgiler taşımaktadır. Yeşil kanal yaklaşımında, bir PPG sinyali elde etmek için filtrelenmiş yeşil kanal bileşeni alınır.

Boyut indirgeme yöntemleri, daha doğru ve sağlam bir PPG bilgi sinyali elde etmek için kullanılmaktadır. rPPG yöntemlerinin ana sınıflandırmaları, ham izlerden pletismografi sinyallerini nasıl çıkardıklarına dayanmaktadır (Premkumar & Hemanth, 2022). Sinyal çıkarma yöntemleri genel olarak üç kategoride sınıflandırılabilir (Hassan ve ark., 2017). 1) Kör kaynak ayırma, 2) Model tabanlı yöntemler, 3) Tasarım tabanlı yöntemler.

Kör kaynak ayrıştırması, karışık sinyaller arasından orijinal sinyalin çıkarımı işlemidir. Bir PPG sinyali, ham sinyallerin ağırlıklı toplamının doğrusal bir kombinasyonu olarak temsil edilen tek boyutlu bir sinyal olarak kabul edilir ve ağırlıkların tahmin etmek zordur (Djeldji et al., 2019). Kör kaynak ayırma (BSS) algoritmalarının amacı, istatistiksel bağımsızlık ve korelasyon nedeniyle istenen PPG sinyalini gürültü ve yapaylıklardan ayırmaktır (Wedekind et al., 2017). Temel bileşen analizi (PCA) ve bağımsız bileşen analizi (ICA), boyutluluk indirgeme için yaygın olarak uygulanan tipik kör kaynak ayrıştırma teknikleridir.

Bu yöntem ile yüksek korelasyonlu değişkenler bir araya getirilir ve çok boyutlu bir veri, aralarında korelasyon içermeyen daha az sayıda değişken ile gösterilmeye çalışılır. PCA, verideki gerekli bilgileri tutarak boyut indirgemeyi sağlamaktadır. Temel bileşenler analizi ile ulaşılmak istenen sonuç, ilgilenilen veri setindeki varyansın en büyük olduğu yani verinin en çok değişim gösterdiği doğrultuyu tespit etmektir. (Aydemir, 2019).

Bağımsız Bileşen Analizi (ICA), çok değişkenli veri kümesinde doğrusal olan, koordinat sistemini bulmaya yarayan istatistiksel bir yöntemdir. Bağımsız bileşen analizi, gürültü giderme, veri madenciliği ve öznitelik çıkarımı ve benzeri problemlerin çözümünde sıklıkla tercih edilmektedir (Aydemir, 2019). Ayrıca kör kaynak ayırma problemlerinde kullanılan yöntemlerden de biridir. Amaç, birden fazla kaynaktan karışmış sinyalleri birbirinden ayırmaktır. Bileşenlerin her biri birbirinden bağımsızdır. Hesaplanan vektörlerin, PCA' da olduğu gibi birbirlerine dik olma şartı yoktur (Şekil 4). PCA' da bazı bileşenler daha yüksek öneme sahip iken, ICA'da tüm bileşenler eşit öneme sahiptir (Aydemir, 2019)



Şekil 4. PCA ve ICA yöntemlerinin karşılaştırılması.

Model tabanlı yaklaşıma ait olan krominans tabanlı (CHROM) algoritmalar, kör kaynak ayrıştırma algoritmasındaki nesne hareketi sorunlarını azaltmaktadır (De Haan & Jeanne, 2013). Bu yaklaşım, aydınlatma rengini normalleştirmek için ayrı ayrı R, G ve B kanallarının işlevlerini araştırmaktadır. Algoritma, ilgili dağınık yansıma bileşenlerine özdeş bir aynasal kesir ekleyerek yansıtıcı yansımanın tüm kanalları etkilediğini varsayar. Böylece, speküler yansıma bileşeni, renk farkı sinyali yani krominans sinyali kullanılarak elimine edilebilir (Premkumar & Hemanth, 2022). Sinyal çıkarma, uzaktan kalp atış hızı ölçüm hattındaki en önemli kısımdır. Temel amacı, kalp atış hızı tahmini için videolardan rPPG sinyalini çıkarmaktır. Daha iyi kalp atış hızı tahmini için çıkarılan rPPG sinyalinin

düzeltilmesi, tahmin doğruluğunu iyileştirmeye yönelik bir yöntemdir.

