

KALP SESLERİNDEKİ ANORMALLİKLERİN BELİRLLENMESİ DETECTING ABNORMALITIES IN HEART SOUNDS

MUHAMMED TELÇEKEN^{1*} YAKUP KUTLU¹

¹Bilgisayar Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi, İskenderun
mtelceken@gmail.com, yakup.kutlu@iste.edu.tr

Özetçe— Kalp sesleri kalbin durumunu yansıtan önemli verilerdir. Kalp seslerindeki anormalliklerin erken teşhisi ile oluşabilecek daha büyük sorunları önlemek mümkün olabilmektedir. Bu nedenle bu çalışmada kalp seslerindeki anormalliklerin tespiti üzerine çalışılmıştır. Kalp seslerindeki anormallikleri tespit etmek için kaggle.com internet sitesi üzerinden ücretsiz olarak elde edilmiş heartbeat-sounds veri seti incelenmiştir. Seslerin özelliklerinin seçiminde Mel frekansı sepstral katsayıları (MFCCs) kullanılmıştır. MFCCs için uygulanacak filtre sayısı, çıkarılacak öznitelik sayısı gibi parametreler farklı değerlerde ayrı ayrı incelenmiştir. Kalp seslerinin MFCCs nin farklı parametrelerinde çıkartılan öznitelik matrisleri K-en yakın komşu algoritması ile sınıflandırma başarımları incelenmiştir. Farklı öznitelik çıkarımlarının sınıflandırma başarımlarını karşılaştırılmış ve en iyi durum tespit edilmeye çalışılmıştır. Veri setini oluşturan iki farklı kayıt ayrı ayrı normal ve anormal olarak incelenmiştir. Sonrada iki kayıt birleştirilerek elde edilen yeni veri seti normal ve anormal olarak incelenmiştir.

Anahtar Kelimeler— MFCCs , K-NN Algoritması, Kalp Sesleri, Sınıflandırma

Abstract— Heart sounds are important data that reflect the state of the heart. It is possible to prevent larger problems that may occur with early diagnosis of abnormalities in heart sounds. Therefore, in this study, the detection of abnormalities in heart sounds has been studied. In order to detect abnormalities in heart sounds, the heartbeat-sounds data set obtained free of charge from the kaggle.com website was examined. Mel frequency cepstral coefficients (MFCCs) were used in the selection of the characteristics of the sounds. Parameters such as the number of filters to be applied for MFCCs, the number of attributes to be extracted are examined separately with different values. The classification performance of heart sounds with feature matrices extracted in different parameters of MFCCs with K-nearest neighbor algorithm was investigated. The classification performance of different feature extractions was compared and the best case was tried to be determined. Two different records that make up the data set were examined separately as normal and abnormal. Then, the new data set obtained by combining the two records was examined as normal and abnormal.

Keywords— MFCCs, K-NN, Heart-Sounds, classification

I. GİRİŞ

Vücudumuzun oksijen ve besin ihtiyacını sağlamak için kan dolaşımının düzenli bir şekilde sağlanması hayati öneme sahiptir. Kanın vücutta dolaşımını sağlayan Kalp

