Sürekli Dalgacık Dönüşümü ile EKG Sinyallerinden Duygu Tespiti

Emotion Detection from ECG Signals with Continuous Wavelet Transform

Tuğrul ARTUĞ
Teknik Bilimler Meslek Yüksekokulu
Elektrik Programı
İstanbul Üniversitesi-Cerrahpaşa
İstanbul, Türkiye
tugrul.artug@iuc.edu.tr

Abdulhamit SUBASI
Information Sciences and Technology Department
College of Emergency Preparedness, Homeland Security & Cybersecurity
State University of New York at Albany
Albany, NY,12222, USA
asubasi@albany.edu

***Özetçe*—Biyomedikal sinyaller vasıtasıyla bireyin o an içinde bulunduğu duygu durumunu bilebilmek erken müdahale için bir fırsat verebilir. EKG sinyali en bilinen biyo-sinyallerden biridir. Bu çalışmada 12 bireye izletilen 3 setlik 7 farklı video sonucu kaydedilen EKG sinyalleri kullanılmıştır. Sürekli dalgacık dönüşümü ile EKG sinyallerinden 2 boyutlu görüntüler elde edilmiştir. Oluşan veri seti 7 farklı duyguyu barındırmaktadır. Bu veri seti transfer öğrenme yöntemi vasıtasıyla önceden eğitilmiş evrişimsel sinir ağları üzerinde sınıflandırılmıştır. Sınıflandırma başarısının artırılması hedeflenmiş olup, elde edilen en yüksek başarıya ResNet50 ağı ile %81,63 olarak erişilmiştir.**

Anahtar Kelimeler — duygu tespiti; elektrokardiyogram; sürekli dalgacık dönüşümü; evrişimsel sinir ağları; transfer öğrenme; işaret işleme.

***Abstract*—Knowing the individual's current emotional state through biomedical signals may give an opportunity for early intervention. ECG signal is one of the most well-known bio-signals. In this study, ECG signals were used which were recorded as a result of 3 sets of 7 different videos watched by 12 individuals. Two dimension images were obtained from ECG signals by using continuous wavelet transform. The resulting dataset includes 7 different emotions. This dataset was classified on pre-trained convolutional neural networks via transfer learning method. It is aimed to increase the classification performance and the highest value was achieved as 81.63% with the ResNet50 network.**

Keywords — emotion detection; electrocardiogram; continuous wavelet transform; convolutional neural networks; transfer learning; signal processing.

I. GİRİŞ

Biyomedikal sinyaller üzerinden yapılan sayısız çalışmalardan biri de, bireyin o anki duygusunun tespitidir. Bunun için çeşitli sinyaller kullanılmıştır. Biyo-sinyallere örnek olarak elektrookülogram (EOG), elektroensefalogram (EEG), ve elektrokardiyogram (EKG) verilebilir. Bunların dışında konuşma, görüntü veya video üzerinden işaret işleme yöntemleriyle yapılan çalışmalar da mevcuttur [1, 2, 3].

Cai ve arkadaşlarının yapmış olduğu çalışma [4] EOG ve EEG sinyallerini, karar düzeyi füzyonu (DLF) ve öznitelik düzeyi füzyonu (FLF) vasıtasıyla birleştirmeyi önermiştir. Bu yolla duygu tespiti başarısını arttırmayı hedeflemişlerdir. Veriyi 6 saniyelik pencerelere bölerek uyarılma açısından %95,62 ve değerlik açısından %95,58 başarı elde etmişlerdir.

2023 yılında Kar ve diğerleri tarafından yapılan çalışma [5], EEG sinyalleri ile iki sınıflı bir duygu tespiti görevini gerçekleştirebilmek adına eğiticili ve eğiticisiz yöntemleri karşılaştırmıştır. Eğiticili yöntem ile ortalama %62,76 başarı elde ettiklerini rapor etmişlerdir.

