

Kalp Atış Seslerinin Derin Öğrenme Kullanarak Sınıflandırılması

Classification of Heartbeat Sounds Using Deep Learning

Gökhan TUTAR¹, Serdar AYDIN²

ÖZ

Kalp hastalığına bağlı ölüm oranları dünyadaki günlük ölüm oranlarında büyük bir yer edinmektedir. Uzun yıllardır doktorlar kalp hastalıklarının teşhisi için ilk olarak hastanın kalp atış sesini dinlemekte ve bu veriye dayalı olarak hastaya ilk tanıyı koymaya çalışmaktadır.

Kalp sesinden hastalık olup olmadığını anlamak tecrübe gerektirdiği için zor bir iştir. Derin öğrenme ile kalp atış sesinin sınıflandırılması da zor bir iştir. Çünkü stetoskop ile alınan seslerde hem akciğer sesi hem de diğer dış ortam sesleri yanlış tanıya neden olabilmektedir.

Bu çalışmada veri kümesi olarak halka açık bir kütüphane olan "Pascal Heart Sound Challenge" kullanılmıştır. Veri kümesinde üç kategori bulunmaktadır. Bunlar; "Normal", "Murmur" ve "Extra-systole" dur.

Bu çalışmada kalp atışı ses sinyalinin hangi sınıfa ait olduğunu yüksek oranda doğru tahmin etmek amaçlanmaktadır.

Anahtar Kelimeler: Derin öğrenme, Kalp atış sesi, CNN, SVM, Sınıflandırma

ABSTRACT

Death rates due to heart disease have a large place in the daily death rates in the world. For many years, doctors have first listened to the patient's heartbeat sound to diagnose heart diseases and have tried to make an initial diagnosis based on this data.

Understanding whether there is a disease from the heart sound is a difficult task because it requires experience. Classifying the heartbeat sound with deep learning is also a difficult task. Because both lung sounds and other external environmental sounds in the sounds taken with a stethoscope can cause misdiagnosis.

In this study, the publicly available library "Pascal Heart Sound Challenge" was used as the dataset. There are three categories in the dataset. These are; "Normal", "Murmur" and "Extra-systole".

In this study, it is aimed to predict the class of the heartbeat sound signal with a high degree of accuracy.

Keywords: Deep learning, Heartbeat sound, CNN, SVM, Classification

¹ Öğr. Gör., Gökhan TUTAR, Yönetim Bilişim Sistemleri, Atatürk Üniversitesi, gokhan@atauni.edu.tr, ORCID: 0000-0002-9851-9067

² Doç. Dr., Serdar AYDIN, Yazılım Mühendisliği, Atatürk Üniversitesi, Mühendislik Fakültesi, serdar@atauni.edu.tr, ORCID: 0000-0003-4943-3272

İletişim / Corresponding Author: Gökhan Tutar
e-posta/e-mail: gokhan@atauni.edu.tr

Geliş Tarihi / Received: 06.11.2022

Kabul Tarihi/Accepted: 21.12.2024

GİRİŞ

Kalp insan vücudunda bulunan diğer organlara kan pompalayan ve yaşam için kritik öneme sahip bir organdır. Normal şartlar altında bir insanın kalbi dakikada 72 kez atar.¹ Günümüzde kalp hastalıkları insan sağlığını tehdit eden en büyük unsurlardan birisidir. Kalp hastalıklarına bağlı ölüm oranları dünyadaki günlük ölüm oranlarında büyük bir yer edinmektedir. Dünya Sağlık Örgütü (WHO), kalp hastalıklarından kaynaklı ölümlerin 2030'da yılda 23,6 milyon ölüme çıkabileceğini öngörerek etkili önleme ve tedavi stratejilerine acil ihtiyaç olduğunu vurgulamaktadır.² Bundan dolayı kalp hastalıklarının erken teşhis etmek hayat kurtarabilir.³

