

T.C.
ANKARA YILDIRIM BEYAZIT ÜNİVERSİTESİ
TIP FAKÜLTESİ

YAPAY ZEKA ARACILIĞIYLA VENTRİKÜLER TAŞİKARDİ (VT) VE SUPRAVENTRİKÜLER TAŞİKARDİ (SVT) AYRIMI

UZMANLIK TEZİ

Dr. Can Berk İNAN

ACİL TIP ANA BİLİM DALI

Ankara, 2023

T.C.
ANKARA YILDIRIM BEYAZIT ÜNİVERSİTESİ
TIP FAKÜLTESİ

YAPAY ZEKA ARACILIĞIYLA VENTRİKÜLER TAŞİKARDİ (VT) VE SUPRAVENTRİKÜLER TAŞİKARDİ (SVT) AYRIMI

UZMANLIK TEZİ

Dr. Can Berk İNAN

TEZ DANIŞMANI

Prof. Dr. Havva ŞAHİN KAVAKLI

ACİL TIP ANA BİLİM DALI

Ankara, 2023

BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün aşamalarda patent ve telif haklarını ihlal edici etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tezde kullanılmış olan tüm bilgi ve yorumlara kaynak gösterdiğimi beyan ederim.

Tarih:03.05.2023

Araş. Gör. Dr. Can Berk İNAN

TEŞEKKÜR

Gerek asistanlığım gerekse tez çalışmam süresince her zaman yanımda olan, bilgi ve tecrübeleri ile yolumu daima aydınlatan, birçok alanda örnek aldığım, üslubu ve bizlere yaklaşımında her zaman mütevazı olan, tez öğrencisi olmaktan onur duyduğum değerli hocam Prof. Dr. Havva ŞAHİN KAVAKLI' ya,

Eğitimimiz boyunca tecrübe ve bilgisi ile bizlere yol gösteren klinik eğitim sorumlumuz saygıdeğer hocam Prof. Dr. Şervan GÖKHAN'a,

Bizlere her zaman destek olan, kapısını bize hep açık tutan, klinik idari sorumlumuz değerli hocam Prof. Dr. Gülhan KURTOĞLU ÇELİK'e,

Asistanlığım boyunca olduğu gibi tez yazım sürecinde de tüm sorularımı yanıtlayan daima yanımda olan ve tecrübelerinden yararlandığım değerli hocam Doç. Dr. Alp ŞENER'e

Saygıdeğer hocalarım Prof. Dr. Ayhan ÖZHASENEKLER'e, Prof. Dr. Hakan OĞUZTÜRK'e, Doç. Dr. Mehmet ERGİN'e, Doç. Dr. Nazlı GÖRMELİ KURT'a, Doç. Dr. Mehmet Ali CEYHAN'a, Dr. Öğr. Üyesi Gül PAMUKÇU GÜNAYDIN'a, Dr. Öğr. Üyesi Fatih TANRIVERDİ'ye, Dr. Öğr. Üyesi Ahmet Fatih KAHRAMAN'a,

Her an yanımda olan, bana cesaret ve güç veren, en büyük destekçim, neşe kaynağım, biricik eşim Nurşen AKGÜN İNAN'a,

Uzun yıllardır olduğu gibi çalışmam ve asistanlığım boyunca da bir an bile desteğini esirgemeyen sevgili çocukluk arkadaşım Ahmet AYMAZ'a

Beraber çalışmaktan keyif aldığım, çalışmam süresince yanımda olan her türlü problemde çözüm sunan Özel Medikal'den sevgili Erdem GUNT'a,

Çalışmamızın var olmasını sağlayan yapay zeka konusunda bize bilinmeyen bir dünyanın kapılarını aralayan TOBB Üniversitesinden Doç. Dr. Ahmet Murat ÖZBAYOĞLU ve değerli öğrencisi Abdulsamet TÜRKER'e,

Gerek tezimde gerekse diğer çalışmalarımızda birlikte çalışma şansına eriştiğim ve kendilerini tanımaktan, birlikte çalışmaktan onur duyduğum Kardiyoloji Anabilim dalından Doç. Dr. Hülya ÇİÇEKÇİOĞLU ve Doç. Dr. Kerem ÖZBEK'e,

