



Çok Ölçekli Temel Bileşen Analizi ve Evrişimsel Sinir Ağları ile Elektrokardiyografi Sinyallerinden Miyokart Enfarktüsünün Tespiti

Arda Aydoğan¹, Buse İçme², Ali İnce³, Sümeyya Arıkan⁴, Fatma Latifoğlu^{5*}

¹ Erciyes Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü, Kayseri, Türkiye, (ORCID: 0000-0001-5982-1477), aydoganarda@yahoo.com

² Erciyes Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü, Kayseri, Türkiye (ORCID: 0000-0001-7262-0725), icmebuse@gmail.com

³ Erciyes Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü, Kayseri, Türkiye. (ORCID: 0000-0003-1159-1785), inceali623@gmail.com

⁴ Düzce Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü, Düzce, Türkiye (ORCID: 0000-0001-7582-7537), sumeyyaarikan@duzce.edu.tr

⁵ Erciyes Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü, Kayseri, Türkiye (ORCID: 0000-0003-2018-9616), flatifoglu@erciyes.edu.tr

(3rd International Conference on Applied Engineering and Natural Sciences ICAENS 2022, July 20-23, 2022)

(DOI: 10.31590/ejosat.1146011)

ATIF/REFERENCE: Aydoğan, A., İçme, B., İnce, A., Arıkan, S., Latifoğlu, F., (2022). Çok Ölçekli Temel Bileşen Analizi ve Evrişimsel Sinir Ağları ile Elektrokardiyografi Sinyallerinden Miyokart Enfarktüsünün Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, (39), 138-142.

Öz

Miyokart enfarktüsü (kalp krizi) çok kısa sürede müdahale edilmesi gereken hayati bir hastalıktır. Hastaya ait elektrokardiyografi (EKG) verilerinin analizi teşhiste önemli bir yer tutmaktadır. Bu nedenle bu hastalığın daha hızlı ve doğru olarak belirlenebilmesi için son yıllarda bilgisayar destekli karar destek sistemlerden faydalanılmaktadır. Bu çalışmada miyokart enfarktüsü tanısı almış 61 hastadan ve 52 sağlıklı bireyden elde edilen EKG sinyalleri ve Evrişimsel sinir ağları (ESA) kullanılarak miyokart enfarktüsüne yönelik sınıflandırma modeli ortaya konmuştur. EKG sinyallerine sonlu dürtü yanıtı (FIR) süzgeç, sonsuz dürtü yanıtı (IIR) süzgeç ve çok ölçekli temel bileşen analizi uygulanarak üç farklı süzgeç ile ön işlemeden geçirilmiştir. Sinyaller daha sonra geliştirilen ESA modeli yardımıyla sınıflandırılmıştır. Elde edilen sonuçlara göre çok ölçekli temel bileşen analizi kullanılarak ön işlemeden geçirilen sinyaller kullanılarak %92.3 doğruluk oranıyla sınıflandırma başarısı elde edilmiştir ve FIR, IIR süzgeç yardımıyla ön işleme yapılan sinyallerin sınıflandırılmasına göre daha başarılı sınıflandırma performansının elde edildiği görülmüştür.

Anahtar Kelimeler: Biyomedikal Sinyal İşleme, Evrişimsel Sinir Ağları, Çok Ölçekli Temel Bileşen Analizi, EKG, Miyokart Enfarktüsü

Detection of Myocardial Infarction from Electrocardiography Signals with Multiscale Principal Component Analysis and Convolutional Neural Networks

Abstract

Myocardial Infarction is a vital disease that needs to be intervened in a very short time. The analysis of the patient's electrocardiography (ECG) data has an important place in the diagnosis. For this reason, computer aided decision support systems have been used in recent years in order to determine this disease more quickly and accurately. In this study, classification was made using convolutional neural network algorithms on the ECG signals obtained from 61 patients diagnosed with myocardial infarction and 52 healthy individuals. ECG signals are preprocessed with three different filters by applying finite impulse response (FIR) filter, infinite impulse response (IIR) filter and multiscale principal component analysis. According to the results obtained, classification success was achieved with 92.3% accuracy by using the preprocessed signals using multi-scale principal component analysis, and it was seen that more successful classification performance was obtained compared to the classification of the preprocessed signals with the help of FIR, IIR filter.