tir. Kalbin düzenli çalışması bu nedenle çok önemlidir. Bu yüzden kalbin sağlıklı bir şekilde çalıştığının tespiti çok önemlidir. Kalp sesleri, atan kalp içinden kan akışı tarafından üretilen seslerdir. Sesler esas olarak kalp kapakçıkları kapandığında oluşan türbülansın yansımasıdır. Kalp sesleri, kalbin durumunu gösteren önemli işitsel veriler sağlar. Sağlıklı yetişkinlerde, sıklıkla tanımlanan iki kalp sesi vardır: lub ve dub (veya dup) [1]. Her kalp atışında lub ve dub sıralıdır. AV valflerinin ve yarım ay valflerinin kapatılması sırasıyla birinci kalp sesini (S1) ve ikinci kalp sesini (S2) üretir. Bir anormal ses için kalp hırıltısı gibi mevcut bazı ek sesler vardır. Kalp üfürümleri türbülanslı kan akışıyla üretilir ve kalbin içinde veya dışında meydana gelebilir [1]. Bazı çalışmalar, Doktorların, özellikle zayıf eğitim becerilerine sahip olanların kalp üfürümlerini doğru bir şekilde tanımlamada zorluk yaşayabileceği veya hatalı teşhis koyabileceğini göstermektedir [2]. Tıbbi cihazların gelişmesi ile kalp seslerini dijital ortamda kaydetmek mümkün olmuştur. Dijital cihazlarla kaydedilen kalp seslerinde ki anormalliklerin tespiti için çeşitli çalışmalar yapılmıştır. Bu çalışmalardan bazıları şunlardır. Andrisevic vd. ve arkadaşları [3] dalgacık dönüşümü ve temel bileşeni kullanarak kalp seslerinin özelliklerini belirlemiş ve bir sinir ağı tarafından iki kategoriye ayrılmıştır. C.N.Gupta ve arkadaşları [4] 2007 yılında yaptıkları çalışmada dalgacık dönüşümü kullanarak kalp seslerinin özelliklerini belirlemişler ve Grow and Learn ağı ile kalp seslerini üç kategoride sınıflandırma yaptılar. H. Uguz ve arkadaşları [5] belirlenen dalgacık dönüşümü ve kısa süreli Fourier dönüşümü kullanarak kalp seslerinin öznitelik çıkartmıştır gizli bir Markov modeli tarafından iki kategoriye ayırdılar. Dokur, Z., & Ölmez [6] dalgacık dönüşümü ve yapay sinir ağıları modeli kullanarak dört farklı kalp sesi için sınıflandırma gerçekleştirdi. Özgür SAY [7] Fourier dönüşümü ve yapay sinir ağıları (YSA) kullanarak kalp seslerini dört farklı grupta sınıflandırılma gerçekleştirdi. Sofwan ve ark. [8] 2019 yılında Doğrusal Tahmin Katsayıları (LPC) kullanarak kalp seslerinin öznitelik çıkartmışlar ve sınıflandırmak için en yakın komşu (k-nn) algoritması kullanarak çalışmayı tamamlamışlardır.

Bu çalışmada veri setini oluşturan A, B ve ikisini birleştirerek elde edilen yeni veri setindeki verilerin normal ve anormal olarak sınıflandırması incelenmiştir. Kalp seslerinin özelliklerinin çıkarılmasında Mel frekans

analizi katsayıları kullanılmıştır. Mel frekans için farklı filtre sayıları, farklı sayıda öznelilik çıkarma yapılarak her bir öz nitelik matrisi sınıflandırması K-NN sınıflandırıcısı kullanılarak incelenmiştir.

II. MATERYAL VE METOD

A. Verilerin Elde Edilmesi

Çalışmamızda Kaggle.com internet sitesinde ücretsiz olarak elde edilen heartbeat-sounds veri seti kullanılmıştır. [9] Veri seti iki kaynaktan toplanmış verilerden oluşmuştur. (A) Pro iphone aracılığı ile genel halktan kaydedilen kalp seslerinden (B) dijital stetoskop kullanılarak hastanelerde yapılan bir klinik denemeden kaydedilmiş kalp seslerinden oluşmuştur. Kalp sesleri normal ve dört farklı anormal kalp seslerinden oluşmuştur. Toplam veri sayısı ve ses grupları sayısı tablo-1 de gösterilmiştir.

Etiket	VeriSet-A	VeriSet-B	A&B
Normal	31	320	351
Anormal	93	141	234

Tablo 1. Veri setindeki Toplam veri sayısı ve ses grupları sayısı

Veri Seti-A toplamda 124 kayıttan oluşmakta, 31 normal ses ve (40 artifact, 19 extrals ve 34 murmur birleştirilmesi ile) 93 adet anormal kalp sesi örneğinden oluşmaktadır. Veri Seti-B için toplamda 461 kayıttan oluşmakta ve bunların 320 adet normal kalp sesi örneği ve (95 murmur ve 46 extrastole örneğin birleştirilmesi ile) 141 adet anormal kalp sesinden oluşmaktadır. Bu çalışmada öncelikle her bir veri seti ayrı ayrı ele alınmış daha sonra iki veri seti birleştirilerek toplamda 585 kayıttan oluşan birleşmiş yeni veri seti incelenmiştir.