Dar ve arkadaşları [6] EKG ve galvanik deri tepkisi (GDT) sinyallerini kullanarak duygu tespiti çalışması yapmışlardır. Kendi oluşturdukları veri setiyle [7], önerdikleri metodu kullanarak 8 sınıftan oluşan setini %66,64 başarı ile sınıflandırmışlardır.

Sağlık üzerine yapay zekâ uygulamalarını konu alan ve 2024 yılında çıkmış olan kitabın bir bölümünde [8] EKG sinyalleri ile duygu tanımlanması konusuna değinilmiştir. Tokmak ve diğerleri, çalışmada veri alma, segmentasyon, gürültü giderme, öznitelik çıkarma, boyut azaltma ve sınıflandırma adımlarını ele almışlardır. Ayrıca VGG19, INCEPTIONV3 ve MobileNet gibi çeşitli ağların kodlarını paylaşmışlardır.

Her ne kadar EEG ile yapılan çalışmalar daha fazla olsa da ihtiyaç duyulan ekipman maliyeti ve veri almanın zorluğu aşikardır. EKG sinyalleri ile çalışmak, yaygınlaşan portatif algılayıcılar sayesinde daha kolay olmaktadır. Hastaların duygularının düzenlenmesi özellikle stres temelli tetiklenebilecek rahatsızlıkları önlemek için elzemdir. Sağlık durumunun takibini yapabilecek ve duygu durumunu gözlemleyebilecek bir karar destek sistemi, bireyi istenmeyen

979-8-3315-2981-9/24/$31.00 ©2024 IEEE

bir duygu durumuna girdiği zaman sakinleşmesi konusunda uyarabilir.

Bu çalışmada EKG sinyallerini kullanarak, önceden eğitilmiş evrişimsel sinir ağları üzerinde transfer öğrenme vasıtasıyla duygu sınıflandırması konusunda başarının arttırılması amaçlanmıştır. Metot kısmında veriye yapılan önişlemlerden bahsedilecek ve sonuç kısmında derin öğrenme ağlarının başarım sonuçları sunulacaktır. Çalışma tartışma kısmında sonuçların yorumlanmasıyla son bulacaktır.

II. VERİ SETİ

Veri seti açık erişimli olarak paylaşılmış olup EKG ve GDT sinyallerini içermektedir [7]. Yirmi beş katılımcıdan EKG sinyali kaydedilirken, 12 katılımcıdan da GDT sinyalleri kaydedilmiştir. Katılımcılara her oturumda 7 adet duygu uyandıracak 7 farklı video seyrettirilmiş ve anılan sinyaller kaydedilmiştir. Toplam 3 oturum boyunca kayıt yapılmıştır. Her oturumda kullanılan videolar birbirinden farklı olsa da uyandırdığı 7 duygu her oturum için aynıdır. Veriler 5000 örnekten oluşmuş olup, 39 saniye boyunca 128 Hz örnekleme frekansı ile kaydedilmiştir. Her videonun ilk 5 saniyesi boyunca uyarı verilmemiştir. Videolarda uyandırması beklenen duygular; mutluluk, üzüntü, korku, öfke, iğrenme, şaşırma ve nötrdür (duygusuz).

Bu çalışma için veri setinden sadece EKG sinyalleri kullanılmıştır. Çalışmanın veri seti oluşturulurken katılımcıların her oturuma katılıp, tüm videoları izlemiş olması koşulu belirlenmiştir. Böylece bu koşulu sağlayan 12 katılımcıya ait veriler çalışma için seçilmiştir.