Keywords: Biomedical Signal Analysis, Convolutional Neural Networks, Multislice Principal Component Analysis, ECG, Myocardial Infarction.


* Sorumlu Yazar: flatifoglu@erciyes.edu.tr

1. Giriş

Miyokart enfarktüsü (kalp krizi), uzun süreli iskemi sonucunda kalpte meydana gelen miyokart hasarına denilmektedir. Dünya nüfusunda her yıl yaklaşık 17,3 milyon kişi kalp-damar hastalıkları sebebiyle yaşamını yitirmektedir [1]. EKG deri üzerinden elektrotlar aracılığı ile ölçüm yapılan kalbin elektriksel aktivitesini yansıtan sinyallerdir. Miyokart enfarktüsünü EKG sinyali ile teşhis edebilmek mümkündür, fakat bu sinyallerin genliği küçük, süresi kısa olduğundan hızlı ve doğru bir şekilde yorumlamak zordur [2].

Miyokart enfarktüsü EKG sinyallerinden PR segmentinde, QRS kompleksinde, ST segmentinde veya T dalgalarında ortaya çıkan anormalliklerle belirlenmektedir [3]. Miyokart iskemisinin en erken belirtileri tipik T dalgaları ve ST segmentindeki yükselme-çökme gibi değişikliklerdir [4]. Normal bireylerin EKG sinyallerinde ST segmentinde 1 mm yükselme-çökme normal karşılanmaktadır [5]. Miyokard enfarktüsünün erken teşhis edilmesiyle birlikte kalp-damar kaynaklı ölüm oranının azalması yönünde önemli etkisi olacaktır.

Günümüzde, EKG sinyallerini hızlı ve güvenilir bir şekilde yorumlamak için bilgisayar destekli tanı cihazı kullanılmasına yönelik çalışmalar hızla artmaktadır. Shane Loeffler ve arkadaşları EKG sinyallerinden miyokart enfarktüsünü otomatik olarak teşhis etmek için Evrişimsel Sinir Ağları (ESA) ile stokastik ve reaksiyon-difüzyon modeli kullanarak miyokard infarktüsünün tanısının yapılmasını önermiştir [3]. Fakat bu yaklaşımın matematiksel modeli oldukça karmaşık, uygulaması ise zorludur. Xinwen Liu ve arkadaşlarının yaptığı genel literatür sınıflandırma performansına etkisi analiz edilmiştir. Çalışmanın akış şeması Şekil 1 de görülmektedir.