B. Mel Frekans Kepstral Katsayıları

Mel frekans kepsral katsayıları ses analizinde en çok kullanılan yöntemlerden birisidir. MFCCs temelini sesi oluşturan özelliklerdir [10-11]. MFCCs ile özellik çıkarmanın katmanları Şekil-1 de gösterilmiştir.



Şekil-1. Mel Frekans Kepstral katsayıları (MFCCs) katmanları

Frekansın birimi Hertz iken Mel frekansında frekans birimi mel'dir [11-12].

$$mel(f) = 259 * \log_{10} \left(1 + \left(\frac{f}{700} \right) \right) \quad (1)$$

Mel güç sepekturumu katsayılarını Y_t $t=1, 2, 3, 4, \dots, T$ ile gösterirsek, mel frekans kepsral katsayıları(c_x) denklem-2 de gösterildiği gibi hesaplayabiliriz [11].

$$c_x(m) = u_m \sum_{T=0}^{T-1} (\log Y_t) \cos \left(\frac{(2t+1)m}{2T} \right) \quad (2)$$

$$u_m = 1/\sqrt{T}; m = 0 \quad (3)$$

$$u_m = \sqrt{\frac{2}{T}}; m > 0 \quad (4)$$

M mel frekans kepsral katsayı indeksini, t mel frekans filtre indeksini, T toplam mel filtre sayısını göstermiştir. Denklem 3 ve Denklem 4 te kullanılan T filtre sayısı 64, 128, 256, 512 ve 1024 değerlerinde tek tek incelenmiştir.

Mel-Frekans Kepstral Katsayıları ile kalp sesi örneklerinden özellik çıkartırken döndürülecek MFCC sayısı 20, 40, 60, 80 ve 120 olarak 5 farklı değerde incelenmiş en iyi durum belirlenmeye çalışılmıştır.

C. Verilerin Normalleştirilmesi

K-nn algoritmasının temeli uzaklık hesaplamaya dayandığı için verilerin sınıflandırırken etkilenmesini azaltmak için verileri belirli bir aralıkta tutmak gerekmektedir. Verilerin istenilen aralıkta tutulması için çeşitli normalleştirme fonksiyonları bulunmaktadır. Bu çalışmada **min-max normalleştirme** kullanılmıştır. Veriler $[-1,1]$ arasında tutulması sağlanmıştır. Min-max normalleştirilmesi kullanılarak veriler 0 ile 1 arasında ya da -1 ile 1 aralığında normalleştirilebilirler. Min-max normalleştirmesinde veri kümesinde bulunan veriler içerisinde en büyük değer ve en küçük değer bulunur ve daha sonra normalleştirme için aşağıdaki denklem-5 ve denklem-6 kullanılmaktadır.

- $[0-1]$ aralığında normalleştirme yapmak için denklem 5 de ki formül kullanılmaktadır.

$$x'_i = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (5)$$

- $[1-1]$ aralığında normalleştirme yapmak için denklem 6 da ki formül kullanılmaktadır.

$$x'_i = \frac{x_i \left(\frac{x_{max} + x_{min}}{2} \right)}{x_i \left(\frac{x_{max} - x_{min}}{2} \right)} \quad (6)$$

D. K-en Yakın Komşu Algoritması

K-En Yakın komşu algoritması 1950'li yılların başında tanımlanmıştır [13]. KNN algoritması ilk başlarda büyük eğitim setlerine verilmiş ve bilgisayarlarda yeterli işlem gücü olmadığı için popülerlik kazanmamıştır. KNN algoritması 1960'lı yıllardan sonra bilgisayarların işlem gücünün artması ile önem kazanmıştır [14].