Kalbin mekanik aktivitesiyle oluşan kalp sesleri, çeşitli kalp hastalıklarının tanısında önemli bir rol oynamaktadır. Birincil kalp sesleri olan S1 (birinci kalp sesi) ve S2 (ikinci kalp sesi), sırasıyla kalp kapakların kapanmasına karşılık gelmektedir. Bu sesler genellikle belirgin fazlara ayrılır: sistol ve diyastol; S1 sistolün başlangıcını, S2 ise diyastolün başlangıcını belirtir.⁴⁻⁵ Murmur gibi anormal kalp sesleri, kapak hastalıkları ve yapısal kalp kusurları dâhil olmak üzere çeşitli nedenlerden kaynaklanabilir ve normal kalp sesi örüntüsünden sapan ek seslerle neden olurlar.⁶

Doktorlar hastaların kalp hastalıklarının teşhisi için ilk olarak hastanın kalp atış sesini dinlemekte ve bu veriye dayalı olarak hastaya ilk tanıyı koymaya çalışmaktadırlar. Kalp sesinden hastalık hastalığı teşhis etmek tecrübe gerektirdiği için zor bir işlemdir. Kalp sesini dinleme işlemi, 1816 yılına kadar

doktorların hastanın göğsüne kulaklarını yaklaştırarak gerçekleştirilmekteydi. 1816 yılında Laennec tarafından icat edilen stetoskop kalp sesi dinleme işlemini kısmen kolaylaştırmaktadır.³

Stetoskop cihazı kalp sesi dinleme işlemini kolaylaştırır da kalp sesinden tanı koyma işlemi yine de zordur. Çünkü bu işlem için hem tıp alanından bir eğitim alınması hem de birkaç yıllık klinik tecrübesi gerekmektedir.⁷

Kalp atışında iki farklı ses bulunmaktadır. Bunlar; Lub (S1) ve Dub (S2) sesleridir. Normal bir insanda kalp atışları sırasıyla Lub - Dub, Lub - Dub (S1-S2-S1-S2) şeklinde olmaktadır. Lub için dub süresi dub'dan dub'a kadar olan süreden daha fazladır.⁸

Kalp hastalıklarının belirtileri arasında murmur (hırıltı) ve extra-systole bulunmaktadır. Murmur (hırıltı), kalp atış sesleri arasında bir tür parazit sestir ve kalpten gelir. Yani murmur bir dış ses değildir. Hırıltı birçok kalp hastalığının en belirgin göstergesidir. Extra-systole (kasılma) ise kalp ritmindeki bozukluğu belirtmektedir. Yani normal kalp sesinden farklı olarak Lub - Lub - Dub, Lub - Lub - Dub, Lub - Lub - Dub şeklinde olmaktadır.⁸

Kalp sesleri kalp hastalıklarının teşhisinde hayati bir bileşendir ve kalp fonksiyonu ve sağlığı hakkında temel bilgiler sağlamaktadır. Gelişmiş teknolojilerin sağlık alanıyla entegrasyonu, kalp seslerini analiz etme ve yorumlama yeteneğini önemli ölçüde artırarak, teşhis doğruluğuna katkı sağlamaktadır.

MATERYAL VE METOT

Veri Seti

Çalışmada veri seti olarak açık bir kaynak olan "Pascal Heart Sound Challenge" kullanılmıştır. Bu veri setinde iki farklı veri tabanı bulunmaktadır. Bu veri tabanları Dataset-A ve Dataset-B olarak adlandırılmaktadır. Çalışmada kullanılan Dataset-B veri tabanı dijital stetoskop ile hastanelerdeki klinik çalışmalarda

toplanmıştır. Dataset-B içerisinde toplam 461 ses kaydı bulunmaktadır. Ses kayıtlarının hepsi 4000 hertz frekansındadır. Ses kayıtlarının uzunluğu 1 saniye ile 24 saniye arasında değişiklik göstermektedir.⁴


Aşağıdaki Tablo 1'de Dataset-B'de bulunan verilerin kategori bilgileri ve kategoriye göre ses kayıt sayıları yer almaktadır. Tabloda görülebileceği gibi

“Norman” sınıfındaki ses kayıtlarının sayısı diğer sınıflardan daha fazladır.