III. YÖNTEM

Veriler ağa uygulanmadan önce bazı önişlemlerden geçirilmelidir. Toplam 12 katılımcıya 3 setten 7 video izletildiğinden, veri seti toplamda 252 EKG kaydı içermektedir. Her bir kaydın 128 Hz örnekleme frekansı ile sürekli dalgacık dönüşümü (CWT) hesaplanarak, kayıt başına 94 x 5000'lik 2 boyutlu bir görüntü elde edilmektedir. 5000 örnek 39 saniyeyi temsil etmektedir. Bir sinyalin sürekli dalgacık dönüşümünün hesaplanması için kullanılan dalgacıklardan biri de analitik Morse dalgacığıdır [9] ve ifadesi aşağıda verilmiştir:

$$\psi_{\beta,\gamma}(t) = \frac{1}{2\pi}\int_{-\infty}^{\infty} \Psi_{\beta,\gamma}(\omega) e^{j\omega t}.d\omega \qquad (1)$$

Dalgacık frekans uzayındadır ve $\beta \geq 0$ ve $\gamma > 0$'dır. Sürekli dalgacık dönüşümü ise aşağıdaki denklem [9] ile gösterilmiştir:

$$W_{\beta,\gamma}(\tau,s) \equiv \int_{-\infty}^{\infty} \frac{1}{s}.{\psi^*}_{\beta,\gamma}\left(\frac{t-\tau}{s}\right) x(t).dt = \frac{1}{2\pi}\int_{-\infty}^{\infty} e^{j\omega\tau}{\Psi^*}_{\beta,\gamma}(s\omega)X(\omega)d\omega \qquad (2)$$

Eşitliğin sol tarafı zaman uzayındaki dalgacık dönüşümünü ifade ederken, sağ tarafı frekans uzayındaki dalgacık dönüşümünü ifade eder. Denklemde bulunan s (ölçek) parametresi zamandaki dalgacığın genişlemesini veya daralmasını belirler.

Dalgacık dönüşümü sonrası elde edilen kayıtlardan, uyarı verilmeyen ilk 5 saniyelik kısım atılır ve 34 saniyelik (4360 örnek) kayıt elde edilir. Dönüşüm sonucu elde edilen görüntünün pikselleri karmaşık değerlerden oluştuğundan, önce her bir pikselin mutlak değeri alınır, ardından da işaretsiz tamsayı değer aralığı olan 0-255 arasına normalize edilir. Daha sonra elde edilen görüntüler, kullanılacak olan ağın giriş katmanından kabul ettiği 224 x 224 piksel değerine ölçeklenir. Son olarak resimler 'png' formatına dönüştürülüp kaydedilir ve sınıfına göre ayrı ayrı klasörlerde muhafaza edilir.

Orijinal veri setinde her sınıftan 36 veri bulunmaktadır. Veri artırımı yapmak için tüm verilerin 'y' eksenine göre ayna görüntüsü alınarak veri setine eklenmiştir. Böylece sonuç olarak her sınıftan 72 veri ve toplamda 504 kayıt bulunmaktadır.

Veri seti densenet201 [10], googlenet [11], mobilenetv2 [12], resnet [13] ve vgg16 [14] gibi önceden eğitilmiş olan evrişimsel sinir ağları üzerinde transfer öğrenme yöntemiyle sınıflandırılacaktır. Bu çok katmanlı ağlar, hâlihazırda eğitilmiş halleriyle nesne ve hayvan gibi çeşitli türlerden oluşan 1000 farklı kategoriyi sınıflayabilmektedir. Mevcut problemi sınıflayabilmesi için ise girişteki katmanlarının dondurulup, probleme göre çıkış tarafındaki bir veya daha fazla katmanının eğitilmesi gerekmektedir. Kullanılan ağların bilgisi Tablo 1'de sunulmuştur.