Şekil 1. Genel Akış Algoritması

2. Materyal ve Metot

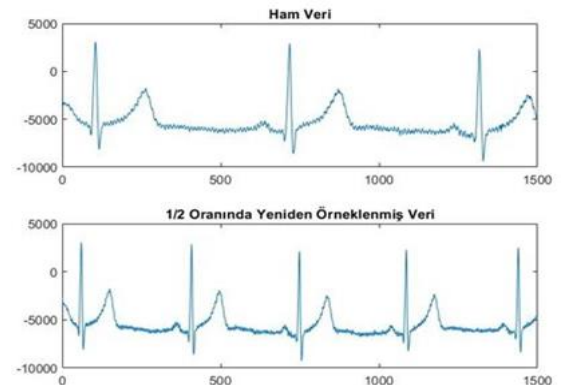
2.1. EKG Verilerinin Eldesi

Bu çalışmada, miyokart enfarktüsünü sınıflandırmak için kullanılan 12 derivasyonlu EKG sinyalleri, Mendeley Database adlı platformda, Gazi Üniversitesi Kardiyoloji anabilim dalına müracaat etmiş, 74 adet koroner arter hastalarının %70'inde ciddi damar tıkanıklığı ve göğüs ağrısı içeren hastalardan elde edilmiştir [10]. Bu halka açık veri setinde 12 kanallı EKG cihazı olan microCOR programı kullanılmıştır. EKG kayıtları, 24-bit örnekleme çözünürlüğü ve 0.1 μ V genlik çözünürlüğü ile 8800 Hz de örneklenecek sayısal formata çevrilmiştir. Elde edilen veri kümesi ham sinyaller olarak herhangi bir filtreleme işlemine tabi tutulmamıştır. Her bireyin EKG verileri tek tek incelenerek ileri derecede faz kayması olan ve sinyalde büyük bozulmalar olan veriler elimine edilerek 61 adet hasta bireylerin veri kümesi oluşturulmuştur [10]. Sınıflandırmada kullanılacak sağlıklı bireylere ait 12 derivasyonlu EKG verileri ise PhysioNet adlı platformdan elde edilmiştir. PTB Diagnostic ECG Database adlı

çalışmalarının özetinde gösterildiği gibi evrişimsel sinir ağları ile yapılan çalışmaların son zamanlarda oldukça arttığı görülmektedir. Ancak yapılan çalışmalar çoğunlukla atriyal fibrilasyon (aritmisi) üzerine farklı uygulama tekniklerinin kullanımı ile gerçekleştirildiği görülmektedir [4]. Ramesh ve arkadaşları, EKG aritmisinin tespiti için her kalp atışından üç adet özellik çıkarımı yapılmıştır. Bu özellikler Çiftli Ağaç Kompleks Dalgacık Dönüşümü ile morfolojik işlemlerin uygulanması sonucu elde edilmiştir. Özellik çıkarımı ile Evrişimsel Sinir Ağlarına uygulanan veriler ile %98 doğruluk elde etmiştir [6]. Wang ve arkadaşları R-R aralıklarından ve R genliklerinden öznelikleri çıkarmak için farklı bir ESA modeli geliştirmiştir. Bu model iki adet evrişim katmanı ve her evrişim katmanının ardından maksimum havuzlama katmanı içermektedir. Sınıflandırıcı olarak LeNet-5 tekniğini kullanmıştır ve çalışmanın sonucunda %87.6 doğruluk elde edilmiştir [7]. Adaboost metodu kullanılan başka bir çalışmada sinyallerin Q-Faktörlü Dalgacık dönüşümünden elde edilen özellikleri sunmuşlardır. Sınıflandırma doğruluğu ise %87.33 olarak belirlenmiştir [8]. Zarei ve arkadaşları ise sınıflandırma için SVM metodunu kullanmıştır. Dalgacık dönüşümü ile EKG sinyallerinden entropi tabanlı özellikleri elde edilerek sınıflandırma çalışması gerçekleştirilmiştir. Sınıflandırma doğruluğu ise %92.98 olarak belirlenmiştir [9]. Yapılan çalışmalarda kullanılan veri seti kümesi genelde aynı olmakla birlikte aritmisi sınıflandırması üzerine yoğunlaşmıştır. Bu çalışmada miyokard infarktüsü tanısı konmuş hastalara ait veri seti [10] ile tarafımızca geliştirilen Evrişimsel Sinir Ağı modeli ile miyokart enfarktüsü sınıflandırılmıştır. Verilerin ön işlenmesi aşamasında FIR, IIR süzgeçleri ve Çok Ölçekli Temel Bileşen Analizi (MPCA) metodu kullanılarak bu ön işlemlerin sı veri kümesi 2000 yılında Department of Cardiology of University Clinic Benjamin Franklin in Berlin hastanesinde kaydedilmiştir. Bu veriler PhysioBank üzerinden elde edilmiştir. 12 kanal olup 52 adet sağlıklı veri vardır ve verilerin örnekleme frekansı 10000 Hz'dir [11].