Tablo 1. Veri Seti

Kategori	Kayıt Sayısı
Normal	320
Murmur	95
Extra-systole	46

Aşağıdaki Şekil 1’de sırasıyla Extra-systole, Murmur ve Normal kalp seslerinin örnek grafiksel olarak gösterimi bulunmaktadır. Şekilde gösterilen Extra-systole, Murmur ve Normal kalp seslerinin örnekleri gözle ayırt edilebilir şekildedir. Ancak ses örneklerinin hepsi bu şekilde gözle ayırt edilebilir halde değildir.



Şekil 1. Ses Kayıtlarının Grafiksel Gösterimi

İlgili Çalışmalar

Birçok araştırmacı, kalp seslerinin sınıflandırma işlemi için segmentasyon, aşağı örnekleme, özellik çıkarma ve sınıflandırma gibi farklı teknikler kullanmıştır. Bu teknikler kalp hastalığını tahmin etmek için kullanılır. Gomes vd., Shannon kalp atışı sinyalini segmentasyona dönüştürdükleri bir sistem önermektedir, ayrıca bu sistem tepe tespiti için kullanılan bir algoritmadır. Segmentasyondan sonra sınıflandırma modeli J48 ve MLP algoritmasını uygulamaktadırlar. Ancak çok büyük bir başarı yakalayamamışlardır.⁴

Pandey vd., EKG sinyallerinden aritmileri tespit etmek için dalgacık dönüşümü tabanlı bir CNN modeli kullanmış ve farklı kalp ritimlerini kategorize etmede yüksek doğruluk elde etmiştir.⁹ Benzer şekilde, Pandey vd. tarafından yapılan başka bir çalışma CNN’leri çift yönlü uzun kısa süreli bellek (BLSTM) ağlarıyla entegre eden bir hibrit derin öğrenme yaklaşımı kullanarak atriyal fibrilasyonun (AF) otomatik olarak tespit edilmesine odaklanmış ve karmaşık kardiyak durumlar için tanısal doğruluğu iyileştirmede derin öğrenmenin potansiyelini vurgulamıştır.¹⁰

Gomes vd., kalp sesi PASCAL Challenge’i sınıflandırmak için bir yöntem tanımlamaktadır. S1’in Lub ve S2’nin Dub olduğu S1 ve S2 kalp sesini tanımlayan bir algoritma kullanmaktadırlar. Bu algoritma ilk olarak, orijinal ses sinyaline MATLAB’ın sonlandırma fonksiyonunu uygulayarak ses sinyallerindeki gürültüyü gidermek için bir bant geçiren filtre uygulamışlardır. Ardından kalp ses sinyalinin piklerini kolayca tanımlamak için yararlı olan ortalama Shannon enerjisini uygulamışlardır. Kalp atışı sesinin segmentasyonunu başarmak için ses sinyalinin maksimum ve minimum noktalarını buldukları bir algoritma kullanmışlardır. Sonuç olarak ses sinyalini tahmin eden modeli eğitmek için J48 ve MLP algoritmasını kullanmaktadırlar.⁸

Zheng vd., kalp sesindeki anormalliği tespit etmek için yeni bir özellik önermişlerdir. Ses sinyalini normalleştirildikten sonra dalgacık paketi tarafından ayrıştırdılar. 80 normal kalp sesi ve 167 murmur kalp sesinden oluşan küçük bir veri kümesi için SVM uygulamışlardır. Amaçlanan yöntemin performansı, 2 kategoriden oluşan küçük bir veri kümesi nedeniyle göreceli olarak daha iyi performans sergilemektedir.¹¹

