



HARRAN ÜNİVERSİTESİ MÜHENDİSLİK DERGİSİ

HARRAN UNIVERSITY JOURNAL of ENGINEERING

e-ISSN: 2528-8733 (ONLINE)

Derin Öğrenme ve Chroma Spektrogramlarına Dayalı EKG Sinyallerinin Sınıflandırılması

Classification of ECG Signals Based on Deep Learning and Chroma Spectrograms

Yazar(lar) (Author(s)): Songül AKDAĞ¹, Mehmet Bilal ER²

¹ ORCID ID: 0000-0003-2278-4232

² ORCID ID: 0000-0002-2074-1776

Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article): Akdağ S., Er M.B., "Derin Öğrenme ve Chroma Spektrogramlarına Dayalı EKG Sinyallerinin Sınıflandırılması", ***Harran Üniversitesi Mühendislik Dergisi***, 9(3): 164-175, (2024).

DOI: 10.46578/humder.1540437



Derin Öğrenme ve Chroma Spektrogramlarına Dayalı EKG Sinyallerinin Sınıflandırılması

Songül AKDAĞ^{1,*}, Mehmet Bilal ER²

¹Harran Üniversitesi, Mühendislik Fakültesi, Yazılım Mühendisliği Bölümü, 63050, Haliliye /ŞANLIURFA

²Harran Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 63050, Haliliye /ŞANLIURFA

Öz

Elektrokardiyografi (EKG), kalbin elektriksel aktivitesini izleyerek ritim ve fonksiyon bozukluklarını tespit etmekte kullanılan, invazif olmayan bir tanı yöntemidir. EKG sinyalleri genellikle düşük genlikli ve karmaşık yapıda olup, bu sinyallerdeki küçük değişiklikler gözle fark edilemeyebilir. Aritmiler, her zaman ciddi olmasa da, kalp hastalığı semptomlarına ve potansiyel olarak tehlikeli durumlara yol açabilir. Yapay zeka, EKG verilerini analiz ederek bu tür kalp hastalıklarının daha hızlı ve doğru bir şekilde tespit edilmesine olanak sağlar, böylece klinik kararların desteklenmesine katkıda bulunur. Bu çalışmada, PhysioNet/CinC Challenge 2016 veri seti kullanılarak, Chroma spektrogramları oluşturulmuş ve bu veriler üzerinde altı farklı önceden eğitilmiş ağ modeli test edilmiştir. Modeller, üç farklı doğrulama yöntemi ve altı farklı sınıflandırıcı ile değerlendirilmiştir. Sonuçlar, MobileNet V2 modeli ile Q-DVM sınıflandırıcısının en iyi performansı sergilediğini göstermiştir. Modelimiz, doğruluk (%87,6), duyarlılık (%96,1), kesinlik (%88,9) ve F1 skoru (%92,4) açısından güçlü ve iyi bir performans sergilemiştir.

Classification of ECG Signals Based on Deep Learning and Chroma Spectrograms

Makale Bilgisi

Başvuru: 29/08/2024

Yayın: 31/12/2024

Anahtar Kelimeler

Derin Öğrenme, EKG, Ses ve Sinyal İşleme, Sınıflandırma, Transfer Öğrenme

Keywords

Deep Learning, ECG, Audio and Signal Processing, Classification, Transfer Learning.

Abstract

Electrocardiography (ECG) is a non-invasive diagnostic method used to detect rhythm and function disorders by monitoring the heart's electrical activity. ECG signals, typically low in amplitude and complex, may exhibit subtle changes that are not easily visible. Although arrhythmias are not always severe, they can signal heart disease and lead to dangerous conditions. Artificial intelligence aids in quicker, more accurate detection of heart diseases through ECG data analysis, thus supporting clinical decisions. In this study, Chroma spectrograms were generated using the PhysioNet/CinC Challenge 2016 dataset, and six pre-trained network models were tested. These models were evaluated with three validation methods and six classifiers. The MobileNet V2 model and Q-SVM classifier performed the best, with strong results in accuracy (87.6%), sensitivity (96.1%), precision (88.9%), and F1 score (92.4%).


1. GİRİŞ (INTRODUCTION)

Kardiyovasküler hastalıklar, dünya genelinde en yaygın ölüm nedenleri arasında yer alır, bu nedenle erken teşhis hayati önem taşır. Elektrokardiyografi (EKG), kalbin elektriksel aktivitesini kaydeden ve vücudun farklı noktalarına yerleştirilen elektrotlarla bu aktiviteyi izleyen bir tekniktir. Kaydedilen voltaj-zaman grafiği, kalp fonksiyonlarını analiz etmek için gerekli temel bilgileri sağlar ve kardiyologlar tarafından çeşitli hastalıkları tespit etmek için sıkça kullanılır [1].

EKG'deki bir dalganın ayrıntısı Şekil 1'de gösterilmiştir. Kalbin bir atımı süresince oluşan elektrik dalgalarıdır. EKG nin temel bileşenleri P Dalgası, QRS kompleksi, T dalgasıdır. Bu dalgalar P, Q, R, S, T

*İletişim yazarı, e-mail: songul.akdag1995@gmail.com

dalgalarından ve çeşitli aralıklardan (PR intervali, QT intervali gibi) oluşur. P dalgası atriyal yani kalp kulakçıklarını temsil ederek kalbin sağ ve sol atriyumlarının kasılmasını sağlar. QRS Kompleksi, ventriküller (karıncıklar) yani kalp karıncıklarının temsil ederek ventriküllerin kasılmasını sağlar. T Dalgası, ventriküllerin repolarizasyonunu yani yeniden yüklenmesine karşılık gelir. Bu dalgaların şekillerini ve belirli aralıkların uzunluklarını inceleyerek kalpteki elektriksel olaylar hakkında bilgi edinilmektedir [2].