Beraber çalışmaktan keyif aldığım eş kıdemim, çalışma arkadaşından ziyade bana birer kardeş olan Dr. Naciye Büşra ÜNVER ERDOĞAN ve eşi Bora ERDOĞAN'a,

Her zaman güvenebileceğim, beni hiçbir zaman yarı yolda bırakmayan değerli arkadaşım, kardeşim Dr. Salih Murat ERTEKİN ve nişanlısı, biricik arkadaşımız İrem ÖNEN'e,

Bugünlere gelmemi sağlayan, emeklerinin karşılığını asla ödeyemeyeceğim, bana her zaman güvenen, arkamda duran annem Hatice İNAN'a ve babam Nazmi İNAN'a, abim İlker İNAN'a, yengem Maya İNAN'a, kardeşim Gizem İNAN'a sonsuz teşekkürlerimi sunarım.

İÇİNDEKİLER

İÇİNDEKİLERi
ÖZETiv
ABSTRACTvi
KISALTMALARviii
TABLO DİZİNİx
ŞEKİL DİZİNİxi
1. GİRİŞ1
2. GENEL BİLGİLER3
2.1. KALBİN YAPISI VE ELEKTRİKSEL İLETİM SİSTEMİ3
2.2. KALBİN ELEKTROFİZYOLOJİSİ4
2.3. MİYOKARD AKSİYON POTANSİYELİ5
2.4. EKG VE TARİHÇESİ6
2.5. EKG ÇEKİMİ VE DERİVASYONLAR7
2.6. EKG KAĞIDI VE ÖZELLİKLERİ8
2.7. EKG DALGA, SEGMENT VE ARALIKLARI9
2.7.1. P Dalgası10
2.7.2. PR Aralığı10
2.7.3. QRS Kompleksi10
2.7.4. ST Segmenti11
2.7.5. T Dalgası11
2.7.6. QT Aralığı12
2.7.7. U Dalgası12
2.8. EKG RİTİM ANALİZİ VE NORMAL SİNÜS RİTMİ (NSR)12
2.9. KARDİYAK ARİTMİLER13
2.10. TAŞİARİTMİLER14
2.11. DAR KOMPLEKS (SUPRAVENTRİKÜLER) TAŞİARİTMİLER14
2.11.1. Sinüs Taşikardisi14
2.11.2. Atriyal Taşikardi15
2.11.3. Atriyal Fibrilasyon16
2.11.4. Atriyal Flutter17

2.11.5. Multifokal Atriyal Taşikardi (MAT)17
2.11.6. AV Nodal Re – Entran Taşikardi (AVNRT)18
2.11.7. AV Re – Entran Taşikardi (AVRT)19
2.12. GENİŞ KOMPLEKS TAŞİKARDİLER20
2.12.1. Monomorfik Ventriküler Taşikardi21
2.12.2. Polimorfik Ventriküler Taşikardi ve Torsades de Pointes22
2.12.3. Ventriküler Fibrilasyon (VF)22
2.13. BRADİARİTMİLER23
2.13.1. Sinüs Bradikardisi24
2.13.2. Hasta Sinüs Sendromu24
2.13.3. Kavşak Kaçış Ritmi25
2.13.4. İdiyoventriküler Kaçış Ritmi26
2.14. KALP BLOKLARI VE İLETİM ANORMALLİKLERİ26
2.14.1. Birinci Derece AV Blok27
2.14.2. İkinci Derece AV Blok – Mobitz Tip 127
2.14.3. İkinci Derece AV Blok – Mobitz Tip 228
2.14.4. Üçüncü Derece AV Blok (Tam Blok)29
2.14.5. Sol Dal Bloğu (LBBB)29
2.14.6. Sağ Dal Bloğu (RBBB)30
2.15. VT – SVT AYRIMI31
2.15.1. Brugada Algoritması33
2.15.2. Vereckei Algoritması33
2.16. TIPTA YAPAY ZEKA34
2.17. MAKİNE ÖĞRENMESİ35
2.18. DERİN ÖĞRENME36
2.19. DERİN ÖĞRENMENİN MAKİNE ÖĞRENMESİNE ÜSTÜNLÜKLERİ37
2.20. RESİDUAL NEURAL NETWORK (RESNET) SİNİR AĞI38
3. GEREÇ-YÖNTEM40
3.1. ÇALIŞMANIN TÜRÜ, KAPSAMI VE ÖRNEKLEMİ40
3.2. VERİLERİN TOPLANMASI VE TASNİFİ41
3.3 DERİN ÖĞRENME AŞAMASI42
3.4. İSTATİKSEL METOT47
4. BULGULAR48