Deng ve Han, segmentasyon kullanmadan otomatik korelasyon özelliğine dayanan kalp sesi sınıflandırması için bir çerçeve sunmaktadır. Ayrık Dalgacık ayrışması (DWT) ile kalp sinyalinin alt bant katsayılarından çıkarılan otomatik korelasyon özelliği kullanmışlardır.¹²

Zhang vd., ölçekli spektrogram ve tensör ayrışımı kullanarak kalp atışı ses sınıflandırmasının ayırt edici özelliğini ayıklamak için bir yöntem amaçlamıştır. Spektrogramlar, ayırt edici özelliği çıkarmak için sabit boyutlu kalp döngülerini saptamışlardır. Tensör ayrışması, daha ayırmacı bir özellik elde etmek için boyutu azaltmak amacıyla kullanılır. Daha sonra, bu özneliklere SVM uygulamışlardır.¹³

Son ve Kwon, kalp atışı ses sınıflandırması için çoklu özellik çıkarma tekniklerini kullanmışlardır. Fonokardiyogram (PCG) adı verilen kalp sesinin dijital kaydını almak için

bir elektronik stetoskop cihazı kullanmışlardır. Mel Frekans Cepstral Katsayısı (MFCC) ve Ayrık Dalgacık Dönüşümü (DWT) bu çalışmada kullanılan özütleme teknikleridir. Ayrıca, sonuçları geliştirmek için MFCC ve DWT özelliklerinin çıkarılmasını birleştirmişlerdir. Bu çalışmada SVM, derin sinir ağı ve en yakın komşu (KNN) gibi çeşitli sınıflandırma algoritmaları kullanmışlardır.¹⁴

Ayrıca, tıbbi görüntüleme veri kıtlığı ve yüksek kaliteli açıklamalara duyulan ihtiyaçla ilişkili zorluklar, araştırmacıları veri açısından verimli derin öğrenme sınıflandırıcıları geliştirmeye yöneltmiştir. Madani vd., kalp hastalıklarının teşhisini otomatikleştirmek için veri açısından verimli denetlenen ve yarı denetlenen öğrenme yaklaşımlarının önemini vurgulayarak, geleneksel yöntemlerin getirdiği sınırlamaları ele almışlardır.¹⁵ Bu, etiketli veri kümelerinin kullanılabilirliğinin model performansını önemli ölçüde etkileyebileceği kalp atışı sesi sınıflandırması bağlamında özellikle önemlidir.

Derin öğrenme tekniklerini kullanarak kalp atışı seslerinin sınıflandırılması, kardiyojide tanı doğruluğunu ve hasta bakımını artırmak için büyük umut vadeden, hızla gelişen bir alandır. Derin öğrenmenin geleneksel

yöntemlerle bütünleştirilmesi ve veri açısından verimli modellerin geliştirilmesi, gelecekte daha sağlam ve güvenilir kardiyak teşhislerin önünü açacaktır.

Aşağıdaki Tablo 2.'de Raza vd. tarafından yapılan Dataset-B veri tabanı için kalp atışı ses sınıflandırması sonuçları bulunmaktadır. Çalışmada Dataset-B de bulunan kalp sesleri uzatılarak veya kısaltılarak aynı boyutta olması sağlanmıştır. Çalışmada ses dosyalarının uzunlukları 12,5 ve 27,8 saniyelik iki tane farklı veri seti kullanılmıştır. Tablodan da görülebileceği gibi çalışma sonucunda en büyük başarı RNN ile gerçekleştirilmiştir. Ayrıca Decision Tree haricinde diğer eğitimlerde süresi uzun olan ses dosyalarındaki eğitimlerin daha başarılı sonuç verdiği görülmektedir.