Şekil 1. Örnek Bir EKG Dalgası [2]

Elektrokardiyografi (EKG) sinyalleri, kalp ritim bozuklukları, kalp krizi ve elektrolit dengesizlikler gibi ciddi kalp rahatsızlıklarının erken teşhisinde hayati öneme sahiptir. Özellikle bazı aritmi türleri, ani ölümlere yol açarak her yıl dünya genelinde milyonlarca insanın hayatını kaybetmesine neden olmaktadır [3,4]. Yapay zeka ve derin öğrenme, EKG analizi ve kalp hastalıklarının teşhisinde geleneksel yöntemlere kıyasla daha hızlı ve doğru sonuçlar sunarak önemli ilerlemeler sağlamıştır [5,6].

Son yıllarda teknolojinin ilerlemesiyle beraber yapay zeka ve derin öğrenme, birçok alanda olduğu gibi sağlık alanında da kullanılmaktadır. Derin öğrenme yöntemleri, çok katmanlı yapıları sayesinde EKG sinyallerini etkili bir şekilde analiz ederek aritmi tespiti ve EKG sinyallerinin sınıflandırılmasında yüksek doğruluk oranlarına ulaşmıştır [7]. Farklı makine öğrenmesi teknikleri ve derin öğrenmedeki yaklaşımlar kullanılarak EKG sinyallerinin sınıflandırılması, aritmi analizleri ve kalp hastalıkları teşhisi gibi konularda çalışmalar yapılmaktadır. Özellikle, AlexNet ve VGG-16 gibi önceden eğitilmiş derin öğrenme modelleri kullanılarak elde edilen transfer öğrenme yaklaşımları, veri ihtiyacını azaltarak daha az veriyle daha yüksek doğruluk elde edilmesini sağlamakta ve eğitim sürelerini optimize etmektedir [6][8-9].

Son yıllarda yapılan araştırmalar, derin öğrenme modellerinin EKG sinyallerinde aritmi tespitinde etkili olduğunu ve bu modellerin kardiyologlara teşhis süreçlerinde yardımcı olabilecek yazılımlar geliştirilmesinde kullanılabileceğini göstermektedir. EKG sinyallerinin sınıflandırılmasında kullanılan bu yaklaşımlar, kardiyovasküler hastalıkların erken teşhisinde büyük bir potansiyele sahiptir ve bu sayede tedavi süreçlerinde önemli iyileşmeler sağlanabilir [3-4].

Bu çalışmada, EKG sinyalleri chroma spektrogramlarına dönüştürülerek görsel olarak temsil edilmiştir. Aritmi tespiti amacıyla, InceptionNet V3, GoogleNet, MobileNet V2, EfficientNet, AlexNet ve ResNet-50 gibi derin öğrenme algoritmaları incelenmiştir. Çalışmada, öncelikle EKG sinyallerine veri ön işleme uygulanmış, ardından bu sinyallerden çıkarılan özellikler, L-DVM, Q-DVM, C-DVM, K-NN, TA ve LR gibi çeşitli sınıflandırıcılar kullanılarak performans açısından değerlendirilmiştir.

Ancak, önerilen yöntemin bazı sınırlamaları da dikkate alınmalıdır. Chroma spektrogramlarının kullanımı, frekans ve harmonik bilgileri zenginleştirirken sinyallerin diğer bazı özelliklerinin geri planda kalmasına neden olabilir. Buna rağmen, bu durum genel model performansını olumsuz etkilememiş ve elde edilen sonuçlar oldukça başarılı olmuştur. Ayrıca, modern derin öğrenme ağları yüksek hesaplama gücü gerektirse de, bu çalışmada kullanılan veri seti bu gereksinimi karşılamış ve yöntemimizin doğruluk oranlarını artırmada etkili olmuştur. Özellikle transfer öğrenmenin kullanılması, daha az veriyle yüksek performans elde etmemizi sağlamış ve eğitim sürelerini optimize etmiştir. Gelecekte, yöntemin farklı veri setleri ve senaryolar üzerindeki performansını değerlendirmek, yöntemin genellenebilirliğini ve esnekliğini daha da artırabilir.

Önerilen yöntem, EKG sinyallerinin analizi konusunda literatüre, Chroma spektrogramlarının ve transfer öğrenme tekniklerinin etkin kullanımıyla, biyomedikal veri analizi için yeni bir yaklaşım sunarak değerli bir katkı sunmaktadır.

2. LİTERATÜR TARAMASI (LITERATURE REVIEW)

Clifford ve arkadaşlarının çalışmasında, kısa ve tek kanallı EKG kayıtlarından atriyal fibrilasyon (AF) sınıflandırmasını otomatik olarak gerçekleştirebilecek bir algoritma geliştirilmesi hedeflenmiştir. EKG sinyalleri dört kategoriye ayrılmış ve toplamda 12,186 EKG kaydı kullanılmıştır. Bu kayıtlardan 8,528'i eğitim seti, 3,658'i ise test seti olarak ayrılmıştır. Çalışmada Random Forest, CNN, RNN gibi yöntemler kullanılmış ve 75 yarışmacı katılmıştır. Sonuç olarak, 0.83 F1 puanı ile dört yarışmacı yarışmayı kazanmış ve en başarılı algoritmanın AF'yi tanımlamada en yüksek doğruluk ve güvenilirliği sağladığı belirlenmiştir. Bu çalışma, EKG analiz sistemlerinin geliştirilmesine önemli katkılar sağlamıştır [10].

Benzer bir yaklaşımla, Liang ve arkadaşları, kalp atışını doğru ve verimli bir şekilde sınıflandırmak için iki yöntem kullanmışlardır. İlk yöntemde genetik algoritma (GA) ve makine öğrenimini birleştiren evrimsel bir sinir sistemi yaklaşımı uygulanırken, ikinci yöntemde Evrimsel Sinir Ağı (CNN) ile Çift Yönlü Uzun Kısa Süreli Bellek (BiLSTM) ağı (CNN-BiLSTM) birleştirilmiştir. İlk yöntem, normal sinüs ritmi, AF ve supraventriküler taşiaritmi gibi durumları saptamada üstün performans gösterirken, ikinci yöntem PAC, atriyal flutter ve ventriküler bigemini gibi durumları saptamada üstünlük sağlamıştır. Farklı veri kümeleri üzerinde %80, %82.6 ve %85 doğruluk oranlarına ulaşılmıştır [11].