4.1. HASTA VERİLERİNİN ANALİZİ48
4.2. RESNET 18 İLE EKG RİTİM ANALİZİ PREDİKSİYONLARI50
4.3. RESNET 34 İLE EKG RİTİM ANALİZİ PREDİKSİYONLARI55
4.4. RESNET 50 İLE EKG RİTİM ANALİZİ PREDİKSİYONLARI59
5.TARTIŞMA63
6. ÇALIŞMANIN KISITLILIKLARI72
7. SONUÇ73
8. KAYNAKLAR74
9. ÖZGEÇMİŞ81
10. EKLER82

ÖZET

YAPAY ZEKA ARACILIĞIYLA VENTRİKÜLER TAŞİKARDİ (VT) VE SUPRAVENTRİKÜLER TAŞİKARDİ (SVT) AYRIMI

Amaç: Kardiyovasküler hastalıklar (KVH) bulaşıcı olmayan hastalıklar arasında dünya genelinde meydana gelen ölümlerin başlıca nedenlerindendir. Elektrokardiyografi (EKG), mortaliteleri son derece yüksek olabilen; ancak büyük oranda önlenebilir olan KVH'nin erken tanısında ve sürecin devamında en sık kullandığımız, hızlı ve kolayca ulaşabildiğimiz, ucuz, güvenilir, noninvaziv ve çok değerli bilgiler sunan bir tanı testidir. Geniş QRS kompleksli taşikardilerde (WCT) olduğu gibi bazı durumlarda EKG'ler, mevcut algoritmalara rağmen tecrübeli klinisyenler tarafından dahi yanlış değerlendirilebilmektedir. Bu çalışmada, yapay zeka (AI) alanında kullanılan derin öğrenme (DL) yöntemiyle VT-SVT ayrımının ne kadar başarılı olabileceği araştırılmıştır.

Materyal ve Metot: Retrospektif olarak yürütülen çalışmamıza, 1 Kasım 2021 – 1 Mart 2023 tarihleri arasında, Ankara Bilkent Şehir Hastanesi Erişkin Acil Tıp Kliniği'ne çarpıntı, baş dönmesi, dispne, göğüs ağrısı ve senkop semptomlarının en az biri ile başvuran ve 18 yaşından büyük olup EKG'leri çekilen hastalar dahil edilmiştir. Çalışmamızda önce EKG'lerinde taşiaritmi saptanan 848 hasta ile EKG'lerinde normal sinüs ritmi (NSR) saptanan 250 hasta incelenmiştir. Sonrasında dışlama kriterleri gereğince artefaktlı, EKG'lerine ulaşılamayan ve mükerrer EKG'leri olan hastalar ayrılarak veri seti oluşturabilmek için NSR EKG'si olan 248 hasta ile taşiaritmi EKG'sine sahip 652 hasta değerlendirmeye alınmıştır. Tarafımızca toplanan EKG'ler ilk olarak iki kardiyoloji uzman hekimine verilerek etiketlendirilmiştir. Etiketlenme sonrası veri setimiz, evrişimli sinir ağı (CNN) modellerimiz ResNet 18-34 ve 50'nin eğitimi ve testi için kullanılmıştır. Son olarak eğitilip hazır hale getirilen modellerimizin VT-SVT ayrımı konusundaki prediksiyonları ile altın standart olarak kabul ettiğimiz kardiyoloji uzman hekimlerininin değerlendirmeleri kıyaslanmıştır. Modellerin başarıları; doğruluk, duyarlılık, kesinlik ve F1 skorlarını içeren performans metrikleri ile ölçülmüştür.