Tablo 2. Önceki çalışmaların sonucu¹⁶

Model	12,5 s(%)	27,8 s(%)
Decision Tree	57,5	48,9
Random Forest	68,3	71,2
Multi Layer Perceptron (MLP 6 Layer)	66,1	67,6
Multi Layer Perceptron (MLP 16 Layer)	67	69
Recurrent Neural Network (RNN)	77,2	80,8

BULGULAR VE TARTIŞMA

Yöntem

Bu çalışmada temelde iki yöntem kullanılarak, Dataset-B deki kalp seslerini doğru sınıflandırma yapılabilmesi amaçlanmıştır. Kullanılacak yöntemler SVM (Support Vector Machine) ve CNN (Convolutional Neural Networks)'dir. SVM zamana dayalı verilerin derin öğrenme ile sınıflandırılmasında sıklıkla kullanılan bir yöntemdir. Ses dosyaları da zamana bağlı bir vektör olduğu için kalp seslerinin sınıflandırmak için kullanılacak ilk metot SVM olacaktır. CNN ise daha çok resim dosyalarının sınıflandırılmasında kullanılan bir metottur. Ses dosyaları spektrograma dönüştürülebilirler. Spektrogramlar ses dalgalarının görsel şekilde sunumudur. Spektrogramlar kullanılarak kalp seslerinin


sınıflandırılmasında CNN yöntemi kullanılabilir.

SVM

SVM sınıflandırıcısı eski ancak etkili olan sınıflandırıcılardan birisidir. Bu sınıflandırıcı başlangıçta iki sınıfı birbirinden ayırmak için kullanılırsa da daha sonraları çoklu sınıfları ayırmada da kullanılmıştır. Bu algoritmanın temelleri Vladimir Vapnik ve Alexey Chervonenkis tarafından atılmıştır. SVM algoritması yüz tanıma sistemlerinden ses analizlerine kadar birçok alanda kullanılmaktadırlar.^{17,18}

SVM öncelikle gelen verinin özneliği boyutunda bir sanal uzay oluşturur. Gelen öz nitelikleri oluşturulan sanal uzaya dağıtmaktadır. Daha sonra bu öz nitelikleri sınıflarına ayırmak için hiper düzlemler

oluşturulur. Aynı uzayda birden fazla hiper düzlem oluşturulabilir. SVM oluşturulabilecek hiper düzlemlerden en geniş aralığa sahip olanı seçmektedir. En geniş aralığa sahip hiper düzlenin seçilmesindeki amaç sınıfların ayrımını daha belirgin olmasıdır. Bundan dolayı aşağıdaki Şekil 2’de sınıfların en uç özneliğine en yakın ve sınıflar arası özneliklere en uzak olan hiper düzlem çizilmiştir.¹⁷



Şekil 2. Support vector machine¹⁷


SVM ses dosyalarının sınıflandırılması için yaygın olarak kullanılmaktadır. Bundan dolayı Dataset-B’deki kalp seslerini sınıflandırmak için ilk önce ses dosyalarının içerikleri hiçbir işlem tabi tutulmadan kullanılmış ve sınıflandırma başarısı %68.75 olarak belirlenmiştir. Dataset-B’de bulunan ses dosyalarının uzunlukları birbirlerinden farklıdır. Yani bir ses dosyasının uzunluğu 1 saniye iken diğer bir ses dosyasının uzunluğu 23 saniyeye kadar uzayabilmektedir. Kısa olan ses dosyalarının sınıflandırmayı kötü yönde etkileyebilmektedir. Bunu engelleyebilmek için bütün ses dosyalarını 50000 frame uzunluğunda sabit tutulmuştur. Bu işlem ses dosyası bittikten sonra devamında aynı verilerin tekrarlanması ile gerçekleştirilmiştir. Yani 1 saniyelik bir ses dosyasının sonuna aynı ses dosyaları eklenerek her bir ses dosyasının uzunluğu 20 saniye olması sağlanmıştır. Bu yöntemle başarı oranı %71.87’ye çıkarılmıştır. Son olarak da matlab programında kullanılan voicebox eklentisi kullanılarak otomatik feature çıkarılarak başarı oranı %73.43’e çıkarılmıştır.