TABLO I. ÖNCEDEN EĞİTİLMİŞ EVRİŞİMSEL SİNİR AĞLARININ ÖZELLİKLERİ

#	Ağ Adı	Katman Sayısı	Parametre Adedi (Milyon)
1	DenseNet	201	20
2	GoogleNet	22	7
3	MobileNet	53	3,5
4	ResNet18	18	11,7
5	ResNet50	50	25,6
6	ResNet101	101	44,6
7	vgg16	16	138

Sınıflanacak veri seti %60 eğitim, %20 test ve %20 validasyon olmak üzere rastgele ayrılmıştır. Ağların çıkış tarafından son iki konvolüsyon katmanı eğitilecektir. Standardizasyon sağlamak adına tüm ağlarda aynı ayarlar tercih edilmiştir ve aşağıda verilmiştir:

- Optimizasyon algoritması: adam
- Öğrenme oranı: 10^{-4}
- İterasyon sayısı: 200
- Validasyon frekansı: 5

Ağ eğitilirken, eğitim ve validasyon setlerinin doğrulukları her 5 iterasyonda bir karşılaştırılarak başarı arttırılmaya çalışılmaktadır. Ağ 200 iterasyon eğitilse de, son iterasyonda elde edilen ağırlıkları almak yerine, doğruluk parametresine göre en iyi validasyon değerinin elde edildiği ağırlıklar ağdan çekilmektedir.

Her ağ için doğruluk parametresi cinsinden eğitim başarısı, test başarısı ve validasyon başarısı hesaplanmaktadır. Ayrıca

kesinlik, duyarlılık, F1 skoru ve karar vericinin etkinliği (ROC) eğrisi altında kalan alan her bir sınıf için hesaplanmaktadır.

Son olarak ROC eğrileri, eğitim, test ve validasyon başarısı için çizdirilir. Karşıtlık matrisleri ile eğitim süreci grafikleri kullanıcıya gösterilir.

IV. SONUÇLAR

Çalışma kapasımda kullanılan bilgisayar 24 çekirdekli 5,8 GHz hızında çalışan işlemci, 32 GB 4800 MHz DDR5 bellek ve 16 GB Nvidia RTX A4000 GDDR6 256 bit ekran kartına sahiptir. Çalışmada tercih edilen veri setini sınıflandırmak için transfer öğrenme yöntemiyle önceden eğitilmiş ağlar üzerinde elde edilen sonuçlar Tablo 2'de sunulmuştur.

TABLO II. TÜM DUYGULARIN ORTALAMA SINIFLANDIRMA SONUÇLARI

	Dense Net	Google Net	Mobile Net	ResNet 18	ResNet 50	ResNet 101	vgg 16
Eğitim Doğruluğu (%)	96,35	**98,01**	96,35	96,68	97,34	95,02	92,36
Test Doğruluğu (%)	75,51	80,61	76,53	79,59	**81,63**	73,47	76,53
Validasyon Doğruluğu (%)	77,14	**83,81**	79,05	80,95	81,90	79,05	78,10
Duyarlılık (%)	75,51	80,61	76,53	79,59	**81,63**	73,47	76,53
Kesinlik (%)	76,09	81,91	81,09	81,89	**83,80**	75,11	78,75
F1 Skoru	0,76	0,81	0,79	0,81	**0,83**	0,74	0,78
ROC Eğrisi Altındaki Alan (Ortalama)	0,86	**0,89**	0,86	0,88	**0,89**	0,85	0,86
Eğitim Süresi (dk:sn)	166:52	3:58	6:07	**2:43**	6:46	68:28	26:54

Eğitim doğruluğu parametresi en yüksek GoogleNet ağı ile %98,01 olarak elde edilmiştir. Hemen arkasından ResNet50 ağı ile %97,34'lük bir başarı sağlanmıştır. Test doğruluğunda en yüksek başarı %81,63'tür ve ResNet50 ağı ile elde edilmiştir. İkinci en iyi sonuç ise aynı parametre için GoogleNet ile alınmıştır ve %80,61'dir. Validasyon doğruluğunda ise GoogleNet öne çıkmaktadır ve %83,81 başarı elde edilmiştir. Arkasından gelen en iyi validasyon doğruluğu ise %81,90 ile ResNet50 ağına aittir. Elde edilen en yüksek test verisi doğruluk değerine sahip Resnet50 ağına ait karşıtlık matrisi Şekil 1'de verilmiştir.