KNN algoritmasının çalışma yöntemi;

1. Gelen verinin, eğitim setinde bulunan her bir veriye olan uzaklığını belirle,
2. Belirlenen uzaklıkların sıralamasını yap,
3. Sıralanan uzaklıklar arasından en küçük olan k tane değeri al,
4. Alınan k adet değer arasında en çok hangi sınıf tekrar ediyorsa veriyi bu sınıfa ata.

KNN algoritmasında eğitim setinde önceden belirlenen sınıflara göre atama yapıldığı için k değeri büyük önem taşımaktadır. Yeni gelen veri eğitim setindeki farklı sınıflara yakın olabilir. Bu veri k değeri 1 olarak alınırsa en yakın olduğu sınıfa dahil olacakken, k değeri 1'den büyük olarak alındığında yakın olduğu sınıflar arasında en çok olana dahil olacaktır. KNN algoritması uygulanırken farklı uzaklık hesaplama yöntemleri uygulanmaktadır. Kullandığım uzaklık hesaplama yöntemleri Manhattan, Euclidean, Canberra vs. uzaklık ölçüm metrikleri ile mesafeler ölçülür.

E. Performans Ölçütü

Bu çalışmada kaggle.com dan elde edilen Heartbeat-Sounds veri setini oluşturan Dataset-A ve Dataset-B kullanılmıştır [9].

Başarım ölçütü olarak hassasiyet, özgünlük, f1-score ve genel başarımlar olarak 4 farklı başarımlar ölçütü değerlendirilmiştir.

$$hassasiyet = \frac{TP}{TP+FN} \quad (7)$$

$$özgünlük = \frac{TN}{TN+FP} \quad (8)$$

$$f1 = 2 * \frac{hassasiyet * özgünlük}{hassasiyet+özgünlük} \quad (9)$$

$$G.B = \frac{TP+TN}{TN+FN+TP+FP} \quad (10)$$

Hesaplamalarda kullanılan parametreler 7,8,9,10 formüllerinde gösterilmiştir.

Burada TP doğru sınıflandırılmış veri sayısını, TF sınıflandırılmış negatifleri, FP yanlış sınıflandırılmış pozitifleri, FN yanlış sınıflandırılmış negatifleri göstermektedir.

III. SONUÇLAR VE TARTIŞMA

Veri setinde bulunan 2 farklı grup içinde (A ve B) sınıflara ait seslerin adetleri arasında ciddi farklar olduğundan ilk olarak bu çalışmada A grubunda kayıtlı verileri ve B grubunda kayıtlı olan verileri kendi içlerinde ikili sınıflandırma yapılarak incelenmiştir. Her grup kendi içinde sınıflandırılıp sonuçları değerlendirildikten sonra A ve B grubunda ki verileri birleştirip normal ve anormal olarak sınıflandırılma sonuçları incelenmiştir. Normal ve anormal sesler olarak etiketlenen kalp seslerinin özneteliklerini çıkartmak için MFCCs tercih edilmiştir. MFCCs ile öznetelik çıkarmak için döndürülecek Mel kat sayısı 20, 40, 60, 80 ve 120 olarak incelenmiştir. Kalp sesi örnekleri için çıkartılan öznetelik matrisleri sınıflandırılma başarımları incelenmesi için K-nn algoritmasında kullanılmıştır. Çıkartılan öznetelik matrisi sayısının en başarılı sınıflandırma sonuçları tespit edilmeye çalışılmıştır. Her kalp sesi örneği için en anlamlı öznetelik matrislerinin sayısı saptanmaya çalışılmıştır. Sınıflandırma için kullanılan K-en yakın komşu algoritmasında k=2,3,5,9 olmak üzere farklı k değerleri ile farklı uzaklık ölçütü olan Euclidean, Manhattan ve Canberra uzaklık ölçüm yöntemleri ile ayrı ayrı incelenmiş ve karşılaştırılmıştır. Hassasiyet, Özgünlük ve F1-score değerleri incelenen veri seti için elde edilen en iyi K-nn Genel Başarımın elde edildiği parametre de hesaplanmıştır.