CNN

Evrişimsel Sinir Ağları (CNN’ler), özellikle görüntü sınıflandırma görevleri için derin öğrenme alanında güçlü bir araç olarak ortaya çıkmıştır. İnsan görsel sisteminden esinlenen mimarileri, çoklu evrişimsel filtre katmanları aracılığıyla özellikleri otomatik olarak çıkararak görsel verileri etkili bir şekilde işlemelerine ve analiz etmelerine olanak tanır. Bu yetenek, tıbbi görüntüleme, uzaktan algılama ve nesne algılama dahil olmak üzere çeşitli uygulamalarda önemli gelişmelere yol açmıştır.

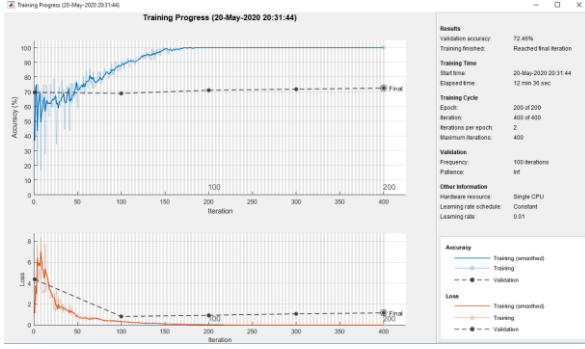
CNN’lerin temel avantajlarından biri, geleneksel makine öğrenimi yaklaşımlarında sıklıkla bir darboğaz olan kapsamlı özellik mühendisliğine olan ihtiyacı azaltma yetenekleridir. CNN’ler hiyerarşik özellik gösterimlerini doğrudan verilerden öğrenir ve bu da görüntü sınıflandırması ve segmentasyon gibi görevlerdeki performanslarını artırır.¹⁹ Liu ve arkadaşları, CNN’lerin mekansal özellikleri çıkarmada üstün olduğunu ve bu sayede çeşitli sınıflandırma görevleri için uygun hale geldiğini ve bu durumun farklı alanlardaki çok yönlülüğünü vurgulamışlardır.²⁰

CNN yöntemi kullanılmadan önce ses dosyaları, matlab programında voicebox tarafından çıkarılan featurelar öncelikle resme dönüştürülmüştür. Ses dosyalarının resme dönüştürülmesi sonucunda ortaya çıkan örnek görüntüler aşağıdaki Şekil 2’de verilmiştir.



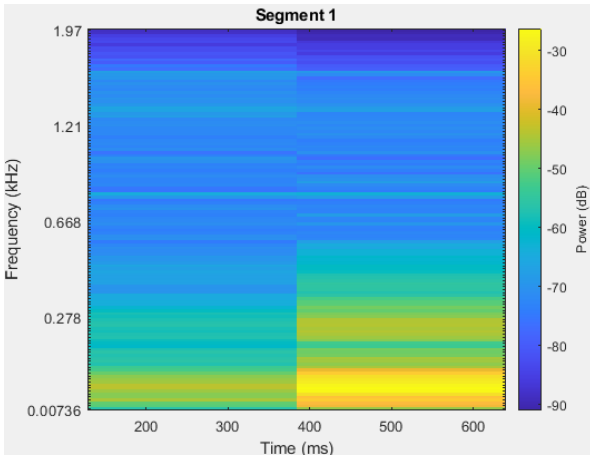
Şekil 2. Ses Kayıtlarının Resim Halindeki Örnek Görüntüleri

CNN ile gerçekleştirilen sınıflandırma işlemi %72.46 başarı oranı elde edilmiştir. Aşağıdaki Şekil 3’te CNN sonucunda elde edilen başarı sonucu gösterilmektedir. CNN’de 200 epoc, 100 iterasyon ve iterasyon başına 2 epoc kullanılmıştır.