Bu çalışmaları takip eden Śmigiel ve arkadaşları, PTB-XL veritabanını kullanarak birincil EKG sinyallerinin otomatik sınıflandırılması için üç farklı ağ mimarisi geliştirmişlerdir. Konvolüsyonel ağ, SincNet ağı ve entropi tabanlı özelliklere sahip bir konvolüsyonel ağ gibi farklı mimariler kullanılmıştır. Elde edilen sonuçlar, entropi özellikli konvolüsyonel ağın iki sınıf için %89.82 ve beş sınıf için %76.5 doğrulukla diğer ağlardan daha iyi performans gösterdiğini ortaya koymuştur [12].

Benzer bir şekilde, Er'in çalışmasında, EKG sinyallerinin sınıflandırılması için PASCAL ve PhysioNet 2016 veri setleri kullanılmış ve 1D Yerel İkili Örüntü (1D-LBP) ile 1D Yerel Üçlü Örüntü (1D-LTP) teknikleriyle özellik çıkarımı yapılmıştır. ReliefF algoritmasıyla seçilen en önemli özellikler, Tek Boyutlu Evrimsel Sinir Ağı (1D-CNN) modelinde sınıflandırılmış ve PASCAL veri kümesinde %91.66, PhysioNet 2016 veri kümesinde ise %91.78 doğruluk elde edilmiştir [13].

Son olarak, Sattar ve arkadaşları, sayısallaştırılmış CPEIC kardiyak veri seti üzerinde makine öğrenimi ve derin öğrenme teknikleri kullanarak EKG sınıflandırması yapmışlardır. Bu çalışmada, EKG görüntülerinin zaman serisi sinyallerine dönüştürülmesi ve kardiyak sınıfların doğru sınıflandırılması için CNN, LSTM ağı ve oto kodlayıcılarla desteklenen bir SSL tabanlı model kullanılmıştır. CNN modeli, yaklaşık %92 doğruluk oranı ile en yüksek performansı göstermiştir [14].


Bu çalışmalar, farklı yöntemlerin EKG sinyallerinin sınıflandırılmasında nasıl kullanıldığını ve hangi yaklaşımların hangi koşullarda üstünlük sağladığını ortaya koymaktadır. Literatürde, EKG sinyallerinin analizleri için çeşitli veri ön işleme yöntemleri ve modelleri kullanılarak birçok araştırma yapılmıştır. Bu analizler, kardiyovasküler sorunların çözümüne yönelik önemli adımlar atılmasını sağlamıştır. Bu çalışmada biz de, PhysioNet/Computing in Cardiology Challenge 2016 veri setini kullanarak, EKG sinyallerinin iki farklı sınıfa ait veri sınıflandırmasını gerçekleştirdik. Sınıflandırma işlemi için Inception Net V3, Google Net, Mobile Net V2, EfficientNet, AlexNet ve ResNet-50 gibi modellerle özellik çıkarımı yapılmış ve bu modeller kullanılarak sınıflandırma gerçekleştirilmiştir.

3. MATERYAL VE METOD (MATERIAL AND METHOD)

Bu çalışmada, PhysioNet/CinC Challenge 2016 veri setindeki EKG sinyalleri, frekans bileşenlerini 12 müzikal nota sınıfına indirgemek suretiyle zaman içinde harmonik yapı analizi yapmayı sağlayan Chroma spektrogramlarına dönüştürülmüş ve elde edilen veriler, transfer öğrenme yöntemleri ile az miktarda veriyle hızlı ve etkili şekilde eğitilmiştir. Transfer öğrenmenin, EKG sinyallerinden aritmi tespitinde kullanılması,

veri ihtiyacını azaltarak daha az veriyle daha yüksek doğruluk elde etmemizi sağlamaktadır. Ayrıca, sıfırdan model eğitimi yerine önceden eğitilmiş modellerin kullanılması, eğitim süresini optimize etmektedir. Çalışmada, bu modellerin EKG verilerindeki karmaşık ve ince özellikleri yakalama yetenekleri nedeniyle transfer öğrenme mimarilerinden en yaygın kullanılan InceptionNet V3, GoogLeNet, MobileNet V2, EfficientNet, AlexNet ve ResNet-50 modelleri kullanılmıştır. Bu modeller, EKG sinyallerinin özelliklerini en iyi şekilde öğrenmek üzere optimize edilmiştir ve elde edilen bu özellikler, daha sonra sınıflandırıcı algoritmalara aktarılmıştır. Model performansını değerlendirmek amacıyla 10 kat çapraz doğrulama ile birlikte %70-30 ve %80-20 eğitim/test oranları kullanılarak elde edilen sonuçlar karşılaştırılmıştır.

Sınıflandırma aşamasında, altı farklı sınıflandırıcı kullanılmıştır: Lineer Destek Vektör Makineleri (L-DVM), Kuadratik Destek Vektör Makineleri (Q-DVM), Kübik Destek Vektör Makineleri (C-DVM), K-En Yakın Komşu (K-NN), Torbalanmış Ağaçlar (TA) ve Lojistik Regresyon (LR). Bu sınıflandırıcılar, transfer öğrenme ile elde edilen özelliklerin en iyi şekilde değerlendirilmesini sağlamak amacıyla kullanılmıştır. Önerilen yöntemin genel akışını gösteren diyagram ise Şekil 2'de sunulmuştur.



Şekil 2. Önerilen Yöntemin Akış Diyagramı.