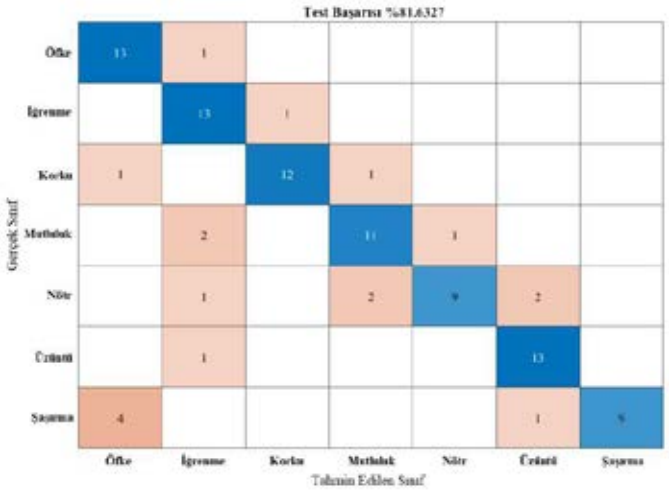
Duyarlılık parametresinde %81,63'lük başarı ResNet50 ağı ile yakalanmıştır. Kayda değer ikinci başarı ise GoogleNet ağı ile %80,61'dir.

ResNet50 ağı %83,80 başarı ile kesinlik anlamında en yüksek değeri vermiştir. Ardından en iyi sonuç GoogleNet ile %81,91 olarak elde edilmiştir.

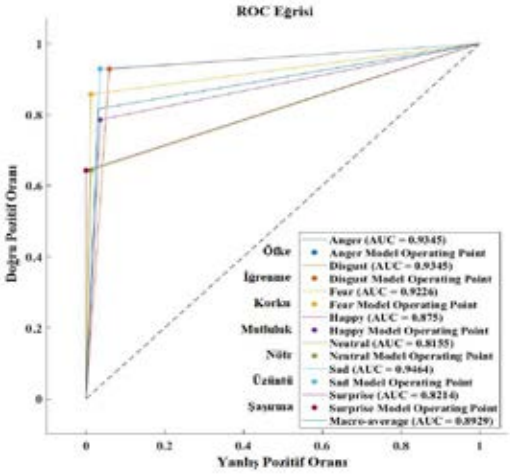
F1 Skoru ise en yüksek ResNet50 ağı ile 0,83 olarak elde edilirken, ikinci en yüksek skor 0,81 ile GoogleNet ve ResNet18 ağlarına aittir.

Karar vericinin etkinliği eğrisi altında kalan alan, her sınıf için elde edilen değerlerin ortalaması olarak verilmiştir. En yüksek değer 0,89 olarak hesaplanmış olup, GoogleNet ve ResNet50 ağları ile elde edilmiştir. İkinci en yüksek değeri veren ağ ResNet18'dir. Şekil 2 ResNet50 ağı ile elde edilen test başarısına dair ROC eğrisini göstermektedir.

Eğitim süresi en kısa süren ağ 2 dakika 43 saniye ile ResNet18'dir. İkinci en hızlı eğitilen ağ ise GoogleNet'tir ve eğitim süresi 3 dakika 58 saniye sürmüştür.



Şekil. 1. ResNet50 ağı ile elde edilen test sonuçlarının karşıtlık matrisi



Şekil. 2. ResNet50 ağına ait test sonuçlarının ROC eğrileri ve sınıfların eğri altında kalan alan değerleri

V. TARTIŞMA

Bu çalışmada bireylerden alınan EKG sinyallerini kullanarak 7 farklı duygunun tespiti yapılmıştır. Bunun için sinyallerin sürekli dalgacık dönüşümü alınarak, sinyaller 2 boyutlu hale getirilmiştir. Ayrıca veri sayısının arttırması için görüntülerin ayna görüntüsü alınmıştır ve veri setine eklenmiştir. Sınıflandırma çalışması için bilinen önceden eğitilmiş evrişimsel sinir ağları kullanılmış ve transfer öğrenme yöntemiyle %81,63 doğrulukla başarı elde edilmiştir.