Veri seti-A, Veri seti-B, Veri seti-A ve Veri seti-B in birleştirilmesi ile elde edilen yeni veri seti için 20, 40, 60, 80 ve 120 öznetelik değerleri ile k=3, 5, 7, 9 için Euclidean, Manhattan ve Canberra uzaklık ölçüm yöntemleri elde edilen **Genel Başarım** sonuçları sırasıyla Tablo 8,9,10 de gösterilmiştir.

Veri seti-A, Veri seti-B, Veri seti-A ve Veri seti-B in birleşmesiyle elde edilen yeni veri setleri için Genel Başarımları incelenmiş ve her veri seti için elde edilen en iyi Genel Başarım sonuçlarına göre sırasıyla A, B, A&B için hassasiyet, özgünlük ve f1-score değerleri ayrı ayrı hesaplanmış ve Tablo 11 de gösterilmiştir.

Veri Set-A													
Öznitelik Sayısı	K = 3			K = 5			K = 7			K = 9			Ortalama
	E	M	C	E	M	C	E	M	C	E	M	C	
20	72.0	80.0	76.0	68.0	84.0	88.0	64.0	76.0	84.0	68.0	80.0	84.0	77.0
40	72.0	84.0	88.0	80.0	84.0	96.0	64.0	88.0	96.0	64.0	88.0	88.0	82.6
60	72.0	80.0	76.0	68.0	80.0	92.0	64.0	88.0	76.0	64.0	88.0	84.0	77.7
80	72.0	80.0	84.0	68.0	80.0	84.0	64.0	76.0	80.0	64.0	84.0	80.0	76.3
120	72.0	84.0	72.0	72.0	72.0	68.0	64.0	80.0	68.0	64.0	80.0	80.0	73.0
* E : Euclidean Distance, M : Manhattan Distance, C : Canberra Distance													

Tablo.8 Veri seti A için farklı k değerleri için farklı uzaklık metrikleri ve farklı feature sayısı değerlerine göre genel başarımlar sonuçları

Veri Set-B													
Öznitelik Sayısı	K = 3			K = 5			K = 7			K = 9			Ortalama
	E	M	C	E	M	C	E	M	C	E	M	C	
20	67.0	70.0	71.0	71.0	74.0	71.0	72.0	73.0	70.0	71.0	75.0	72.0	71.0
40	68.0	75.0	74.0	71.0	75.0	81.0	67.0	76.0	75.0	68.0	74.0	76.0	73.3
60	67.0	77.0	62.0	71.0	75.0	68.0	68.0	77.0	67.0	68.0	80.0	74.0	71.0
80	67.0	78.0	69.0	71.0	75.0	72.0	68.0	78.0	75.0	68.0	78.0	74.0	72.0
120	67.0	76.0	67.0	70.0	77.0	70.0	68.0	78.0	70.0	68.0	76.0	72.0	71.0
* E : Euclidean Distance, M : Manhattan Distance, C : Canberra Distance													

Tablo.9 Veri seti B için farklı k değerleri için farklı uzaklık metrikleri ve farklı feature sayısı değerlerine göre genel başarımlar sonuçları

Veri Set-A & Veri Set-B													
Öznitelik Sayısı	K = 3			K = 5			K = 7			K = 9			Ortalama
	E	M	C	E	M	C	E	M	C	E	M	C	
20	71.0	71.0	70.0	72.0	70.0	72.0	74.0	74.0	74.0	74.0	77.0	74.0	73.0
40	71.0	74.0	74.0	75.0	75.0	74.0	74.0	79.0	80.0	74.0	82.0	81.0	75.3
60	73.0	71.0	73.0	74.0	74.0	74.0	74.0	79.0	77.0	75.0	78.0	76.0	74.0
80	73.0	68.0	75.0	74.0	74.0	73.0	75.0	79.0	76.0	75.0	75.0	79.0	75.0
120	74.0	66.0	72.0	75.0	74.0	72.0	74.0	78.0	72.0	74.0	77.0	72.0	73.0
* E : Euclidean Distance, M : Manhattan Distance, C : Canberra Distance													