Önerilen yöntemde, öğrenme katsayısı, epok sayısı ve batch size gibi hiperparametreler, modelin performansını optimize etmek amacıyla dikkatlice seçilmiştir. MATLAB'da 10 kat çapraz doğrulama yöntemiyle model performansı değerlendirilmiş, her adımda veri seti 10 farklı alt kümeye bölünerek eğitim ve test işlemleri gerçekleştirilmiştir. Ayrıca, %70-30 ve %80-20 eğitim/test oranlarında da tahmin performansı analiz edilmiştir. Öğrenme katsayısı olarak 0.001, epok sayısı olarak 100 ve batch size olarak 64 değerleri kullanılarak, modelin doğruluğu ve eğitim süresi optimize edilmiştir.

3.1. Veri Seti

Bu çalışmada The PhysioNet/Computing in Cardiology Challenge (CinC) 2016 veri seti kullanılmıştır. PhysioNet/CinC Challenge 2016 veri seti kalp seslerini içeren çeşitli kalp ses kayıtlarından oluşmakta olup halka açık veri setidir. Toplamda 1.072 denekten alınan 233.512 adet kayıt bulunmaktadır. Kayıtların süreleri birkaç saniye ile birkaç dakika arasında değişiklik göstermektedir. Kayıtlar normal, anormal veya değerlendirilmesi mümkün olmayan (gürültülü/belirsiz) olarak sınıflandırmak için kullanılır [15].

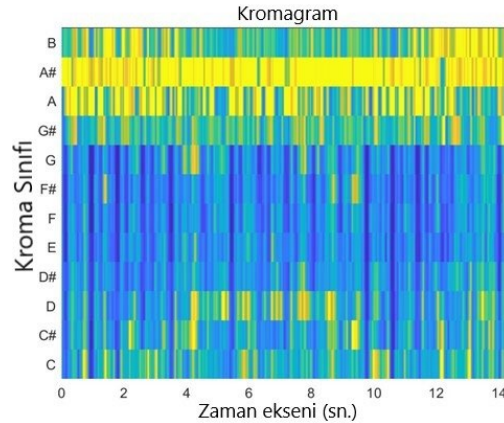
Veri setinin içeriğinde bulunan veri tabanları içerisindeki veri sayıları Şekil 3'de verilmiştir.

VERİ SETİ		
Veri	Normal	Anormal
Training-a	117	292
Training-b	386	104
Training-c	7	24
Training-d	27	28
Training-e	1958	183
Training-f	80	34
Toplam	2578	665

Şekil 3. PhysioNet/CinC Challenge 2016 Veri Seti

Bu çalışma, MATLAB R2023a kullanılarak geliştirilmiştir ve PhysioNet/CinC Challenge 2016 veri seti kullanılmıştır. Veri seti, Training-a, Training-b, Training-c, Training-d, Training-e ve Training-f olmak üzere altı farklı sınıfa ayrılmış toplam 3240 veriden oluşmaktadır. Her veri seti, normal ve anormal olmak üzere iki sınıfa ayrılmıştır. Çalışmada, 2380 normal ve 665 anormal veri olmak üzere toplamda 3045 veri kullanılmıştır.

PhysioNet/CinC Challenge 2016 veri setinde bulunan EKG ses sinyalleri MATLAB R2023a kullanılarak okundu ve bu sinyallerin Chroma spektrogramları elde edilerek görsel formata dönüştürüldü. 00009 numaralı hastaya ait EKG ses sinyalinin Chroma spektrogram örneği Şekil 4’de gösterilmiştir.



Şekil 4. 00009 Numaralı Ses Sinyalinin Chroma Spektrogramı

4. BULGULAR VE TARTIŞMA (FINDINGS AND DISCUSSION)

Bu çalışmada, derin öğrenme teknikleri kullanılarak EKG verilerinin sınıflandırılması gerçekleştirilmektedir. Bu amaçla, Transfer Öğrenme yöntemi uygulanarak MATLAB ortamında EKG sinyallerinden Chroma spektrogramları elde edilmektedir. Elde edilen Chroma spektrogramları, iki sınıfa ayrılmış verileri temsil etmektedir: normal ve anormal (aritmi). Elde edilen spektrogramlardan özellik çıkarımı; InceptionNet V3, GoogleNet, MobileNet V2, EfficientNet, AlexNet ve ResNet-50 gibi çeşitli transfer öğrenme modelleri kullanılarak yapılmaktadır. Her biri için ayrı ayrı özellikler çıkarıldı. Bu sayede, EKG sinyallerinin doğru bir şekilde sınıflandırılabilmesi amacıyla transfer öğrenme modellerinden elde edilen anlamlı özellikler kullanılmaktadır.

Her bir model için elde edilen öznelilikler, sınıflandırma işlemini gerçekleştirmek amacıyla transfer öğrenme modellerinin tam bağlı (fully connected, FC) katmanından çıkarılmıştır. Bu özellikler, EKG sinyallerinin frekans ve zamansal yapılarını en iyi şekilde temsil etmek için özenle seçilmiştir ve sinyaldeki