3.3.2 Derin Öğrenme Tabanlı Yaklaşım

Geleneksel yöntemlerle çıkarılan rPPG sinyali vücut hareketlerinden, aydınlatma değişikliklerinden, kamera sensöründen kaynaklanan çok sayıda gürültüden etkilenmektedir. Bian ve diğerleri tarafından yapılan çalışmada (Bian, 2019), iki katmanlı bir Long Short-Term Memory (LSTM) kullanılarak, gürültülü olan rPPG sinyalinin filtrelenmesi ve gürültüsüz bir rPPG sinyali elde edilmesi için yeni bir regresyon modeli önerilmiştir (Şekil 5). Çok sayıda sentetik gürültü veri eğitiminden sonra, veri odaklı gürültü sinyallerini filtreleyip modelleyebilmesi ve kalp atış hızı tahmininde birçok faydalı sinyali koruyabilmesinden dolayı LSTM tercih edilmiştir. İlk olarak çok sayıda zaman alanı sentetik sinyaliyle LSTM ağı eğitilmektedir. Ardından ağı parametrelerinin hassas ayarını yapmak için, ROI'den çıkarılan sinyal normalleştirilip genel MMSE-HR veri tabanı sinyalinin bir kısmı LSTM ağına alınmaktadır.




Şekil 5. Bian ve ark. tarafından kullanılan mimari (Bian, 2019).

Tsou ve arkadaşları daha iyi bir rPPG sinyali elde etmek için 3 boyutlu CNN'e dayalı bir çerçeve olan Siamese-rPPG ağını kullanmıştır (Tsou ve ark., 2020). Bu ağın arkasındaki fikir, farklı yüz bölgelerinin farklı gürültülerden etkilenebileceği ve kendine ait görünüme sahip olabileceğidir. Ancak, yaklaşık olarak aynı rPPG özelliklerini taşımalarıdır. Bu nedenle öncelikle ROI olarak, daha fazla rPPG bilgisi içeren alın ve yanak bölgeleri seçilmiştir. Daha sonra, bu iki ROI'deki pikselleri çıkarmak için sırasıyla alın ve yanak kısmına ikisi de aynı mimariye sahip 3D CNN uygulanmıştır. Bu iki kısma da ağırlık paylaşım mekanizması uygulanır. Böylece yanak veya alın bölgesi gürültü içerse bile, ağı diğer bölgeyi sinyal çıkarmak için kullanarak genel sağlamlığı iyileştirilebilmektedir. Bu iki kısımdan gelen çıktılar, tahmin edilen rPPG sinyalini üretmek için bir ekleme yapılarak iki tane 1 boyutlu evrişim işlemi ve ortalama bir pooling ile birleştirilmektedir.

rPPG uygulamalarında daha farklı kardiyak özellikleri hesaplamak için stres algılama, duygusal sınıflandırma ve sağlık izleme gibi çalışmalarda yüksek kaliteli dalga formları önemlidir (Song ve ark., 2021). Gürültü bileşeni ve model sınırlaması nedeniyle geleneksel yöntemlerin, dalga biçimlerinin kalitesinin düşük kaldığını belirten Song ve arkadaşları bir koşullu üretken çekişmeli ağı (cGAN) ile rPPG sinyalini elde etmek için PulseGAN (Şekil 6) adlı yeni bir yapı sunmuşlardır (Song ve ark., 2021). Bu yöntemde, ilk olarak, 68 noktali yüz işaretleri tespit edilmekte ve sol ve sağ yanakları kapsayan bu işaret noktalarına göre bir analiz bölgesi (ROI) tespit edilmektedir. Daha sonra, ROI'nin rgb sinyalleri videolardan çıkarılır. Filtreleme işlemlerinden sonra, ham sinyalleri elde etmek için CHROM algoritması kullanılmaktadır. CHROM yöntemi hareket etkilerine karşı hızlı ve kararlı olduğu için seçilmiştir. Hem zaman hem de spektrum alanlarında tanımlanan hata kayıplarına sahip bir üretken çekişmeli ağı çerçevesine dayalı olarak tasarlanan PulseGAN, giriş olarak ham CHROM sinyalini


almakta ve derin üretken model aracılığıyla gelişmiş bir rPPG sinyalini vermektedir. Genel 3 veri setinde test edilen PulseGAN mimarisi geleneksel yöntemleri ve GAN'ı etkin bir şekilde birleştirmektedir. Ayrıca mevcut bazı rPPG yöntemleriyle kolayca entegre edilebilmekte ve rPPG tekniklerinin uygulama kapsamını genişletebilmektedir.



Şekil 6. PulseGAN mimarisi (Song ve ark., 2021).

Chen ve McDuff, 2018'de DeepPhys adlı derin bir evrişimsel ağı kullanarak video tabanlı kalp ve solunum hızı için uçtan uca bir yöntem geliştirmiştir (Chen & McDuff, 2018). Kişinin hareketinden kaynaklanan sorunu çözmek için önerilen bu yöntem, yüzey yansıma modeline dayalı bir hareket temsil algoritması kullanılmaktadır. Sonuç olarak hareketler daha etkili bir şekilde yakalanabilmektedir. Sunulan çalışma, bir hareket ve görünüm modelini birlikte eğiten VGG tarzı bir 2D CNN'dir.