2.2. Sinyal Önişleme

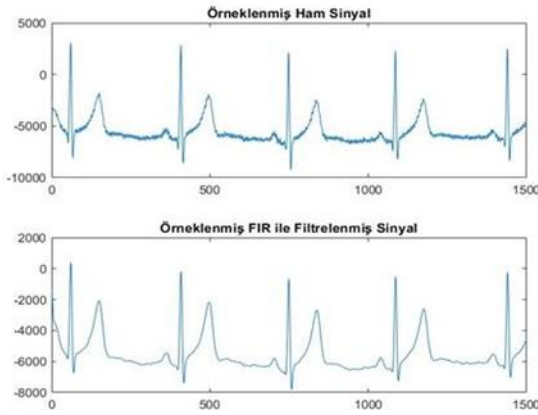
Bu çalışmada iki farklı halka açık veri setinden elde edilen EKG sinyallerinden sağlıklı bireylere ait olanlar 10000 Hz örnekleme frekansı ile örnekleşken Miyokard İnfarktüsü geçirmiş bireylere ait olanlar ise 8800 Hz örnekleme frekansı ile örneklendirilmiştir. Farklı örnekleme frekansları ile örneklenecek elde edilen EKG sinyalleri, örnekleme frekansı 5000 Hz. olacak şekilde sağlıklı bireylerin sinyallerini Şekil 2 de görüldüğü gibi $\frac{1}{2}$ oranında, hasta bireylerin sinyalleri ise $\frac{5}{8.8}$ oranında yeniden örneklendirilmiştir. Şekil 2 de sağlıklı bireye ait örnek bir EKG sinyali görülmektedir.



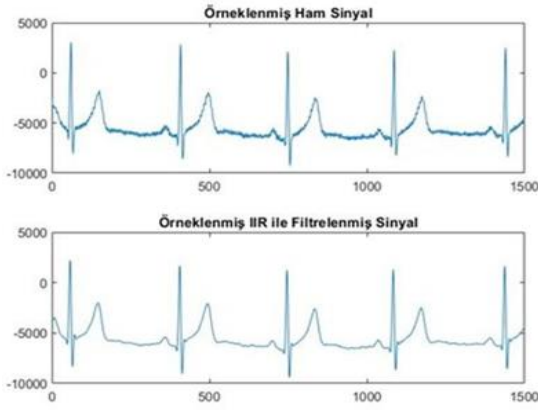
Şekil 2. EKG sinyalinin yeniden örnekleme

Telefon, radyo, radar, uydu, işaret işleme, medikal sistemler gibi hemen hemen her alanda kullanılan süzgeçler genellikle elektronik devrelerde, gürültüyü ve istenmeyen işaretleri süzmek, belirli frekansları birbirinden ayırmak, örnekleme işleminden önce sinyalleri sınırlamak gibi çeşitli amaçlarla kullanılmaktadır [14].

Sonlu dürtü yanıtı (FIR) ve sonsuz dürtü yanıtı (IIR) süzgeçleri dijital sinyal işlemede kullanılan başlıca süzgeçlerdir. FIR süzgeçler lineer fazlı frekans yanıtına sahiptir ve sabit grup gecikmesi sağlarlar. IIR süzgeçler ise FIR süzgeçlere göre daha verimlidir çünkü daha az geciktirici eleman, toplayıcı ve çoğaltıcıya ihtiyaç duymaktadır. FIR süzgeç ile filtrelenmiş örnek bir EKG sinyali Şekil 3 de gösterilmektedir. IIR süzgecin FIR süzgece göre avantajı grup gecikmesinin olmaması ve geçirme bandının daha dar bir frekans sahasında yer almasıdır. IIR süzgeç ile filtrelenmiş örnek bir EKG sinyali Şekil 4 te gösterilmektedir.