Bulgular: Çalışmaya 652 tanesi taşiaritmik, 248 tanesi NSR EKG'si olan toplam 900 hasta dahil edildi. Hastaların %61.4'ü (n=553'ü) kadın olarak gözlenirken; tüm hastaların yaş ortalamaları 57±17 yıl olarak gözlendi. SVT-VT ayrımı için performans metriklerine bakıldığında 3 ResNet modelinin de doğruluk ve duyarlılık (ağırlıklı) yüzdeleri %95 olarak tespit edilirken; kesinlik (ağırlıklı) ve F1 skoru (ağırlıklı) yüzdeleri Resnet 18 ve 50 için %95 iken ResNet 34 için %94 olarak elde edildi.

Tartışma ve Sonuç: Çalışmamızda kullandığımız 3 ResNet modeli de başarılı bir şekilde VT-SVT ayrımı yapmış olup, doğru teşhis oranları mevcut klasik algoritmaların üzerindedir. Her geçen gün büyüyen EKG arşivleri sayesinde doğru teşhis oranları şüphesiz daha da artacaktır. Ancak yine de bu uygulamaların büyük çok merkezli çalışmalar ile prospektif olarak uygulanabilirliği test edilmelidir.

Anahtar Kelimeler: EKG, Derin öğrenme, Ventriküler taşikardi, Supraventriküler taşikardi, ResNet, Yapay zeka

ABSTRACT

ARTIFICIAL INTELLIGENCE BASED DIFFERENTIATION OF VENTRICULAR TACHYCARDIA(VT) AND SUPRAVENTRICULAR TACHYCARDIA(SVT)

Objective: Cardiovascular diseases (CVDs) are among the leading causes of non-communicable deaths worldwide. Electrocardiogram (ECG) is a commonly used, rapid, easily accessible, inexpensive, reliable, non-invasive diagnostic tool that provides valuable information in the early diagnosis and ongoing management of CVDs, which can have high mortality rates but are largely preventable. However, despite existing algorithms, ECGs can still be misinterpreted by experienced clinicians, especially in cases of wide QRS complex tachycardias. In this study, the aim was to successfully differentiate Ventricular Tachycardia (VT) and Supraventricular Tachycardia (SVT) using deep learning (DL) methods, a branch of artificial intelligence.

Material and Method: Our retrospective study was conducted at Ankara Bilkent City Hospital Adult Emergency Medicine Clinic between November 1, 2021 and March 1, 2023. Patients who presented with at least one of the symptoms of palpitation, dizziness, dyspnea, chest pain, and syncope, and who were 18 years of age or older and had ECG's taken were included in our study. Among the patients, 848 with tachyarrhythmia detected on ECG and 250 with normal sinus rhythm (NSR) on ECG were evaluated after excluding patients with artifact, unavailable ECG's, and duplicate ECG's, resulting in a dataset of 248 patients with NSR ECG and 652 patients with tachyarrhythmia ECG. The ECG's collected by our team were initially labeled by two cardiology experts. After labeling, our dataset was used for training and testing convolutional neural network models, specifically ResNet 18-34 and 50. Finally, the predictions of our trained and prepared models on VT-SVT differentiation were compared with the evaluations of our cardiology experts, whom we considered as the gold standard. The performance of the models was measured using accuracy, sensitivity, specificity, and F1 score as performance metrics.

Results: In the study, a total of 900 patients were included, with 652 having tachyarrhythmic ECG's and 248 having NSR ECG's. Among the patients, 61.4% or 553 were female, and the mean age of all patients was observed to be 57±17 years.

When looking at the performance metrics for SVT-VT differentiation, all three ResNet models showed an accuracy and sensitivity (weighted) of 95%. The specificity (weighted) and F1 score (weighted) were also observed to be 95% for ResNet 18 and 50, and 94% for ResNet 34.

Conclusion: Our study successfully used three ResNet models to differentiate between VT and SVT, with accuracy rates surpassing those of traditional algorithms. With the growing ECG archives, the accuracy of these diagnoses is expected to further improve. However, the applicability of these applications should still be tested prospectively in large multicenter studies.