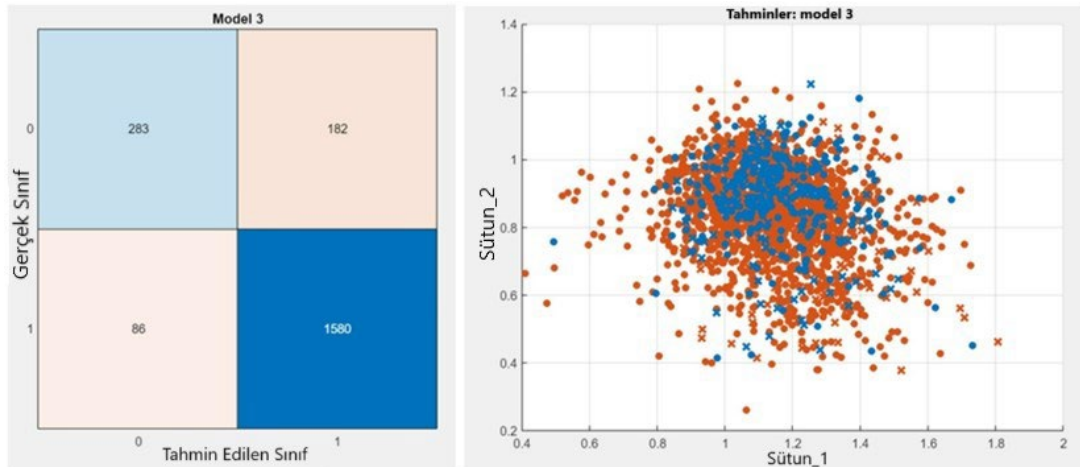
ince farklılıkları ayırt etmede önemli rol oynamaktadır. Bu katmanda elde edilen özellikler, çalışmada kullandığımız sınıflandırma algoritmalarına girdi olarak kullanılmak üzere veriyi 10 kat çapraz doğrulama, %70 eğitim - %30 test ve %80 eğitim - %20 test veri bölünmeleri ile test edilmiştir. Çapraz doğrulama, modelin genel performansını artırmak ve aşırı öğrenme riskini azaltmak için kritik bir strateji olarak tercih edilmiştir.

Inception V3, GoogleNet, MobileNet V2, EfficientNet, AlexNet ve ResNet-50 modellerine ait 10 katlı çapraz doğrulama ile sınıflandırma performansları Tablo 1’de gösterilmiştir. 10 katlı çapraz doğrulamada, %87.4 doğruluk ile en iyi sonucu EfficientNet modelinde Q-SVM sınıflandırıcısından elde edilmiştir. EfficientNet’in bu performansı, parametre sayısını optimize ederken modelin kapasitesini maksimize etme stratejisine dayanmaktadır. Sınıflandırıcı performansları değerlendirildiğinde ise en iyi sonucun Q-SVM ile alındığı gözlemlenmiştir. Q-SVM’in yüksek genelleme yeteneği, özellikle küçük veri kümeleriyle çalışırken büyük avantaj sağlamış ve bu sınıflandırıcının diğerlerine göre üstün olmasına yol açmıştır.

Tablo 1. 10- kat Çapraz Doğrulama Sonuçları

Metod	Performans Değerleri					
	InceptionNet V3	GoogLeNet	MobileNet V2	EfficientNet	AlexNet	ResNet 50
L-DVM	% 84	%84.9	%84.8	%86.7	%85.3	%85.3
Q-DVM	%84.5	%85.8	%86.4	%87.4	%86.9	%87.2
C-DVM	%83.4	%83.2	%86	%86.4	%85.9	%86.3
K-NN	%81.4	%82.6	%84.1	%85.1	%84.4	%84.6
TA	%81.3	%82.7	%84	%84.8	%83.5	%83.9
LR	%81.7	%81.9	%84.1	%84.6	%84.2	%83.8

10 katlı çapraz doğrulamada, %87.4 doğruluk ile en iyi sonucu EfficientNet modelinde Q-DVM sınıflandırıcısından elde edilmiştir (Şekil 5).



Şekil 5. EfficientNet - Q-DVM Modeline Ait Karışıklık Matrisi ve Dağılım Grafiği


Inception V3, GoogleNet, MobileNet V2, EfficientNet, AlexNet ve ResNet-50 modellerine ait %70-%30 eğitim ve test verisi için sınıflandırma performansları Tablo 2’de gösterilmiştir. %70-%30 veri ayırımında gerçekleştirilen deneylerde, %87.5 doğruluk oranı ile en iyi sonuç EfficientNet modelinde Q-SVM sınıflandırıcısı kullanılarak elde edilmiştir. Bu sonuç, modelin yüksek performans gösterdiğini ve özellikle Q-SVM sınıflandırıcısının etkili bir şekilde çalıştığını ortaya koymaktadır. Sınıflandırıcı performansları genel olarak değerlendirildiğinde, Q-SVM’in diğer sınıflandırıcılara göre daha başarılı olduğu

gözlemlenmiştir. Bu deneyin ardından, MobileNet modelinde C-SVM sınıflandırıcısı kullanılarak %87.3 doğruluk oranı elde edilmiştir. MobileNet ve C-SVM kombinasyonu, yüksek bir performans sergilemiş ancak Q-SVM ve EfficientNet çiftinin gerisinde kalmıştır. Bu sonuçlar, farklı modeller ve sınıflandırıcılar arasında yapılan karşılaştırmalarda, Q-SVM'in genelde daha iyi performans gösterdiğini ortaya koymaktadır.

Tablo 2. Eğitim ve Test Veri Seti için Doğrulama Sonuçları (%70 Eğitim - %30 Test Ayrımı)

Metod	Performans Değerleri				AlexNet	ResNet 50
	InceptionNet V3	GoogLeNet	MobileNet V2	EfficientNet		
L-DVM	%83.6	%85.6	%85	%86.7	%82.8	%84.3
Q-DVM	%84.7	%84.2	%86.7	%87.5	%85.1	%84.9
C-DVM	%83.7	%81.1	%87.3	%85	%84.7	%82.6
K-NN	%81.2	%80.06	%83.4	%83.4	%83.4	%84.1
TA	%79.2	%80.04	%82.5	%83.1	%83.4	%82.9
LR	%80.9	%81.5	%83.3	%82.5	%83.4	%82.9

%70 - %30 eğitim-test veri ayırımında yapılan doğrulamada, %87.5 doğruluk ile en iyi sonuç EfficientNet modelinde Q-DVM sınıflandırıcısıyla elde edilmiştir (Şekil 6.).