Şekil 3. CNN Eğitim Ekran Görüntüsü

CNN'deki başarıyı yükseltmek için; ses dosyalarının uzunluğu 30 saniye uzatılarak, 1024 frame overlap gerçekleştirilmiştir. Feature çıkarma işlemi ise matlab programındaki bir eklenti olan "Audio Toolbox" kullanılmıştır. Bunlara ek olarak ses dosyalarının mel spectrogramları kullanılarak CNN oluşturulmuştur. Aşağıdaki Şekil 4'te örnek mel spectrogramlar resmi gösterilmektedir.



Şekil 4. Mel Spectrogram Örnek Görüntüsü

Aşağıdaki Şekil 5'te ise; CNN'in eğitim sonucunda oluşan ekran görüntüsü verilmiştir. CNN'de 20 epoc kullanılmıştır. Ağ yaklaşık olarak 4.5 saatte oluşturularak %85.42 başarı oranı elde edilmiştir.



Şekil 5. CNN Mel Spectrogram Eğitim Ekran Görüntüsü

Aşağıdaki Şekil 6'da test kayıtlarının doğruluk oranını gösteren confusion chart bulunmaktadır. Bu grafiğe göre CNN ile yapılan son eğitimde test başarı oranı %85.42'dir.

		Test Accuracy - CNN				
		extrastole	murmur	normal		
True Class	extrastole	10		10	50.0%	50.0%
	murmur		22	15	59.5%	40.5%
	normal	2	1	132	97.8%	2.2%
		83.3%	95.7%	84.1%		
		16.7%	4.3%	15.9%		
		extrastole	murmur	normal		

Şekil 6. Confusion Chart

Yukardaki Şekil 6'da de görülebileceği gibi eğitilen CNN ağı, normal kalp sesini diğer (murmur ve extrastole) kalp seslerinde ayırt etmede %98'e yakın bir başarı göstermektedir. Hırıltılı (murmur) kalp sesini diğer (normal ve extrastole) kalp seslerinden ayırt etme başarısı ise %60'a yakındır. Kalp ritim bozukluğu (extrastole) sesini diğer (normal ve murmur) kalp seslerinden ayırmadaki başarı oranı ise %50'dir.

SONUÇ VE ÖNERİLER

Daha önceden gerçekleştirilen farklı çalışmalarda en yüksek başarı oranı %80.8 dir. Bu çalışmada ise en yüksek başarı oranı %85.42 dir. Kalp seslerinin sınıflandırma işleminde en büyük başarıyı mel

spektrogramların CNN yönteminde kullanılmasıyla gerçekleştirilmiştir. CNN ile yapılan son eğitimde test başarı oranı %85.42'dir. Yani sınıflandırma işlemi yaklaşık olarak %5 oranından arttırılmıştır.

Sonuç olarak ağ normal kalp sesini büyük oranda (%97.8) doğru tahmin etmesine rağmen diğer kalp seslerinde (mumur ve extrasystole) kalan %50 lik ihtimalden birini seçmektedir. Bunu en büyük etkenlerinden birisi de eğitim verisinin yaklaşık %70'i normal, %20'si hırıltılı (murmur) geriye kalan %10'luk kısım ise ritim bozukluğu (extrasystole) sesinden oluşmasıdır. Ağ normal kalp sesleri için yeteri kadar eğitilebiliyorken diğer sesler (murmur ve extrasystole) için yeteri kadar eğitilememiştir.

Aşağıdaki Tablo 3'te yapılan çalışmalar sonucunda elde edilen başarı oranları listelenmiştir.