Şekil 3. FIR ile filtrelenmiş sinyal



Şekil 4. IIR ile filtrelenmiş sinyal

2.3. Çok Ölçekli Temel Bileşen Analizi

Temel bileşen analizi (PCA), değişken kombinasyonları üretmek bu kombinasyonlara ait önemli veri çeşitlerinin yönlerini belirlemeye yarayan istatistiksel bir yöntemdir [15]. PCA özellik çıkarma ve boyut küçültme konusunda yüksek performansa sahiptir. Veri seti gözlem ve değişken sayısı ile bir matris üzerinde tanımlar ve matris birim varyans ve sıfır ortalamalarla standartlaştırılır, tek değerli ayrıştırma ile yeni bir matrise yorumlanır [15]. Bu yöntem Bakshi tarafından dalgacık analizi yöntemiyle birleştirilmiş, her dalgacık ölçeğinde PCA modellerini belirleyen çok ölçekli temel bileşen analizi (Multiscale Principal Component Analysis, MSPCA) yöntemi ortaya çıkmıştır [16]. Bu çalışmada 12 derivasyonlu EKG

sinyallerine çok ölçekli temel bileşen analizi uygulanarak EKG sinyallerinin gürültüsü elimine edilmiştir.

EKG sinyallerinin çok ölçekli temel bileşen analizi sahte kodu aşağıda yer almaktadır [17]:

- for Her EKG matrisi satırı için
 - o dalgacık ayrışımı hesapla
- end
- for Her ölçek için
 - o seçilen ölçekte dalgacık kovaryans matrisini hesapla
 - o PCA yüklerini ve katsayılarını hesapla
 - o uygun sayıda yükleme seç
 - o uygun eşikten daha büyük katsayıları seç
- end
- for tüm ölçekleri birlikte
 - o önemli verilere sahip ölçekleri dahil ederek PCA hesapla
 - o her ölçekte seçilen eşiklenmiş değerlerden yaklaşık veri matrisini tekrar oluştur
- end

2.4. Evrişimsel Sinir Ağları

ESA derin öğrenmenin alt grubu olarak incelenen çok katmanlı yapıya sahip makine öğrenmesidir. Büyük ölçekli verilerden özellik çıkarmakta kullanılır [18]. Biyolojik süreçlerden esinlenilmiş, özellik çıkarma ve sınıflandırmayı birleştirerek, doğrudan görüntünün piksellerinden veya sinyallerden kalıpları tanımak üzere tasarlanmış ileri beslemeli yapay sinir ağlarıdır [19]. Yapay sinir ağlarında bulunmayan evrişim katmanı filtreler ile görüntüyü sağ-sol, yukarı-aşağı olacak şekilde tarayarak özellik haritasının elde edilmesini sağlar [20]. Son yıllarda ESA mimarisi görüntü sınıflama, nesne tanıma, tespit etme yöntemleri olarak bilgisayar uygulamalarında ve sağlık alanında yüksek sınıflama doğruluk oranları ile kullanılmaktadır [21]. ESA; evrişim (konvolüsyon) katmanı, havuzlama katmanı, aktivasyon (Re-Lu) katmanı, tam bağlı katman ve sınıflandırma katmanlarından oluşmaktadır.

Evrişim (Konvolüsyon) Katmanı: Derin sinir ağının temelini oluşturur. Küçük boyutlu (2x2, 3x3, 5x5) süzgeçlerin görüntünün tamamında gezdirilerek özellik çıkarılmasını, yeni görüntü elde edilmesini sağlayan katmandır [21].

Havuzlama Katmanı: Bu katmanda görüntüdeki piksellerin maksimum, ortalama, minimum değerleri hesaplanarak boyut azaltma işlemi yapılmaktadır. En önemli dezavantajı, işlem esnasında bilgi kaybına, performansın düşmesine neden olabilmesi ve en önemli avantajı ise modelin ezberlemeyi önlemesi, hesaplama yükünü azaltmasıdır [21].

Aktivasyon Katmanı: Re-Lu derin sinir ağlarında sıklıkla kullanılan, girişteki negatif değerleri sıfıra çekerek ağın hızlı öğrenmesini sağlayan katmandır [21].