Çalışma sonuçları incelendiğinde, en ideal ağın hangisi olacağını belirlemek birkaç parametrenin beraber değerlendirilmesi sonucu ortaya çıkacaktır.

Test başarısı olduğu kadar validasyon başarısı da bir diğer önemli parametredir. Test için %1, validasyon için ise %2'lik

bir yaklaşıklıkla GoogleNet ve ResNet50 ağları öne çıkmaktadır. Elde edilen en yüksek test başarısı ResNet50 ile %81,63'tür.

Kesinlik için de yine ResNet50 ağı %83,80 gibi bir değerle en yüksek skoru vermektedir. GoogleNet ise %2'lik bir fark ile ikinci en iyi sonucu vermiştir.

F1 skoru kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır. Standart ortalama, aykırı değerlerin fark edilmemesine sebep olurken, harmonik ortalama bunun önüne geçmektedir. Ayrıca sınıftaki eleman sayısı eşit dağılmayan veri setleri için de önemli bir metriktir. F1 skoru sistem performansı hakkında bilgi sunarken, kesinlik ve duyarlılık metriklerini bir parametreye indirger. F1 skoru 0 ile 1 arasında değer alır ve 1'e ne kadar yaklaşırsa sistem performansı o kadar yüksektir. Bu bilgiler ışığında ResNet50 0,83 değeriyle diğer ağların önündedir. Hemen ardından gelen GoogleNet için ise 0,81'lik bir skor elde edilmiştir. Ayrıca ResNet18 de GoogleNet ile aynı değeri yakalamıştır.

Karar vericinin etkinliği eğrisi altında kalan alanda da yine GoogleNet ve ResNet50 ağları birbirinden ayrılmamaktadır ve elde edilen değer 0,89'dur. Şekil 2 incelendiğinde en iyi sınıflandırılan duyguların öfke, iğrenme ve üzüntü olduğu görülmektedir.

Eğitim için geçen süre incelendiğinde ResNet18 öne çıkmasına rağmen hiçbir metrikte ilk sırada olmamıştır. İkinci en hızlı eğitilen ağ GoogleNet'tir ve eğitim yaklaşık 4 dakika sürmüştür.

Dar ve diğerleri [6] yaptıkları çalışmada, hem EGK verisini hem de GDT sinyallerini beraber kullanmışlardır. Bu çalışmada ise sadece EKG sinyalleri kullanılmıştır. Çalışmalarında validasyon seti kullanmadan, verilerini doğrudan eğitim ve test olarak %70 ile %30 olmak üzere ayırmışlardır. Bu çalışmada ise %60 eğitim, %20 test ve %20 validasyon tercih edilmiştir. Çalışmalarında kullandıkları optimizasyon algoritması mevcut çalışmadakiyle aynıdır. Paylaşılan veri setini [7] kullanan orijinal çalışmada [6] elde edilen başarı %66,64'ken, mevcut çalışmada %81,63'lük bir başarı elde edilmiştir.

Yapılan çalışmada başarı, orijinal çalışmanın üzerine çıkmıştır. EKG verisinden duygu tespiti için en uygun ağ ResNet50 olarak gözükse de GoogleNet de mutlaka denenmesi gereken ağlar arasındadır. Hatta veri sayısı artması halinde eğitim süresi de uzayacağından büyük çaplı verilerde GoogleNet'in öne çıkma ihtimali de göz önünde bulundurulmalıdır.