Bugüne kadar yapılan geleneksel çalışmaların çoğunda yalnızca ortalama kalp atış hızının tespit edilmeye çalışıldığı ve bunun atriyal fibrilasyon (AF) tespiti gibi birçok tıbbi uygulamada yeterli olmadığı Yu ve diğerleri tarafından bildirilmiştir. Ayrıca, kalp atış hızı değişkenliği (HRV) analizi için yüzden hassas rPPG sinyallerinin ölçülmesi gerektiği açıklanmıştır (Z. Yu ve ark., 2020). Derin öğrenme yaklaşımlarını kullanarak kalp atışı hızını uzaktan tahmin etmek için yapılan bazı çalışmalar birkaç dezavantaj içermektedir: 1) Manuel özellikler içeren ön işleme veya işleme sonrası adımlar gerektirmektedir. 2) Zorlu tıbbi uygulamalarda kullanımı sınırlayan bireysel nabız tepe bilgisi kaybedilmektedir. 3) rPPG ölçüm problemi için gerekli olan zamansal bağlam özelliklerini dikkate almayan 2 boyutlu uzamsal sinir ağına (2D CNN) dayanmaktadır. İşlenmemiş yüz videolarından tam rPPG sinyallerini yeniden oluşturmak için ilk derin uzamsal-zamansal ağı kullanan, PhysNet olarak tanımlanan bir rPPG ölçüm yöntemi sunulmuştur (Şekil 7). Ağın girişi, RGB kanallı T-frame yüz görüntüleridir. Uzamsal-zamansal özellikleri temsil etmek için 2 ana model bulunmaktadır. Video algılama için yaygın olarak kullanılan ve aynı anda zamansal bağlam içeren 3D CNN tabanlı ve CNN uzamsal özellikleri arasında zamansal bağlamı da yakalayabilen RNN tabanlı olmak üzere 2 ana model bulunmaktadır. PhysNet, OBF ve MAHNOB-HCI veri kümeleri üzerinde test edilmiştir. Sonuçların yalnızca ortalama kalp atış hızı tespitinde değil, aynı zamanda AF tespiti ve duygu tanıma için etkili olduğu açıklanmıştır. HRV özelliklerini ve vuruşlar arası aralık (IBI) bilgilerini ölçmek için üstün performans gösterdiği belirtilmiştir.



Şekil 7. 3D CNN PhysNet Mimarisi (Z. Yu ve ark., 2020).

Yu ve ark. karşılaştıkları bazı sorunları şu şekilde aktarmıştır: Geleneksel yöntemlerle rPPG elde etme

çalışmalarında, analiz bölgesi (ROI) tespiti bilgi kaybına neden olabilecek şekilde keyfi olarak seçilmiştir. Teorik olarak tüm cilt pikselleri, rPPG sinyallerinin elde edilmesine katkıda bulunabilmektedir. Ortalama kalp atış hızı tahmininde, önerilen bazı derin öğrenme yöntemleri ise rPPG ölçümü için gerekli olan zamansal özellikleri içermeyen uzamsal 2D CNN'ye dayanmaktadır. Yüksek oranda sıkıştırılmış videolardan ölçülen rPPG sinyalleri, video sıkıştırma işleminin hem frame içi hem de frameler arası kodlamasından kaynaklanan bilgi kaybından dolayı genellikle gürültülü eğri şekli ve hatalı pik konumuyla karşılaşmaktadırlar. Farklı bit hızlarına sahip sıkıştırılmış videolar kullanıldığında, rPPG ölçümünün performansının çeşitli düzeylerde düştüğüne dair yapılmış birkaç çalışma bulunmaktadır. Bu belirtilen problem ve eksikliklerin üstesinden gelmek için iki aşamalı, uçtan uca derin öğrenmeye dayalı bir yöntem olarak STVEN ve rPPGNet mimarisi (Şekil 8) tasarlanmıştır (Z. Yu ve ark., 2019). Kullanılan metotta, STVEN ağı ilk önce videoları iyileştirmektedir. Ardından rPPGNet'in, kalp atış hızı (HR) ve kalp atış hızı değişkenliği (HRV) özellik ölçümü için rPPG sinyallerini elde etmesi amaçlanmaktadır. Yöntem, yüksek oranda sıkıştırılmış videolardan rPPG sinyallerinin elde edilmesi için OBF ve MAHNOB-HCI veri setlerinde test edilmiştir.



Şekil 8. STVEN ve rPPGNet mimarisi (Z. Yu ve ark., 2019).