Şekil 6. EfficientNet - Q-DVM Modeline Ait Karışıklık Matrisi ve Dağılım Grafiği

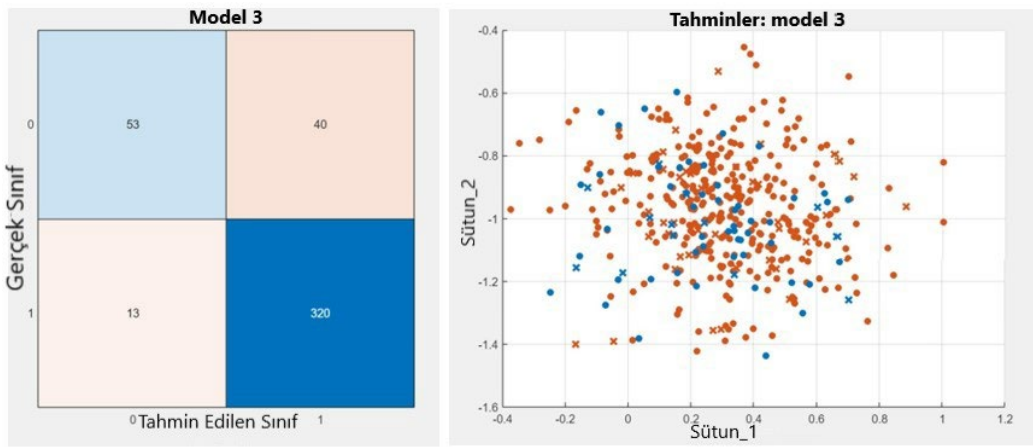
Inception V3, Google Net, Mobile Net V2, EfficientNet, AlexNet ve ResNet-50 modellerine ait %80-%20 eğitim ve test verisi için sınıflandırma performansları Tablo 3' de gösterilmiştir. %80-%20 veri ayırımında, %87.6 doğruluk ile en iyi sonuç MobileNet modelinde Q-DVM sınıflandırıcısı kullanılarak elde edilmiştir. Sınıflandırıcı performansları değerlendirildiğinde ise en iyi sonucun Q-DVM ile alındığı gözlemlenmiştir.

MobileNet V2 modeli ve Q-SVM sınıflandırıcısı kullanılarak yapılan deneylerde, en iyi sonuç %80-%20 veri ayırımında %87.6 doğruluk oranı ile elde edilmiştir. Bu, modelin genel veri seti üzerinde yüksek doğrulukla çalıştığını ve Q-SVM sınıflandırıcısının bu modelle etkili bir şekilde bütünleştiğini göstermektedir. MobileNet V2'nin diğer modeller ve sınıflandırıcılarla yapılan karşılaştırmalarda üstün performans sergilemesi, güçlü genelleme yeteneğini ortaya koymuştur. Sonuç olarak, Q-SVM modelinin bu veri seti üzerinde hızlı ve etkili bir şekilde çalıştığı görülmüştür. QDVM modelinin daha iyi sonuçlar vermesi, veri uzayındaki sınırlı örneklerin ayırımı daha iyi optimize etmesi ve düşük boyutlu veri setlerinde daha etkili olmasıdır.

Tablo 3. Eğitim ve Test Veri Seti için Doğrulama Sonuçları (%80 Eğitim - %20 Test Ayrımı)

Metod	Performans Değerleri				AlexNet	ResNet 50
	InceptionNet V3	GoogLeNet	MobileNet V2	EfficientNet		
L-DVM	% 83.8	%85.2	%86.2	%84.7	%84.7	%84.6
Q-DVM	%84.3	%85.9	%87.6	%87.1	%87.3	%85.8
C-DVM	%84.3	%84.3	%86.4	%83.6	%85.4	%84.7
K-NN	%82.4	%82.6	%84.7	%84.5	%83.6	%83.9
TA	%81	%82.6	%85.2	%84	%83.8	%84.2
LR	%81.5	%83.3	%85.4	%81.5	%84.3	%83

Modelin performansını değerlendiren karışıklık matrisi ve tahmin performansı grafiklerinde, doğru tahminler kırmızı dairelerle, yanlış tahminler ise mavi çarpılarla gösterilmiştir; bu da modelin genel olarak iyi bir performans gösterdiğini ortaya koymaktadır (Şekil 7). Matrisin sağ alt köşesinde yer alan 320, modelin 1 sınıfını doğru bir şekilde tahmin ettiği örneklerin sayısını (true positive) göstermektedir; bu da modelin pozitif sınıflandırmalarda oldukça başarılı olduğunu bizlere göstermektedir. Bununla birlikte, sol üst köşede 53 doğru negatif (true negative) tahmin bulunmakta, yani model 0 sınıfını da belirli bir oranda doğru tespit etmiştir. Ancak, sağ üst köşede modelin 40 örneği yanlış pozitif (false positive) olarak sınıflandırdığı, yani aslında 0 olan örnekleri 1 olarak tahmin ettiği görülmektedir. Aynı şekilde, sol alt köşede 13 yanlış negatif (false negative) tahmin, yani aslında 1 olan örneklerin 0 olarak tahmin edildiği durumlar bulunmaktadır. Bu matrise göre, model 1 sınıfında başarılı olmasına rağmen 0 sınıfını tanımada bazı zorluklar yaşamaktadır. Genel olarak model, pozitif sınıfların tespitinde iyi performans gösterse de, negatif sınıfların doğru bir şekilde sınıflandırılmasında iyileştirmeye ihtiyaç duyabilir.

**Şekil 7.** MobileNet V2 - Q-DVM Modeline Ait Karışıklık Matrisi ve Dağılım Grafiği

Farklı çalışmaların ve elde edilen sonuçların, çeşitli değerlendirme kriterlerine göre karşılaştırılması yapılmış ve sonuçlar Tablo 4'te sunulmuştur. Tabloda farklı araştırma çalışmalarının doğruluk oranlarını ve kullanılan yöntemleri karşılaştırılmaktadır.