Tablo.10 A ve B birleştirilmesi ile elde edilen yeni veri seti için farklı k değerleri için farklı uzaklık metrikleri ve farklı feature sayısı değerlerine göre genel başarımlar sonuçları

Etiket	Hassasiyet			Özgünlük			f1-score		
	A	B	A&B	A	B	A&B	A	B	A&B
Normal	80.0	84.0	85.0	100.0	92.0	86.0	89.0	88.0	86.0
Anormal	100.0	62.0	77.0	95.0	45.0	75.0	98.0	53.0	76.0
* A: Veri Set-A B: Veri Set-B A&B: Veri Set-A +Veri Set-B									

Tablo 11. Veri setleri için Hassasiyet, Özgünlük ve F1-score değerleri

Kalp seslerinin sınıflandırma sonuçları incelendiğinde kalp sesi örneklerinden en anlamlı olarak 40 özniteliğin çıkartıldığı gözlemlenmiştir. Daha düşük veya daha yüksek sayıda çıkartılacak özniteliklerin başarımlarını etkilemediği yada düşürdüğü gözlemlenmiştir.

Kalp sesi örneklerinden öznitelikleri çıkartılırken uygulanan MFCCs katsayıları için uygulanacak filtre sayıları 64, 128, 256, 512 ve 1024 olarak belirlenmiş ve her bir filtre sayısı uygulanarak çıkartılan öznitelik matrisleri K-nn algoritması ile sınıflandırma başarımları

incelenmiştir. Uygulanacak en iyi filtre sayısının başarımlar üzerinde ki etkisi incelenmiştir.

Veri seti-A, Veri seti-B, Veri seti-A ve Veri seti-B nin birleştirilmesi ile elde edilen yeni veri setleri için MFCCs ile öznitelik matrisi çıkartılırken uygulanacak filtre sayıları 64,128,256,512,1024 olarak belirlenmiş ve çıkartılan öznitelik matrisleri K-nn algoritması ile k=3, 5, 7, 9 için Euclidean, Manhattan ve Canberra uzaklık ölçüm yöntemleri elde edilen **Genel Başarımlar** sonuçları sırasıyla Tablo 12,13,14 de gösterilmiştir.

Veri Set-A													
Filtre Sayısı	K = 3			K = 5			K = 7			K = 9			Ortalama
	E	M	C	E	M	C	E	M	C	E	M	C	
64	68.0	72.0	72.0	68.0	80.0	84.0	72.0	76.0	72.0	68.0	72.0	80.0	73.6
128	68.0	76.0	72.0	68.0	84.0	88.0	68.0	80.0	72.0	64.0	72.0	84.0	74.6
256	72.0	74.0	76.0	76.0	80.0	84.0	64.0	80.0	76.0	72.0	80.0	80.0	76.2
512	68.0	80.0	76.0	72.0	80.0	92.0	64.0	76.0	88.0	72.0	76.0	88.0	77.6
1024	72.0	84.0	88.0	80.0	84.0	96.0	64.0	88.0	96.0	64.0	88.0	88.0	82.6
* E : Euclidean Distance, M : Manhattan Distance, C : Canberra Distance													

Tablo 12. Veri Seti A için farklı k değerleri ve öznitelik çıkartılırken uygulanan farklı filtre sayılarına göre genel başarımlar sonuçları

Veri Set-B													
Filtre Sayısı	K = 3			K = 5			K = 7			K = 9			Ortalama
	E	M	C	E	M	C	E	M	C	E	M	C	
64	66.0	72.0	69.0	69.0	69.0	74.0	64.0	76.0	68.0	68.0	72.0	76.0	70.3
128	67.0	67.0	67.0	71.0	70.0	72.0	68.0	76.0	68.0	64.0	72.0	73.0	69.7
256	67.0	69.0	69.0	68.0	70.0	68.0	64.0	74.0	70.0	72.0	73.0	71.0	69.7
512	68.0	74.0	72.0	76.0	75.0	74.0	68.0	74.0	72.0	72.0	76.0	72.0	72.8
1024	68.0	75.0	74.0	71.0	75.0	81.0	67.0	76.0	75.0	68.0	74.0	76.0	73.3
* E : Euclidean Distance, M : Manhattan Distance, C : Canberra Distance													