3.4 Kalp Atış Hızı Tahmini

3.4.1 Renk Yoğunluk Temelli Yaklaşım


Pletismografik sinyalin yaklaşık bir $p(t)$ sinyali verildiğinde, kalp atış hızı, frekans analizi kullanılarak tespit edilebilir. Bu amaçla, belirgin bir periyodiklik içeren bu sinyal, ayrık bir Fourier dönüşümü kullanılarak frekans alanına dönüştürülebilir. Çoğu yazar tarafından tercih edilen algoritma Fast Fourier Transform (FFT) dur. Ayrıca DCT (Irani ve ark., 2014), Welch yöntemi (Li ve ark., 2014) ve kısa süreli Fourier dönüşümünü (STFT) kullanılmaktadır. Frekans alanında, en yüksek spektral güce sahip indekse karşılık gelen frekans, kalp atış hızı frekansı için bir tahmin olarak seçilmektedir.

Sinyalin zirve noktalarını kullanarak, vuruşlar arası aralıklardan kalp atış hızı değişkenliği gibi daha fazla bilgi çıkarmak mümkündür. Pik tespiti yapıp sinyali iyileştirmek için, sinyal genellikle bir kübik spline fonksiyonu (McDuff ve ark., 2014b, 2014a; M. Z. Poh ve ark., 2011) kullanılarak enterpolasyon yapılır. Pikler, sinyal içindeki maksimumlar olduklarından hareketli bir pencere kullanılarak kolayca tanımlanabilmektedir.

3.4.2 Derin Öğrenme Tabanlı Yaklaşım


Geleneksel yöntemlerle yapılan önceki çalışmaların çoğunda kişilerin hareketsiz kalmaları istenmektedir. Bu nedenle yüz videolarının çoğu doğal yüz ifadeleri ve aydınlatma değişiklikleri içermemektedir (Yang ve ark., 2018). Ancak gerçek hayatta hareketler ve aydınlatma değişiklikleri kaçınılmazdır. Gürültülü girişimlerin üstesinden gelmek, modelin periyodik kalp atış hızı özelliğini otomatik olarak öğrenmesini sağlamak için, zaman serilerinin, karşılık gelen spektruma dönüştürüldüğü ve ardından CNN aracılığıyla regresyon yapıldığı sağlam ve

verimli bir yaklaşım Yang ve arkadaşları tarafından sunulmuştur (Yang ve ark., 2018). Önerilen yöntem (Şekil 9) dört adımdan oluşmaktadır. İlk başta, analiz bölgesi (ROI) tanımlanır ve yoğunluk değişiklikleri, ROI üzerinden ortalama yoğunluk değeri hesaplanarak kaydedilmektedir. Daha sonra farklı ön işleme yaklaşımları kullanılmaktadır. Her bir zaman alanı sinyali ve ilgili frekans alanı bileşeni bir spektrum görüntüsünde birleştirilerek farklı ön işleme yöntemleri arasındaki performansı karşılaştırılmaktadır. Son olarak, kalp atış hızı sinyali doğrudan spektrum görüntülerinden tahmin etmek için ImageNet veri seti ile önceden eğitilmiş ResNet18 (He ve ark., 2016) tabanlı bir kalp atış hızı tahmincisi kullanılmaktadır. Yöntemin, ışık değişimi ve baş hareketlerinin neden olduğu girişimin üstesinden gelebildiği ve önceki çalışmaların çoğuna kıyasla üstün performans elde ettiği belirtilmiştir.



Şekil 9. Yang ve diğerleri tarafından kullanılan mimari (Yang ve ark., 2018).

Huang ve arkadaşları tarafından, görsel nabız hızı tahmini veya rPPG elde etme için derin öğrenme teknolojilerine dayanan öncü yaklaşımların bazı eksiklerinin bulunduğu belirtilmiştir: 1) Videolardan veri işleme süreleri uzundur. 2) Tek aşamalı veri hattına sahiptirler. 3) Video kareleri arasında gizlenen geçici bilgiler tam olarak dikkate alınmamaktadır. Bu gibi sınırlılıkların üstesinden gelmek için PRnet (Şekil 10) adını verdikleri ağı tasarlamışlardır (Huang ve ark., 2021). Önerilen mimari, sabit videolardan kalp atış hızı çıkarımı yapmak için tek aşamalı bir derin öğrenme modelidir. PRnet; 3 boyutlu CNN (3D CNN), LSTM ve FC kısımlarından oluşmaktadır. Tanımlanan ROI'den, gizli uzamsal ve zamansal özellikleri çıkarmak için 3D CNN kullanılır. Daha sonra, çıktı özellik haritası, global zamansal özelliklerin elde edilmesi için bir LSTM çıkarıcıya beslenmektedir. Son olarak, çıkarılan özellik haritasından kalp atış hızını tahmin etmek için tam bağlantılı bir katman uygulanmaktadır. PRnet ağı güç spektral yoğunluğu (PSD) ve Hızlı Fourier Dönüşümü (FFT) gibi hiçbir ek geleneksel algoritmanın uygulanmadığı ortak bir optimizasyon mimarisidir. Bu nedenle, önerilen mimari, veri işleme gecikmesi açısından önemli bir avantaj sunmaktadır. Darbe hızını, diğer geleneksel ve derin öğrenme yöntemlerinin büyük çoğunluğundan daha kısa bir pencere boyutuyla (2 sn, 60 kare video) tahmin edebilmektedir.