Şekil 5. Evrişimsel Sinir Ağları Katmanları

Tam Bağlı Katman: Kendisinden sonra gelen katmanın tüm nöronlarına bağlı ve tek boyutlu bir matristir. Sınıf skorları optimize edilir ve derin öğrenme mimarisine göre de katman sayısı değişiklik gösterebilmektedir [21].

Sınıflandırma Katmanı: Sınıflandırma işleminin gerçekleştiği son katmandır. Bu katmanda sıklıkla softmax sınıflandırıcısı kullanılmaktadır. Bu sınıflandırıcı her bir sınıf için ayrı ayrı 0-1 arasında olasılıksal değerler üretmektedir ve sonuç olarak en yüksek olasılıklı modelin tahmin edildiği sınıf belirlenmektedir [21]. Bu çalışmada miyokard enfarktüsünün belirlenmesine yönelik farklı katmanlardan oluşan ESA mimarisi denemiştir ve sınıflandırma performansının en iyi elde edildiği Şekil 5 te görülen ESA mimarisi geliştirilmiştir.

Model eğitimi sırasında öğrenme algoritması olarak Adam algoritması kullanılmış olup, döngü sayısı 150, Mini Batch boyutu 64 olarak ve öğrenme oranı değeri 0.001 olarak belirlenmiştir.

3. Araştırma Sonuçları ve Tartışma

Bu çalışmada, miyokard enfarktüsünü belirlemeye yönelik bir ESA modeli geliştirilmiştir. Ayrıca EKG sinyalleri üzerinde yer

alan istenmeyen gürültülerin eliminasyonu için farklı süzgeçlerin sınıflandırma başarısına etkisi analiz edilmiştir. EKG sinyallerinin filtrelenmesi aşamasında FIR, IIR süzgeçler ve Çok Ölçekli Temel Bileşen Analizi yöntemlerini kullanılmıştır. Sınıflandırma performansının belirlenmesi aşamasında 10-fold çapraz doğrulama yöntemi kullanılmıştır. 12 derivasyonlu EKG sinyallerine ilk olarak, kesim frekansı 0.13 olan alçak geçiren bir FIR süzgeç uygulanmıştır. FIR süzgeç ile filtrelenmiş sinyallerin geliştirilen ESA modeli ile sınıflandırılması sonucunda Tablo 1 den de görüldüğü gibi doğruluk oranı %75.3, F1 skoru ise 0.79 olan sınıflandırma performansı elde edilmiştir. İkinci olarak kesim frekansı 0.13 olan bir alçak geçiren IIR süzgeç 12

derivasyonlu EKG sinyallerine uygulanmıştır. IIR süzgeç ile filtrelenmiş EKG sinyallerinin ESA modeli ile sınıflandırılması sonucunda Tablo 1 den de görüldüğü gibi doğruluk oranı %89.4, F1 skoru ise 0.88 olan sınıflandırma performansı elde edilmiştir. Bu sonuçlara göre IIR süzgeç kullanılan modelin FIR süzgeç kullanılan modele nazaran daha başarılı bir sınıflandırma performansı ortaya koyduğu görülmüştür. Son olarak da EKG sinyallerine çok ölçekli temel bileşen analizi uygulanarak EKG sinyallerindeki ortak gürültü giderilmiştir. Bu sinyallere ESA modelinin uygulanması sonucunda Tablo 1 den de görüldüğü gibi doğruluk oranı %92.3, F1 skoru ise 0.93 olan sınıflandırma performansı elde edilmiştir.