Tablo 4. Önerilen Yöntemim Önceki Çalışmalar ile Karşılaştırılması

Yazar(lar)	Model/Yöntem	Veri Seti	Başarı Oranı (Accuracy)
Clifford et al., (2016) [16]	AdaBoost & CNN	PhysioNet/CinC Challenge 2016	% 86.02
Grzegorzcyk ve ark. (2016) [17]	Sinir ağı (NN)	PhysioNet/CinC Challenge 2016	% 78.9
Rubin ve ark. (2016) [18]	Convolutional Neural Networks (CNN) ve Mel-Frequency Cepstral Coefficients (MFCC)	PhysioNet/CinC Challenge 2016	Faz I: %88, Faz II: %84.8
Nilanon ve ark. (2016) [19]	Convolutional Neural Networks (CNN) ve Mel-frequency cepstrum coefficients (MFCCs)	PhysioNet/CinC Challenge 2016	%81.3
Noman ve ark. (2019) [20]	1D-CNN (bir boyutlu Convolutional Neural Network) ve 2D-CNN (iki boyutlu Convolutional Neural Network), TF-ECNN	PhysioNet/CinC Challenge 2016	%89.22
Bouril ve ark. (2019) [21]	Support Vector Machines (SVM)	PhysioNet/CinC Challenge 2016	Faz I: %78 Faz II :%78.64
Önerilen Yöntem	Mobile Net V2	PhysioNet/CinC Challenge 2016	%87.6

Clifford ve arkadaşları (2016), AdaBoost ve CNN kombinasyonu %86.02 doğruluk sağlamıştır. Bu yöntem, klasik makine öğrenme yöntemleri ile derin öğrenme tekniklerini birleştirerek başarılı sonuçlar elde etmiş olsa da, Chroma spektrogramları gibi zengin frekans temsili sağlamadığından doğruluk oranı bizim çalışmamızdan daha düşük kalmıştır.

Grzegorzcyk ve arkadaşları (2016), Temel sinir ağları (NN) ile %78.9 doğruluk elde edilmiştir. Bu düşük sonuç, kullanılan sinir ağlarının daha basit ve yetersiz özellik çıkarma kapasitesinden kaynaklanmaktadır, oysa bizim çalışmamızda Chroma spektrogramları ve daha gelişmiş derin öğrenme ağları kullanılmıştır.

Rubin ve arkadaşları (2016), CNN ve MFCC kullanılarak %84.8 doğruluk elde edilmiştir. MFCC, EKG gibi karmaşık sinyallerin frekans ve harmonik özelliklerini tam olarak temsil edemediğinden, Chroma spektrogramlarına kıyasla daha düşük performans göstermiştir.

Nilanon ve arkadaşları (2016), CNN ve MFCC kullanarak %81.3 doğruluk sağlamışlardır. Yine MFCC'nin sınırlı frekans temsili, Chroma spektrogramlarının sunduğu daha geniş frekans ve harmonik yapı temsiline kıyasla yetersiz kalmıştır.

Noman ve arkadaşları (2019), 1D-CNN ve 2D-CNN ile %89.22 doğruluk elde edilmiştir. Bu yüksek doğruluk, daha karmaşık CNN mimarilerinin kullanılmasından kaynaklanmaktadır, ancak bizim çalışmamızda önceden eğitilmiş modeller, genel performansı optimize etmekte ve eğitim süresini kısaltmaktadır.

Bouril ve arkadaşları (2019), SVM kullanarak %78 doğruluk sağlamışlardır. SVM, doğrusal olmayan sınıflandırma görevlerinde iyi sonuçlar verse de, derin öğrenme modellerinin sunduğu daha güçlü özellik çıkarma kapasitesine sahip değildir.

Kısaca, tabloya göre birçok yöntem önerilen yöntemimizle kıyaslanabilir bir performans sergilemiştir. Bununla birlikte, bazı durumlarda bizim yöntemimiz, diğer yaklaşımlardan daha üstün sonuçlar elde etmiştir. Bu karşılaştırmalar, yapılan çalışmanın başarısını ve önerilen yöntemin diğer yaklaşımlara göre avantajlarını net bir şekilde ortaya koymaktadır. Chroma spektrogramlarının ve modern derin öğrenme ağlarının kullanılması, modelimizin performansını artırmada kritik bir rol oynamıştır ve bu da yapılan çalışmanın doğruluk oranlarına olumlu bir katkı sağlamıştır.

5. SONUÇ (CONCLUSION)

Bu çalışmada, derin öğrenme ve transfer öğrenme yöntemleri kullanılarak EKG sinyallerinden aritmi tespiti yapılmıştır. Çalışma, derin öğrenme modellerinin EKG verilerini sınıflandırmada yüksek doğruluk sağladığını ve bu modellerin klinik ortamlarda güvenilir tanı araçları olarak kullanılma potansiyeline sahip olduğunu göstermektedir. Elde edilen sonuçlar, bu modellerin sadece akademik başarıyla sınırlı kalmayıp, gerçek dünya uygulamalarında da etkili olabileceğini ortaya koymaktadır.

Transfer öğrenme tekniklerinin uygulanmasıyla, önceden eğitilmiş modellerin yeni veri setlerine uyarlanması sayesinde hem sınıflandırma performansı artırılmış hem de modelin eğitim süresi önemli ölçüde kısaltılmıştır. Bu çalışmanın sonuçları, kalpteki ritim bozukluklarının tespitinde uzman kişilerin hızlı ve doğru teşhis koymasına yardımcı olabilecek etkili araçlar sunmaktadır. Ancak, modellerin güvenilirliğini artırmak için daha büyük ve çeşitli veri setleri üzerinde çalışmalar yapılması önerilmektedir. Gelecekteki araştırmalar, bu modellerin geniş kapsamlı olarak gerçek hayatta uygulanabilirliğinin test edilmesine ve klinik pratikteki kullanım alanlarının genişletilmesine odaklanmalıdır.

TEŞEKKÜR (ACKNOWLEDGMENTS)

Bu çalışma 22219 no'lu proje olarak HÜBAK tarafından desteklenmiştir.