Şekil 10. PRNet Mimarisi (Huang ve ark., 2021).

Öğrenmeye dayalı bir model kullanan bir yüz video dizisinden uzaktan kalp atış hızı tahmini, eğitim verilerinin eksikliği, hareket, ortam ışığı vb. nedenlerle zor olabilmektedir. Bu zorlukları ele alan SynRhythm mimarisi (Niu ve ark., 2018), derin kalp atış hızı regresyon modelini önceden eğitmek için ImageNet ve büyük miktarda sentetik ritim uzamsal-zamansal haritaları kullanılmaktadır. Yüz video dizilerinden kalp atış hızı


sinyallerinin transfer öğrenimi yoluyla genelden özele uzamsal-zamansal temsillerinde kalp atış hızını doğrudan tahmin etmeyi amaçlamaktadır.

Yüz videolarından kalp atış hızı tespitinde baş hareketi, aydınlatma ve sensör çeşitliliğindeki farklılıklar karşılaşılan bazı problemlerdir. Niu ve diğerleri tarafından bu gibi problemlerin üstesinden gelmesi amacıyla daha stabil bir kalp atış hızı tespiti için derin öğrenmeye dayalı RhythmNet mimarisi (Şekil 11) tasarlanmıştır (Niu ve ark., 2020). Bir giriş video dizisi verilip birden çok kısa video klibe bölünmekte ve yüz hizalaması için her karede yüz ve yer işareti tespiti gerçekleştirilmektedir. Ardından, kalp atış hızı sinyallerini temsil etmek için video klip başına hizalanmış yüz görüntülerinden uzamsal-zamansal haritalar (spatial-temporal maps) üretilmektedir. Daha sonra kalp atış hızını uzamsal-zamansal haritalardan tahmin etmek için CNN'den çıkarılan özellikler, ölçümler arasındaki zamansal ilişkiyi modellemek için bir hücre, bir sıfırlama geçidi ve bir güncelleme geçidinden oluşan tek katmanlı bir GRU (Gated Recurrent Unit) yapısına beslenmektedir. Son olarak, giriş video dizisi için tahmin edilen kalp atış hızı, tek tek video kliplerden tahmin edilen tüm kalp atış hızlarının ortalaması olarak hesaplanmaktadır.



Şekil 11. RhythmNet Mimarisi (Niu ve ark., 2020).

HR-CNN adı verilen uçtan uca derin öğrenme yaklaşımı, bir dizi yüz görüntüsünden kalp atış hızını tahmin etmek amacıyla Şpetlik ve arkadaşları tarafından sunulmuştur. HR-CNN mimarisi (Şekil 12), bir çıkarıcı ve kalp atış hızı tahminicisi içeren, iki aşamalı evrimsel sinir ağından (CNN) oluşmaktadır (Şpetlik ve ark., 2018). Çıkarıcı bir dizi görüntü üzerinde çalıştırılarak, bir NrPPG sinyali olan bir dizi skaler çıktı üretilmektedir. NrPPG sinyali, kalp atış hızını veren tahminciye beslenmektedir. İlk olarak, sinyal-gürültü oranını (SNR) en üst düzeye çıkarmak için eğitilmektedir. Ardından, tahmin edici, gerçek ve tahmin edilen kalp atış hızının ortalama mutlak hatasını (MAE) en aza indirmek için eğitilmektedir. Yöntem, yoğun hareket kaynaklı gürültülere ve ışık girişimine karşı değerlendirmek için kullanılmıştır.



Şekil 12. HR-CNN Mimarisi (Şpetlik ve ark., 2018).