Keywords : ECG, Deep learning, Ventricular tachycardia, Supraventricular tachycardia, ResNet, Artificial intelligence

KISALTMALAR

AF	: Atriyal Fibrilasyon
AI	: Artificial Intelligence (Yapay Zeka)
AKS	: Akut Koroner Sendrom
AMI	: Akut Miyokard Enfarktüsü
AV	: Atriyovenriküler
AVNRT	: AV Nodal Re-entran Taşikardi
AVRT	: AV Re-entran Taşikardi
CI	: Confidence Interval (Güven Aralığı)
CNN	: Convolutional Neural Network (Evrişimli sinir ağı)
DL	: Deep Learning (Derin Öğrenme)
EKG	: Elektrokardiyografi
KAH	: Koroner Arter Hastalığı
KVH	: Kardiyovasküler Hastalık
LBBB	: Left Bundle Branch Block (Sol Dal Bloğu)
LLA	: Limb Leads Algorithm (Ekstremite Derivasyonları Algoritması)
LSTM	: Long-Short Time Memory (Uzun- Kısa Süreli Bellek)
MAT	: Multifokal Atriyal Taşikardi
YSA	: Yapay Sinir Ağı
ML	: Machine Learning (Makine Öğrenmesi)
mm	: Milimetre
msn	: Milisaniye
NSR	: Normal Sinüs Ritmi
QTc	: Corrected QT Interval (Düzeltilmiş QT Aralığı)
RBBB	: Right Bundle Branch Block (Sağ Dal Bloğu)
RNN	: Recurrent Neural Networks (Tekrarlayan Sinir Ağı)
RWPT	: R Wave Peak Time (R Dalgası Tepe Zamanı)
STEMI	: ST Eleve Miyokard Enfarktüsü
SVT	: Supraventriküler Taşikardi
VF	: Ventriküler Fibrilasyon

VT : Ventiküler Taşikardi

WCT : Wide Complex Tachycardia (Geniş QRS Kompleksli Taşikardi)

WPW : Wolf Parkinson White Sendromu

TABLO DİZİNİ

Tablo 1. Araştırmaya Dahil Edilme ve Dışlanma Kriterleri 40
Tablo 2. Hastaların Cinsiyet ve Yaş Dağılımları 49
Tablo 3. EKG'lerin Kardiyoloji Uzmanlarınca Etiketlenmesi 49
Tablo 4. EKG Ritimleri ve Yaş Dağılımları 50
Tablo 5. EKG Ritimleri ve Cinsiyete Göre Dağılımları 50
Tablo 6. Resnet 18 İçin Performans Metrikleri 52
Tablo 7. Resnet 18'in Taşiaritmik-NSR EKG Prediksiyon Yüzdeleri 53
Tablo 8. Resnet 18'in Taşiaritmik-NSR Tanısal Değerlilik İstatistikleri 53
Tablo 9. Resnet 18'in VT-SVT EKG Prediksiyon Yüzdeleri 54
Tablo 10. Resnet 18'in VT-SVT Tanısal Değerlilik İstatistikleri 54
Tablo 11. Resnet 34 İçin Performans Metrikleri 56
Tablo 12. Resnet 34'ün Taşiaritmik-NSR EKG Prediksiyon Yüzdeleri 56
Tablo 13. Resnet 34'ün Taşiaritmik-NSR Tanısal Değerlilik İstatistikleri 57
Tablo 14. Resnet 34'ün VT-SVT EKG Prediksiyon Yüzdeleri 58
Tablo 15. Resnet 34'ün VT-SVT Tanısal Değerlilik İstatistikleri 58
Tablo 16. Resnet 50 İçin Performans Metrikleri 60
Tablo 17. Resnet 50'nin Taşiaritmik-NSR EKG Prediksiyon Yüzdeleri 61
Tablo 18. Resnet 50'nin Taşiaritmik-NSR Tanısal Değerlilik İstatistikleri 61
Tablo 19. Resnet 50'nin VT-SVT EKG Prediksiyon Yüzdeleri 62
Tablo 20. Resnet 50'nin VT-SVT Tanısal Değerlilik İstatistikleri 62
Tablo 21. Farklı Resnet Modellerinin VT-SVT Prediksiyonlarının İstatistiki Olarak Karşılaştırılması 63