Not: Bu makale, yüksek lisans tez çalışmasından elde edilen bulgulara dayanmaktadır.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

KAYNAKLAR (REFERENCES)

- [1] Vikipedi yazarları, "Elektrokardiyografi," Vikipedi, Özgür Ansiklopedi. Erişim tarihi: 29 Mayıs 2024. [https://tr.wikipedia.org/wiki/Elektrokardiyografi#:~:text=Elektrokardiyografi%20\(EKG\)%2C%20kalp%20kas%C4%B1n%C4%B1n,kullan%C4%B1lan%20alete%20de%20elektrokardiyograf%20denir.](https://tr.wikipedia.org/wiki/Elektrokardiyografi#:~:text=Elektrokardiyografi%20(EKG)%2C%20kalp%20kas%C4%B1n%C4%B1n,kullan%C4%B1lan%20alete%20de%20elektrokardiyograf%20denir.)
- [2] A. Alpman, "Elektrokardiyogram (EKG)," Ahmet Alpman. Erişim tarihi: 6 Ağustos 2024. <https://ahmetalpman.com/elektrokardiyogram-ekg/>.
- [3] Y. Ansari, O. Mourad, K. Qaraqe, ve E. Serpedin, "Deep learning for ECG arrhythmia detection and classification: an overview of progress for period 2017–2023," *Frontiers in Physiology*, 14 (2023) 1246746.
- [4] Q. Xiao, K. Lee, S. A. Mokhtar, I. Ismail, A. L. B. M. Pauzi, Q. Zhang, ve P. Y. Lim, "Deep learning-based ECG arrhythmia classification: A systematic review," *Applied Sciences*, 13:8 (2023) 4964.

- [5] N. Katal, S. Gupta, P. Verma, ve B. Sharma, "Deep-learning-based arrhythmia detection using ECG signals: A comparative study and performance evaluation," *Diagnostics*, 13: 24 (2023) 3605.
- [6] Mohebbanaaz, L. R. Kumar, ve Y. P. Sai, "A new transfer learning approach to detect cardiac arrhythmia from ECG signals," *Signal, Image and Video Processing*, cilt. 16: 7 (2022) 1945-1953.
- [7] P. N. Singh ve R. P. Mahapatra, "A novel deep learning approach for arrhythmia prediction on ECG classification using recurrent CNN with GWO," *International Journal of Information Technology*, 16:1 (2024) 577-585.
- [8] M. B. Er ve I. B. Aydilek, "Music emotion recognition by using chroma spectrogram and deep visual features," *International Journal of Computational Intelligence Systems*, 12:2 (2019) 1622–1634. <https://doi.org/10.2991/ijcis.d.191216.001>.
- [9] M. B. Er, "A novel approach for classification of speech emotions based on deep and acoustic features," *IEEE Access*, 8 (2020) 221640-221651. <https://doi.org/10.1109/ACCESS.2020.3043201>.
- [10] G. D. Clifford, C. Liu, B. Moody, H. L. Li-wei, I. Silva, Q. Li, ... ve R. G. Mark, "AF classification from a short single lead ECG recording: The PhysioNet/computing in cardiology challenge 2017," *2017 Computing in Cardiology (CinC)*, ss. 1-4, Eylül 2017.
- [11] Y. Liang, S. Yin, Q. Tang, Z. Zheng, M. Elgendi, ve Z. Chen, "Deep learning algorithm classifies heartbeat events based on electrocardiogram signals," *Frontiers in Physiology*, 11 (2020) 569050.
- [12] S. Śmigiel, K. Pałczyński, ve D. Ledziński, "ECG signal classification using deep learning techniques based on the PTB-XL dataset," *Entropy*, 23:9 (2021) 1121.
- [13] M. B. Er, "Heart sounds classification using convolutional neural network with 1D-local binary pattern and 1D-local ternary pattern features," *Applied Acoustics*, 180 (2021) 108152.
- [14] S. Sattar, R. Mumtaz, M. Qadir, S. Mumtaz, M. A. Khan, T. De Waele, ... ve A. Shahid, "Cardiac arrhythmia classification using advanced deep learning techniques on digitized ECG datasets," *Sensors*, 24:8 (2024) 2484.
- [15] C. Liu, D. Springer, B. Moody, I. Silva, A. Johnson, M. Samieinasab, ... ve G. D. Clifford, "Classification of heart sound recordings-the PhysioNet computing in cardiology challenge 2016," *PhysioNet*, 2016.
- [16] G. D. Clifford, C. Liu, B. Moody, D. Springer, I. Silva, Q. Li, ... ve R. G. Mark, "Classification of normal/abnormal heart sound recordings: The PhysioNet/Computing in Cardiology Challenge 2016," *2016 Computing in Cardiology Conference (CinC)*, ss. 609-612, Eylül 2016.
- [17] I. Grzegorzcyk, M. Soliński, M. Łeppek, A. Perka, J. Rosiński, J. Rymko, ... ve J. Gierałtowski, "PCG classification using a neural network approach," *2016 Computing in Cardiology Conference (CinC)*, ss. 1129-1132, Eylül 2016.
- [18] J. Rubin, R. Abreu, A. Ganguli, S. Nelaturi, I. Matei, ve K. Sricharan, "Classifying heart sound recordings using deep convolutional neural networks and mel-frequency cepstral coefficients," *2016 Computing in Cardiology Conference (CinC)*, 813-816, Eylül 2016.
- [19] T. Nilanon, J. Yao, J. Hao, S. Purushotham, ve Y. Liu, "Normal/abnormal heart sound recordings classification using convolutional neural network," *2016 Computing in Cardiology Conference (CinC)*, ss. 585-588, Eylül 2016.
- [20] F. Noman, C. M. Ting, S. H. Salleh, ve H. Ombao, "Short-segment heart sound classification using an ensemble of deep convolutional neural networks," *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, ss. 1318-1322, Mayıs 2019.

- [21] A. Bouril, D. Aleinikava, M. S. Guillem, ve G. M. Mirsky, "Automated classification of normal and abnormal heart sounds using support vector machines," 2016 Computing in Cardiology Conference (CinC), ss. 549-552, Eylül 2016.