5. Sonuç

Bu çalışmada, videolardan kalp atış hızı tespiti üzerine literatürdeki mevcut yöntemlerin kapsamlı bir incelemesi gerçekleştirilmiştir. Kalp atış hızı kestirim süreci; yüz analiz bölgesi (ROI) tespiti, pletismografik sinyal çıkarımı ve kalp atış

hızı tahmini olarak 3 ana aşamada incelenmiş ve her bir aşama için önerilen yaklaşımlar renk yoğunluk temelli ve derin öğrenme tabanlı olmak üzere ayrı ayrı ele alınmıştır. Özellikle derin öğrenme yöntemleri ile kalp atışı hızı kestirimi sürecindeki aşamaların nasıl iyileştirilebileceği ve nasıl daha yüksek doğrulukta kalp atışı hızı tespiti yapılabileceği analiz edilmiştir. Bununla birlikte derin öğrenme tabanlı yöntemler için karşılaşılan en büyük zorluklardan biri çok fazla eğitim verisi gerektirmesidir. Gerçek zamanlı ve koyu ten rengine sahip kişilerin videolarından fizyolojik sinyallerin tespitindeki problemler ele alınması gereken diğer önemli zorluktur. Çeşitli veri kümeleriyle, farklı yöntemlerin analiz edilmesi ve karşılaştırılması yeni model ve mimarilerin oluşturulmasında katkı sağlayacaktır.

Kaynakça

- Aydemir, B. (2019). *Egzersiz esnasında toplanan fotopletizmografi sinyallerinden kalp atım hızı ve ventilasyon hızı değişkenlerinin ayrıştırılması* [MARMARA ÜNİVERSİTESİ].
<https://acikbilim.yok.gov.tr/handle/20.500.12812/282457>
- Bian, M. (2019). Pattern Recognition and Computer Vision. In *Fundamentals of Uncertainty Calculi with Applications to Fuzzy Inference*. https://doi.org/10.1007/978-94-015-8449-4_9
- Bousefsaf, F., Maaoui, C., & Pruski, A. (2013). Continuous wavelet filtering on webcam photoplethysmographic signals to remotely assess the instantaneous heart rate. *Biomedical Signal Processing and Control*, 8(6), 568–574. <https://doi.org/10.1016/j.bspc.2013.05.010>
- Bush, I. (2016). *Measuring Heart Rate from Video*. https://web.stanford.edu/class/cs231a/prev_projects_2016/finalReport.pdf
- Chen, W., & McDuff, D. (2018). DeepPhys: Video-Based Physiological Measurement Using Convolutional Attention Networks. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11206 LNCS, 356–373. https://doi.org/10.1007/978-3-030-01216-8_22
- Cheng, C. H., Wong, K. L., Chin, J. W., Chan, T. T., & So, R. H. Y. (2021). Deep learning methods for remote heart rate measurement: A review and future research agenda. In *Sensors* (Vol. 21, Issue 18). MDPI. <https://doi.org/10.3390/s21186296>
- De Haan, G., & Jeanne, V. (2013). Robust pulse rate from chrominance-based rPPG. *IEEE Transactions on Biomedical Engineering*, 60(10), 2878–2886. <https://doi.org/10.1109/TBME.2013.2266196>
- Deng, Y., & Kumar, A. (2020). *Standoff heart rate estimation from video – a review*. 6. <https://doi.org/10.1117/12.2560683>
- Djeldjli, D., Bousefsaf, F., Maaoui, C., & Bereksi-Reguig, F. (2019). Imaging Photoplethysmography: Signal Waveform Analysis. *Proceedings of the 2019 10th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications, IDAACS 2019*, 2, 830–834. <https://doi.org/10.1109/IDAACS.2019.8924239>
- Elgendi, M. (2012). On the Analysis of Fingertip Photoplethysmogram Signals. *Current Cardiology Reviews*, 8(1), 14–25. <https://doi.org/10.2174/157340312801215782>
- ElMaghraby, A., Abdalla, M., Enany, O., & Y. El Nahas, M. (2014). Detect and Analyze Face Parts Information using