Tablo 13. Veri Seti B için farklı k değerleri ve öznitelik çıkartılırken uygulanan farklı filtre sayılarına göre genel başarımlar sonuçları

Veri Set-A & Veri Set-B													
Filtre Sayısı	K = 3			K = 5			K = 7			K = 9			Ortalama
	E	M	C	E	M	C	E	M	C	E	M	C	
64	68.0	70.0	72.0	68.0	70.0	70.0	72.0	74.0	74.0	72.0	72.0	76.0	71.5
128	70.0	72.0	68.0	68.0	72.0	72.0	72.0	76.0	75.0	68.0	74.0	76.0	71.9
256	72.0	71.0	73.0	72.0	74.0	74.0	74.0	76.0	77.0	73.0	74.0	72.0	73.5
512	72.0	68.0	72.0	74.0	74.0	73.0	75.0	76.0	76.0	72.0	77.0	76.0	73.8
1024	71.0	74.0	74.0	75.0	75.0	74.0	74.0	79.0	80.0	74.0	82.0	81.0	75.3
* E : Euclidean Distance, M : Manhattan Distance, C : Canberra Distance													

Tablo 14. Veri seti-A ve Veri seti-B in birleştirilmesi ile elde edilen yeni veri seti için farklı k değerleri ve öznitelik çıkartılırken uygulanan farklı filtre sayılarına göre genel başarımlar sonuçları

MFCCs için uygulanacak filtre sayıları incelendiğinde en iyi genel başarımlar değerleri 1024 filtre uygulanması ile elde edilmiştir.

Mehrez Boulares ve arkadaşları [15] bizim kullanmış olduğumuz verileri kullanarak yaptıkları çalışmada verileri normal ve anormal olmak üzere ikili sınıflandırma ve normal, murmur ve extrastole olarak üç kategoride sınıflandırma yaparak iki farklı şekilde inceleme yapmışlardır. Ses sinyallerinin özelliklerini çıkartmada MFCCs i tercih etmişlerdir. Sınıflandırma içinde CNN algoritması tercih etmişlerdir. Gereksiz ses örneklerini çıkartarak elde ettikleri verileri normal ve anormal olarak incelediklerinde tüm verilerin (351 normal 194 anormal) ikili sınıflandırmasında %77 doğruluk ve %75 hassasiyet elde etmişlerdir. Verileri 194'er örnek olarak dengeleyip yaptıkları ikili sınıflandırmada ise %89 doğruluk elde etmişlerdir. Narváez, P ve arkadaşları [16] bizim de çalışmamızda kullanmakta olduğumuz veri setinde dahil olduğu 6 farklı veri setinden toplamda 805 tane (415 tane normal ve 390 tane anormal olmak üzere) kalp sesi sinyalini normal ve anormal olarak incelemişlerdir. Sinyallerin özelliklerini çıkartmak için MFCC, LPC, DWT, EWT ve POWER gibi yöntemleri karşılaştırmışlardır. Sınıflandırma için ise SVN, KNN, ANN ve RANDOM FOREST sınıflandırıcılarını incelemişlerdir. Ve en iyi sonucu EWT + POWER + KNN olarak incelemişlerdir. 415 normal 390 anormal kalp sesi sinyalinin sınıflandırılmasında %99.25 doğruluk %100 özgünlük ve %98.57 hassasiyet elde etmişlerdir.