ŞEKİL DİZİNİ

Şekil 1. Kalp İletim Sistemi 4
Şekil 2. Kardiyak Miyositlerdeki Elektriksel İletim 5
Şekil 3. Hücre Zarı Boyunca Elektrolitler, Aksiyon Potansiyeli, Ekg Kaydı 6
Şekil 4. Einthoven Üçgeni ve Bipolar Ekstremite Derivasyonları 7
Şekil 5. Göğüs Derivasyonları 8
Şekil 6. EKG Kağıdı 9
Şekil 7. EKG Dalga Biçimi ve Aralıkları 9
Şekil 8. Normal Sinüs Ritmi 13
Şekil 9. Sinüs Taşikardisi 15
Şekil 10. Atriyal Taşikardi 15
Şekil 11. Atriyal Fibrilasyon 16
Şekil 12. Atriyal Flutter 17
Şekil 13. Multifokal Atriyal Taşikardi 18
Şekil 14. Tipik Yavaş-Hızlı AV Nodal Re-Entran Taşikardi 19
Şekil 15. Ortodromik AVRT 20
Şekil 16. Antidromik AVRT 20
Şekil 17. Monomorfik VT 21
Şekil 18. Torsades De Pointes 22
Şekil 19. Ventriküler Fibrilasyon 23
Şekil 20. Sinüs Bradikardisi 24
Şekil 21. Hasta Sinüs Sendromu - Bradikardi Taşikardi Sendromu 25
Şekil 22. Kavşak Kaçış Ritmi 26
Şekil 23. Ventriküler Kaçış Ritmi ile Sinüs Arresti 26
Şekil 24. Birinci Derece Av Blok 27
Şekil 25. İkinci Derece Av Blok - Mobitz Tip 1 28
Şekil 26. İkinci Derece Av Blok - Mobitz Tip 2 28
Şekil 27. Üçüncü Derece Av Blok 29
Şekil 28. Sol Dal Bloğu 30
Şekil 29. Sağ Dal Bloğu 31
Şekil 30. Solda Biyolojik Nöron Yapısı, Sağda Yapay Nöron Yapısı 37

Şekil 31. Derin Sinir Ağı 38
Şekil 32. Resnet Mimari Yapısı 39
Şekil 33. Veri Toplama ve Tasnif Yol Haritası 41
Şekil 34. Derin Öğrenme Model Mimarisi 44
Şekil 35. 10 - Katlamalı Çapraz Doğrulama 45
Şekil 36. Doğruluk, Kesinlik Ve Duyarlılık Metriklerinin Hesaplanması 46
Şekil 37. Hastaların Cinsiyet Dağılımları 48
Şekil 38. Resnet 18 İçin Hata Matrisi 51
Şekil 39. Resnet 18 İçin Roc Eğrisi 51
Şekil 40. Resnet 18 İçin Kesinlik- Duyarlılık Eğrisi 52
Şekil 41. Resnet 34 İçin Hata Matrisi 55
Şekil 42. Resnet 34 İçin Roc Eğrisi 55
Şekil 43. Resnet 34 İçin Kesinlik-Duyarlılık Eğrisi 56
Şekil 44. Resnet 50 İçin Hata Matrisi 59
Şekil 45. Resnet 50 İçin Roc Eğrisi 59
Şekil 46. Resnet 50 İçin Kesinlik-Duyarlılık Eğrisi 60