- Viola- Jones and Geometric Approaches. *International Journal of Computer Applications*, 101(3), 23–28. <https://doi.org/10.5120/17667-8494>
- Hassan, M. A., Malik, A. S., Fofi, D., Saad, N., Karasfi, B., Ali, Y. S., & Meriaudeau, F. (2017). Heart rate estimation using facial video: A review. In *Biomedical Signal Processing and Control* (Vol. 38, pp. 346–360). Elsevier Ltd. <https://doi.org/10.1016/j.bspc.2017.07.004>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016-Decem, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Huang, B., Lin, C.-L., Chen, W., Juang, C.-F., & Wu, X. (2021). A novel one-stage framework for visual pulse rate estimation using deep neural networks. *Biomedical Signal Processing and Control*, 66(June 2020), 102387. <https://doi.org/10.1016/j.bspc.2020.102387>
- Irani, R., Nasrollahi, K., & Moeslund, T. B. (2014). Improved pulse detection from head motions using DCT. *VISAPP 2014 - Proceedings of the 9th International Conference on Computer Vision Theory and Applications*, 3, 118–124. <https://doi.org/10.5220/0004669001180124>
- Kazemi, V., & Sullivan, J. (2014). One millisecond face alignment with an ensemble of regression trees. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1867–1874. <https://doi.org/10.1109/CVPR.2014.241>
- Kwon, S., Kim, J., Lee, D., & Park, K. (2015). ROI analysis for remote photoplethysmography on facial video. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS, 2015-Novem*, 4938–4941. <https://doi.org/10.1109/EMBC.2015.7319499>
- Li, X., Chen, J., Zhao, G., & Pietikäinen, M. (2014). Remote heart rate measurement from face videos under realistic situations. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 4264–4271. <https://doi.org/10.1109/CVPR.2014.543>
- McDuff, D., Gontarek, S., & Picard, R. W. (2014a). Improvements in remote cardiopulmonary measurement using a five band digital camera. *IEEE Transactions on Biomedical Engineering*, 61(10), 2593–2601. <https://doi.org/10.1109/TBME.2014.2323695>
- McDuff, D., Gontarek, S., & Picard, R. W. (2014b). Remote detection of photoplethysmographic systolic and diastolic peaks using a digital camera. *IEEE Transactions on Biomedical Engineering*, 61(12), 2948–2954. <https://doi.org/10.1109/TBME.2014.2340991>
- Meinzer, H. P., Deserno, T. M., Handels, H., & Tolxdorff, T. (2013). ROI Selection for Remote Photoplethysmography. *Informatik Aktuell*, 99–103. <https://doi.org/10.1007/978-3-642-36480-8>
- Niu, X., Han, H., Shan, S., & Chen, X. (2018). SynRhythm: Learning a Deep Heart Rate Estimator from General to Specific. *Proceedings - International Conference on Pattern Recognition*, 2018-Augus(i), 3580–3585. <https://doi.org/10.1109/ICPR.2018.8546321>
- Niu, X., Shan, S., Han, H., & Chen, X. (2020). RhythmNet: End-to-End Heart Rate Estimation from Face via Spatial-Temporal Representation. *IEEE Transactions on Image Processing*, 29, 2409–2423. <https://doi.org/10.1109/TIP.2019.2947204>
- Pagano, T. P., Santos, V. R., Bonfim, Y. da S., Paranhos, J. V. D., Ortega, L. L., Sá, P. H. M., Nascimento, L. F. S., Winkler, I., & Nascimento, E. G. S. (2022). Machine Learning Models and Videos of Facial Regions for Estimating Heart Rate: A Review on Patents, Datasets, and Literature. *Electronics (Switzerland)*, 11(9). <https://doi.org/10.3390/electronics11091473>
- Poh, M., McDuff, D. J., & Picard, R. W. (2010). Noncontact automated cardiac pulse measurements using video imaging and blind.pdf. *Medical Optics and Biotechnology*, 18(10), 795–805.
- Poh, M. Z., McDuff, D. J., & Picard, R. W. (2011). Advancements in noncontact, multiparameter physiological measurements using a webcam. *IEEE Transactions on Biomedical Engineering*, 58(1), 7–11. <https://doi.org/10.1109/TBME.2010.2086456>
- Premkumar, S., & Hemanth, D. J. (2022). Intelligent Remote Photoplethysmography-Based Methods for Heart Rate Estimation from Face Videos: A Survey. In *Informatics* (Vol. 9, Issue 3). MDPI. <https://doi.org/10.3390/informatics9030057>
- Rautaray, S. S., & Agrawal, A. (2012). *R Eal T Ime H and G Esture R Ecognition*. 3(1), 21–31.
- Rouast, P. V., Adam, M. T. P., Chiong, R., Cornforth, D., & Lux, E. (2018). Remote heart rate measurement using low-cost RGB face video: a technical literature review. In *Frontiers of Computer Science* (Vol. 12, Issue 5, pp. 858–872). Higher Education Press. <https://doi.org/10.1007/s11704-016-6243-6>
- Sabokrou, M., Pourreza, M., Li, X., Fathy, M., & Zhao, G. (2021). Deep-HR: Fast heart rate estimation from face video under realistic conditions. *Expert Systems with Applications*, 186. <https://doi.org/10.1016/j.eswa.2021.115596>
- Shao, D., Liu, C., & Tsow, F. (2021). Noncontact Physiological Measurement Using a Camera: A Technical Review and Future Directions. *ACS Sensors*, 6(2), 321–334. <https://doi.org/10.1021/acssensors.0c02042>
- Sinhal, R., Singh, K., & Raghuvanshi, M. M. (2020). An Overview of Remote Photoplethysmography Methods for Vital Sign Monitoring. *Advances in Intelligent Systems and Computing*, 992, 21–31. https://doi.org/10.1007/978-981-13-8798-2_3
- Song, R., Chen, H., Cheng, J., Li, C., Liu, Y., & Chen, X. (2021). PulseGAN: Learning to Generate Realistic Pulse Waveforms in Remote Photoplethysmography. *IEEE Journal of Biomedical and Health Informatics*, 25(5), 1373–1384. <https://doi.org/10.1109/JBHI.2021.3051176>
- Spetlik, R., Franc, V., Cech, J., & Matas, J. (2018). Visual heart rate estimation with convolutional neural network. *British Machine Vision Conference 2018, BMVC 2018*, 1–12.
- Sun, Y., & Thakor, N. (2016). Photoplethysmography Revisited: From Contact to Noncontact, from Point to Imaging. *IEEE Transactions on Biomedical Engineering*, 63(3), 463–477. <https://doi.org/10.1109/TBME.2015.2476337>
- Swinehart, D. F. (1962). The Beer-Lambert law. *Journal of Chemical Education*, 39(7), 333–335. <https://doi.org/10.1021/ed039p333>
- Tamura, T., Maeda, Y., Sekine, M., & Yoshida, M. (2014). Wearable photoplethysmographic sensors—past and present. *Electronics*, 3(2), 282–302. <https://doi.org/10.3390/electronics3020282>
- Tang, C., Lu, J., & Liu, J. (2018). Non-contact heart rate monitoring by combining convolutional neural network skin detection and remote photoplethysmography via a low-cost