Mehrez Boulares ve arkadaşları [15] MFCCs ile kalp sesleri örneklerinden öznitelikleri çıkartırken 1024 filtre uygulamışlardır. Bu çalışmada ses örneklerinin öznitelikleri çıkartılırken uygulanacak filtre sayıları ve

çıkartılacak öznitelik sayıları incelendi. En iyi genel başarımlar sonuçları 40 öznitelik çıkartılması ve 1024 filtre uygulandığında elde edildi. Mehrez Boulares ve arkadaşları [15] 'in tüm verileri (351 normal 194 anormal) normal ve anormal olarak incelediklerinde elde ettikleri doğruluk oranı %77 iken bu çalışmada Data set-A ve Data-set-B in birleştirilmesi ile elde edilen yeni veri seti (351 normal 234 anormal) kalp sesi normal ve anormal olarak sınıflandırma başarımları incelendiğinde %82 Genel başarımlar elde edildi. Veri örneklerinin sayılarının dengeli olduğu bir veri seti üzerinde daha iyi sonuçlar alınacağı düşünüldü.

KAYNAKÇA

- [1] Joyanta Kumar Roy and Tanmay Sinha Roy. 2017. A Simple technique for heart sound detection and real time analysis. IEEE [accessed online on October 30, 2019].
- [2] Garcia G, Moreira G, Menotti D, Luz E (2017) Inter-patient ECG heartbeat classification with temporal VCG optimized by PSO. Sci Rep 7(1):10543.
- [3] N. Andrišević, K. Ejaz, F.R. Gutierrez, R.A. Flores, Detection of heart murmurs using wavelet analysis and artificial neural networks, J. Biomech. Eng. 127 (2005) 899–904.
- [4] C.N. Gupta, R. Palaniappan, S. Swaminathan, S.M. Krishnan, Neural network classification of homomorphic segmented heart sounds, Appl. Soft Comput. 7 (2007) 286–297.
- [5] H. . Uguz, A. Arslan, I. Turkoglu, A biomedical system based on hidden Markov model for diagnosis of the heart valve diseases, Pattern Recogn. Lett. 28 (2007) 395–404.

- [6] Dokur, Z., & Ölmez, T. (2008). Heart sound classification using wavelet transform and incremental self-organizing map. *Digital Signal Processing*, 18(6), 951-959. doi:10.1016/j.dsp.2008.06.001.
- [7] Tez (Yüksek Lisans) -- İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 2002
- [8] Sofwan, A., Santoso, I., Pradipta, H., Arfan, M., & Zahra M, A. A. (2019). Normal and Murmur Heart Sound Classification Using Linear Predictive Coding and k-Nearest Neighbor Methods. 2019 3rd International Conference on Informatics and Computational Sciences (ICICoS). doi:10.1109/icicos48119.2019.8982393
- [9] <https://www.kaggle.com/kinguistics/heartbeat-sounds>
- [10] Banerjee, M., & Majhi, S. (2020). Multi-class Heart Sounds Classification Using 2D-Convolutional Neural Network. 2020 5th International Conference on Computing, Communication and Security (ICCCS). doi:10.1109/icccs49678.2020.9277204
- [11] Fu, W., Yang, X., & Wang, Y. , Heart sound diagnosis based on DTW and MFCC, 3rd International Congress on Image and Signal Processing (CISP2010), 2010, 6(2), 2920–2923.
- [12] Çaycı, Ç. Y., Müzikal Enstrümanların Doğrusal Ayırtaç Analizi Yöntemiyle Ayırt Edilmesi, Yüksek Lisans Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2007.
- [13] O. Cheng, W. Abdulla, and Z. Salcic, "Performance evaluation of front-end algorithms for robust speech recognition," in *Proc. ISSPA*, 2005.
- [14] Sillverman, B. W., vd., An important contribution to nonparametric discriminant analysis and density estimation, *International Statistical Review*, cilt 57, no. 3, pp. 233-247, 1951
- [15] Boulares, Mehrez, Tarik Alafif, and Ahmed Barnawi. "Transfer learning benchmark for cardiovascular disease recognition." *IEEE Access* 8 (2020): 109475-109491.
- [16] Narváez, P., Gutierrez, S., & Percybrooks, W. S. (2020). Automatic Segmentation and Classification of Heart Sounds Using Modified Empirical Wavelet Transform and Power Features. *Applied Sciences*, 10(14), 4791. doi:10.3390/app10144791