Tablo 1 - Eğitim Başarı Parametreleri

Doğruluk Değeri											
	1.fold	2.fold	3.fold	4.fold	5.fold	6.fold	7.fold	8.fold	9.fold	10.fold	Ortalama
MSPCA	88.24	91.18	97.06	85.30	79.41	91.67	97.06	100	93.94	100	92.33
IIR	75	81.82	81.82	81.82	100	90.91	100	91.67	90.91	100	89.40
FIR	36.36	81.82	45.46	54.55	81.82	91.67	81.82	91.67	72.73	91.67	72.96
Özgünlük Değeri											
	1.fold	2.fold	3.fold	4.fold	5.fold	6.fold	7.fold	8.fold	9.fold	10.fold	Ortalama
MSPCA	1	0.8	1	0.92	1	1	1	1	0.94	1	0.97
IIR	1	1	0.86	1	1	0.8	1	1	1	1	0.97
FIR	0	1	0	0	1	0.8	1	0.86	1	0.83	0.65
F1 Skoru											
	1.fold	2.fold	3.fold	4.fold	5.fold	6.fold	7.fold	8.fold	9.fold	10.fold	Ortalama
MSPCA	0.89	0.92	0.96	0.88	0.81	0.90	0.97	1	0.93	1	0.93
IIR	0.80	0.80	0.75	0.80	1	0.92	1	0.86	0.89	1	0.88
FIR	0.53	0.86	0.63	0.71	0.83	0.93	0.80	0.91	0.73	0.92	0.79

4. Sonuçlar

Miyokart enfarktüsü; hekimler tarafından bireylerin EKG veya kan tahliline bakılarak teşhis edilebilmektedir. Acil ve anlık karar verilmesi gereken durumlarda uzman bilgisi gerekirken ve EKG sinyallerinin doğru bir şekilde değerlendirilmesinde zorluk çekebilmektedirler. Bu çalışmada 12 derivasyonlu EKG sinyallerinden miyokart enfarktüsünün tespiti üzerine bir ESA modeli geliştirilmiştir. Literatürde Evrişimsel Sinir Ağları çoğunlukla sağlık alanlarında ve sinyalleri görüntü olarak ele alarak sınıflandırma yapılmıştır. Önerilen yöntemde ise ESA mimarisine EKG verileri 1 boyutlu sinyal olarak uygulanmıştır. FIR, IIR süzgeçler ve çok ölçekli temel bileşen analizi ile ön işleme yapılarak elde edilen EKG sinyalleri evrişimsel sinir ağı modelinde girdi olarak uygulanmıştır. Tasarlanan ESA modeli ile yapılan sınıflandırma çalışmasında en yüksek doğruluk oranının çok ölçekli temel bileşen analizi ile ön işlenmiş sinyallerin kullanılması sonucunda elde edildiği görülmüştür. Bu çalışmada 12 derivasyonlu EKG sinyallerinin çok ölçekli temel bileşen analizi ve ESA modeli ile başarılı bir şekilde sınıflandırılabilineceği ortaya konmuştur.