- camera. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, 2018-June, 1390–1396. <https://doi.org/10.1109/CVPRW.2018.00178>
- Tsou, Y. Y., Lee, Y. A., Hsu, C. T., & Chang, S. H. (2020). Siamese-rPPG network: Remote photoplethysmography signal estimation from face videos. *Proceedings of the ACM Symposium on Applied Computing*, 2066–2073. <https://doi.org/10.1145/3341105.3373905>
- Verkruyse, W., Svaasand, L. O., & Nelson, J. S. (2008). Remote plethysmographic imaging using ambient light. *Optics Express*, 16(26), 21434. <https://doi.org/10.1364/oe.16.021434>
- Wang, W. (2017). *Robust And Automatic Remote Photoplethysmography* (Vol. 1, Issue 2017). https://pure.tue.nl/ws/files/78340965/20171023_Wang.pdf%0Ahttps://research.tue.nl/en/publications/robust-and-automatic-remote-photoplethysmography%0Ahttps://pure.tue.nl/ws/portalfiles/portal/78340965/20171023_Wang.pdf
- Wedekind, D., Trumpp, A., Gaetjen, F., Rasche, S., Matschke, K., Malberg, H., & Zaunseder, S. (2017). Assessment of blind source separation techniques for video-based cardiac pulse extraction. *Journal of Biomedical Optics*, 22(3), 035002. <https://doi.org/10.1117/1.jbo.22.3.035002>
- YAMAN, A. U. (2018). *Yüz tanıma sistemlerinin yanıtılmasına karşı bir yöntem: yüz videolarında nabız tespiti ile canlılık doğrulaması* [Ankara Üniversitesi]. <https://tez.yok.gov.tr/UlusalTezMerkezi/tezDetay.jsp?id=UwWffTuiMVwjS85blanc6Q&no=LlzkDJAuYHVHoM9tysjGIA>
- Yang, W., Li, X., & Zhang, B. (2018). Heart Rate Estimation from Facial Videos Based on Convolutional Neural Network. *Proceedings of 2018 6th IEEE International Conference on Network Infrastructure and Digital Content, IC-NIDC 2018*, 45–49. <https://doi.org/10.1109/ICNIDC.2018.8525602>
- Yu, Z., Li, X., & Zhao, G. (2020). Remote photoplethysmograph signal measurement from facial videos using spatio-temporal networks. *30th British Machine Vision Conference 2019, BMVC 2019*.
- Yu, Z., Peng, W., Li, X., Hong, X., & Zhao, G. (2019). Remote heart rate measurement from highly compressed facial videos: An end-to-end deep learning solution with video enhancement. *Proceedings of the IEEE International Conference on Computer Vision, 2019-October*, 151–160. <https://doi.org/10.1109/ICCV.2019.00024>
- Zhang, K., Zhang, Z., Li, Z., & Qiao, Y. (2016). Joint Face Detection and Alignment Using Multitask Cascaded Convolutional Networks. *IEEE Signal Processing Letters*, 23(10), 1499–1503. <https://doi.org/10.1109/LSP.2016.2603342>