İlerleyen çalışmalarda farklı işaret işleme yöntemleriyle verilerin işlenmesi, derin öğrenme ağlarının parametreleri üzerinde değişiklik yapılması ve ağlara bazı katman eklentileri yapılarak sınıflandırma performansının arttırılması planlanmaktadır.

BİLGİLENDİRME

Bu çalışmanın tamamlanması için "Yapay Zekâ Laboratuvarı" imkânlarını kullanıma açan İstanbul Üniversitesi-Cerrahpaşa Teknik Bilimler Meslek Yüksekokulu Müdürlüğü'ne minnettarız.

KAYNAKLAR

[1] Ando, A., Masumura, R., Sato, H., Moriya, T., Ashihara, T., Ijima, Y., and Toda, Y., "Speech Emotion Recognition Based on Listener Adaptive Models", *2021 IEEE International Conference on Acoustics (ICASSP 2021), Speech and Signal Processing*, 6274-6278, 2021.

[2] Deshmukh, R. S., Jagtap, V., and Paygude, S., "Facial emotion recognition system through machine learning approach", *2017 International Conference on Intelligent Computing and Control Systems (ICICCS)*, 272-277, 2017

[3] Qiu, H., He, L., and Wang, F., "Dual Focus Attention Network For Video Emotion Recognition", *2020 IEEE International Conference on Multimedia and Expo (ICME)*, 1-6, 2020.

[4] Cai, H., Liu, X., Jiang, A., Ni, R., Zhou, X., and Cangelosi, A., "Combination of EOG and EEG for emotion recognition over different window sizes", *2021 IEEE 2nd International Conference on Human-Machine Systems (ICHMS)*, 1-6, 2021.

[5] Kar, P., Hazarika, J., and Sethi, M. R., "A Comparative Study between Supervised and Unsupervised Techniques for Two Class Emotion Recognition using EEG", *2023 IEEE 8th International Conference for Convergence in Technology (I2CT)*, 1-6, 2023.

[6] Dar, M. N., Rahim, A., Akram, M. U., Gul Khawaja, S., and Rahim, A., "YAAD: Young Adult's Affective Data Using Wearable ECG and GSR sensors", *2022 2nd International Conference on Digital Futures and Transformative Technologies (ICoDT2)*, 1-7, 2022.

[7] Akram, M. U., Dar, M. N., and Rahim, A., "Young Adult's Affective Data (YAAD) Using ECG and GSR Signals", *Mendeley Data*, V4, https://doi.org/10.17632/g2p7vwxyn2.4.

[8] Tokmak, F., Subasi, A., and Qaisar, S. M., "Artificial intelligence-based emotion recognition using ECG signals", In: Subasi, A., editor, *Artificial Intelligence Applications in Healthcare and Medicine, Applications of Artificial Intelligence in Healthcare and Biomedicine*, Academic Press, 2024, pp. 37-67.

[9] Lilly J. M., "Element analysis: a wavelet-based method for analysing time-localized events in noisy time series", *Proc. R. Soc. A., Mathematical, physical, and engineering sciences*, 473:20160776, 2017.

[10] Huang, G., Liu, Z., Van Der Maaten, L., and Weinberger, K. Q., "Densely Connected Convolutional Networks", *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2261-2269, 2017.

[11] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A., "Going deeper with convolutions", *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1-9. 2015.

[12] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., and Chen, L.-C., "MobileNetV2: Inverted Residuals and Linear Bottlenecks", *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 4510-4520, 2018.

[13] He, K., Zhang, X., Ren, S., and Sun, J., "Deep Residual Learning for Image Recognition", *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778, 2016.

[14] Simonyan, K., and Zisserman, A., "Very deep convolutional networks for large-scale image recognition", *3rd International Conference on Learning Representations (ICLR 2015)*, 1–14, 2015.

[15] Poola, R. G., Pl, L., and Y, S. S., "COVID-19 diagnosis: A comprehensive review of pre-trained deep learning models based on feature extraction algorithm", *Results in engineering*, 18:101020, 2023.