Kaynakça

- [1] Benjamin, E. J., Muntner, P., Alonso, A., Bittencourt, M. S., Callaway, C. W., Carson, A. P., ... & American Heart Association Council on Epidemiology and Prevention Statistics Committee and Stroke Statistics Subcommittee. (2019). Heart disease and stroke statistics—2019 update: a report from the American Heart Association. *Circulation*, 139(10), e56-e528
- [2] Acharya, U. R., Fujita, H., Oh, S. L., Hagiwara, Y., Tan, J. H., & Adam, M. (2017). Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals. *Information Sciences*, 415, 190-198.
- [3] Loeffler, S., & Starobin, J. (2021). Reaction-diffusion informed approach to determine myocardial ischemia using stochastic in-silico ECGs and CNNs. *Computers in Biology and Medicine*, 136, 104635.
- [4] Liu, X., Wang, H., Li, Z., & Qin, L. (2021). Deep learning in ECG diagnosis: A review. *Knowledge-Based Systems*, 227, 107187.
- [5] Thygesen, K., Alpert, JS, White, HD ve Miyokard Enfarktüsünün Yeniden Tanımlanması için Ortak ESC/ACCF/AHA/WHF Görev Gücü. (2007). Miyokard enfarktüsünün evrensel tanımı. *Amerikan Kardiyoloji Koleji Dergisi*, 50 (22), 2173-2195
- [6] Ramesh, G., Satyanarayana, D., & Sailaja, M. (2021). Composite feature vector based cardiac arrhythmia classification using convolutional neural networks. *Journal of Ambient Intelligence and Humanized Computing*, 12(6), 6465-6478.
- [7] Wang, T., Lu, C., Shen, G., & Hong, F. (2019). Sleep apnea detection from a single-lead ECG signal with automatic feature-extraction through a modified LeNet-5 convolutional neural network. *PeerJ*, 7, e7731.
- [8] Hassan, A. R. (2016). Computer-aided obstructive sleep apnea detection using normal inverse Gaussian parameters and adaptive boosting. *Biomedical Signal Processing and Control*, 29, 22-30.
- [9] Zarei, A., & Asl, B. M. (2018). Automatic detection of obstructive sleep apnea using wavelet transform and entropy-based features from single-lead ECG signal. *IEEE journal of biomedical and health informatics*, 23(3), 1011-1021.
- [10] Terzi, M. B., Abaci, A., Arikan, O., Candemir, M., & Dedeoglu, M. (2020). The GU-ECG Database: ECG Datasets for Detection and Classification of Acute Myocardial Ischaemia Through Machine Learning. *Mendeley Data*, v1.
- [11] Goldberger, A. L., Amaral, L. A., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., ... & Stanley, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *circulation*, 101(23), e215-e220.
- [12] Eltrass, A. S. (2022). Novel cascade filter design of improved sparse low-rank matrix estimation and kernel adaptive filtering for ECG denoising and artifacts cancellation. *Biomedical Signal Processing and Control*, 77, 103750.,
- [13] Özpolat, E., Karakaya, B., & Gülten, A. (2017). FIR Filtre Tasarımı ve FPGA Ortamında Gerçeklenmesi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 29(2), 269-275.
- [14] Dandıl, E., Turkan, M., Mustafa, B. O. Ğ. A., & Çevik, K. K. (2019). Daha hızlı bölgesel-evrişimsel sinir ağları ile sığır yüzlerinin tanınması. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 6, 177-189.
- [15] Ali, H., Maulud, A. S., Zabiri, H., Nawaz, M., Suleman, H., & Taqvi, S. A. A. (2022). Multiscale Principal Component Analysis-Signed Directed Graph Based Process Monitoring and Fault Diagnosis. *ACS omega*, 7(11), 9496- 9512.
- [16] Lee, D. S., Park, J. M., & Vanrolleghem, P. A. (2005). Adaptive multiscale principal component analysis for on-line monitoring of a sequencing batch reactor. *Journal of Biotechnology*, 116(2), 195-210.
- [17] Sharmila, K., Krishna, E. H., Reddy, K. N., & Reddy, K. A. (2011, May). Application of multiscale principal component analysis (MSPCA) for enhancement of ECG signals. In *2011 IEEE International Instrumentation and Measurement Technology Conference* (pp. 1-5). IEEE.
- [18] Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017, August). Understanding of a convolutional neural network. In *2017 international conference on engineering and technology (ICET)* (pp. 1-6). IEEE.
- [19] Başaran, E., Cömert, Z., Sengur, A., Budak, Ü., Celik, Y., & Toğaçar, M. (2020). Normal ve Kronik Hastalıklı Orta Kulak İmgelerinin Evrişimsel Sinir Ağları Yöntemiyle Tespit Edilmesi. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 13(1), 1-10.
- [20] Ali, A. R. I., & Hanbay, D. (2018). Bölgesel evrişimsel sinir ağları tabanlı MR görüntülerinde tümör tespiti. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 34(3), 1395-1408.
- [21] Türkoğlu, M., Hanbay, K., S., Sivrikaya, I., & Hanbay, D. (2020). Derin Evrişimsel Sinir Ağı Kullanılarak Kayıtlı Hastalıklarının Sınıflandırılması. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9 (1), 334-345.