Tablo 3. Eğitilen Modellerin Başarı Oranları

Model	Başarı Oranı (%)
SVM	68,75
SVM (Ses dosyalarının süresi uzatılmış hali)	71,87
SVM (Voicebox feature)	73,43
CNN (Voicebox feature)	72,46
CNN (Mel Spectrogram 30sn)	85,42

KAYNAKLAR

1. Somers VK, Dyken ME, Clary MP, et al. "Sympathetic neural mechanisms in obstructive sleep apnea". *J Clin Invest* 1995; 96: 1897–1904.
2. Cibo M, Brigic L, Tukulija S, et al. "Management and Invasive Cardiological Review by Comparison of Percutaneous Coronary Intervention in Left Anterior Descending Artery with Drug Eluting and Bare Metal Stents". *Acta Informatica Medica* 2018; 26: 130.
3. Hanna IR, Silverman ME. "A history of cardiac auscultation and some of its contributors". *Am J Cardiol* 2002; 90: 259–267.
4. Gomes EF, Bentley PJ, Pereira E, et al. "Classifying Heart Sounds-Approaches to the PASCAL Challenge". *Healthinf* 2013; 2013: 337–340.
5. Busono P, Karim S, Kamaruddin A, et al. "Heart Sound Signal Analysis for Digital Auscultation". *J Phys Conf Ser* 2022; 2377: 12024.
6. Kumar D, Carvalho P, Antunes M, et al. "Heart Murmur Classification With Feature Selection". Epub ahead of print 2010. DOI: 10.1109/iembs.2010.5625940.
7. Jiang Z, Choi S. "A cardiac sound characteristic waveform method for in-home heart disorder monitoring with electric stethoscope". *Expert Syst Appl* 2006; 31: 286–298.
8. Gomes EF, Pereira E. "Classifying heart sounds using peak location for segmentation and feature construction". In: *Workshop Classifying Heart Sounds*. 2012, pp. 480–492.
9. Pandey SK, Shukla A, Bhatia S, et al. "Detection of Arrhythmia Heartbeats From ECG Signal Using Wavelet Transform-Based CNN Model". *International Journal of Computational Intelligence Systems*. Epub ahead of print 2023. DOI: 10.1007/s44196-023-00256-z.
10. Pandey SK, Kumar G, Shukla S, et al. "Automatic Detection of Atrial Fibrillation From ECG Signal Using Hybrid Deep Learning Techniques". *Journal of Sensors*. Epub ahead of print 2022. DOI: 10.1155/2022/6732150.
11. Zheng Y, Guo X, Ding X. "A novel hybrid energy fraction and entropy-based approach for systolic heart murmurs identification". *Expert Syst Appl* 2015; 42: 2710–2721.
12. Deng S-W, Han J-Q. "Towards heart sound classification without segmentation via autocorrelation feature and diffusion maps". *Future Generation Computer Systems* 2016; 60: 13–21.
13. Zhang W, Han J, Deng S. "Heart sound classification based on scaled spectrogram and tensor decomposition". *Expert Syst Appl* 2017; 84: 220–231.
14. Yaseen, Son G-Y, Kwon S. "Classification of Heart Sound Signal Using Multiple Features". *Applied Sciences* 2018; 8: 2344.
15. Madani A, Ong JR, Tibrewal A, et al. "Deep Echocardiography: Data-Efficient Supervised and Semi-Supervised Deep Learning Towards Automated Diagnosis of Cardiac Disease". *NPJ Digital Medicine*. Epub ahead of print 2018. DOI: 10.1038/s41746-018-0065-x.
16. Raza A, Mehmood A, Ullah S, et al. "Heartbeat Sound Signal Classification Using Deep Learning". *Sensors* 2019, Vol 19, Page 4819 2019; 19: 4819.
17. Cortes C. "Support-Vector Networks". *Mach Learn*.
18. Schölkopf B. "SVMs - A practical consequence of learning theory". *IEEE Intelligent Systems and Their Applications* 1998; 13: 18–21.
19. Li F, Li X, Wang F, et al. "A Novel P300 Classification Algorithm Based on a Principal Component Analysis-Convolutional Neural Network". *Applied Sciences*. Epub ahead of print 2020. DOI: 10.3390/app10041546.
20. Liu Q, Liu B, Du Y. "An Algorithm to Improve the Performance of Convolutional Neural Networks for TSC Tasks". *Engineering Reports*. Epub ahead of print 2022. DOI: 10.1002/eng2.12589.