1. GİRİŞ

Kardiyovasküler hastalıklar (KVH) bulaşıcı olmayan hastalıklar arasında dünya genelinde meydana gelen ölümlerin başlıca nedenlerindendir. Dünya geneline bakıldığında 2000-2019 yılları arasında KVH nedenli ölümler neredeyse 2 milyonun üzerinde artışla gerçekleşmiş ve toplamda 8.9 milyon olarak gözlenmiştir (1). Her geçen gün gelişen teknoloji ve iyileşen yaşam koşullarıyla yaşam sürelerinde meydana gelen artışlara paralel olarak kalp ve damar hastalıkları da artmakta olup; bu grup hastalıkların ölüm nedenleri arasında uzun yıllar ilk sıralarda olması beklenmektedir. Bu bağlamda söz konusu hastalıkların teşhisi, hem insanların yaşam kalitesini ve süresini arttırmak hem de topluma getirdikleri maliyetleri azaltmak bakımından kritik önem göstermektedir (2). Gerek KVH'lerin tanılarının konmasında gerekse acil olarak nitelendirilen durumlarda ilk değerlendirme için elektrokardiyografi (EKG) olmazsa olmazdır. EKG, mortaliteleri son derece yüksek olabilen; ancak büyük oranda önlenebilir olan KVH 'lerin erken tanısında ve sürecin devamında en sık kullandığımız; hızlı kolayca ulaşabildiğimiz; ucuz, güvenilir, noninvaziv olan ve çok değerli bilgiler sunan bir tanı testidir (3).

Ritim bozuklukları, miyokard enfarktüsleri, kapak hastalıkları, kalp yetmezliği, perikardit ve kardiyomiyopatiler, elektrolit imbalansları, toksidromlar, ilaç komplikasyonları, ve daha birçok durumun tanı ve takibinde EKG en önemli araçtır. Avrupa Kardiyoloji Cemiyeti ve Amerika Kardiyoloji Derneği kılavuzlarında KVH için ilk 10 dakikada EKG görülmesi sınıf 1 öneri ve kanıt düzeyi B olarak önerilmektedir. Çok kısa sürede çekilebilen böylesine kolay bir test olmasının yanı sıra EKG bize KVH ve daha birçok patoloji hakkında erken tanı ve teşhis imkanı sunmakta ve bu sayede gözlenen mortalite ve morbidite oranları anlamlı ölçüde azaltılabilmektedir (4). Ne yazık ki bu kadar değerli bilgiler elde edebildiğimiz EKG'ler, doktorlar ve diğer sağlık uygulayıcıları tarafından her zaman doğru olarak yorumlanamayabilir. Bazı EKG ritimlerinin yorumlanması diğerlerine göre daha zor olabilmektedir.

Çalışmamızın hipotezi olan supraventriküler taşikardi (SVT) ile ventriküler taşikardi (VT) ayrımını yapmak kimi zaman tecrübeli gözler için dahi zor olabilmektedir. SVT-VT ayrımı için birçok faklı algoritma mevcut olmasına rağmen bu algoritmaların uygulanması hem tecrübe hem zaman gerektirmektedir (5).

1970'ten beri, yorumlamalardaki insan hatalarını azaltmak adına EKG yorumları yapan bilgisayar programları geliştirilmiştir; ancak bu yorumların doğruluk oranları henüz istenen düzeyde değildir.Yaklaşık 50 yıl önce kullanıma giren bilgisayar programları düşünüldüğünde yapay zeka kullanılarak EKG yorumlanması aslında elektrofizyoloji alanında yeni bir yaklaşım değildir (6).

Günümüzde artık birçok alanda yaygın şekilde kullanılan yapay zeka (AI) ve makine öğrenimi (ML), haliyle tıp alanında da kullanılır hale gelmiştir ve her geçen gün bu ilgi artarak devam etmektedir. AI ve ML insan görevlerini otomatikleştirmesinin yanı sıra insan yeteneklerinin ötesindeki görevleri dahi gerçekleştirme potansiyeli taşımaktadır. AI tipik olarak insan bilişsel işlevi gerektiren hedeflere ulaşmak için makine tabanlı veri işlemeyi ifade eder. Günümüzde EKG verilerinin uzmanlar tarafından etiketlendiği büyük elektronik veri tabanları kullanılarak; algoritmalardaki yenilikler ve her geçen gün gelişen yazılımsal yetenekler sayesinde gün geçtikçe yapılan yorumlar; EKG eğitimi almış sağlık uygulayıcıların yorumları kadar başarılı olabilmektedir. Böylece erken tanı ve tedavi şansı sağlanması ile kardiyak hastalıklara bağlı oluşabilecek mortalite ve morbiditenin ilerleyen dönemlerde daha da azaltılabilmesi hedeflenmektedir (6,7).

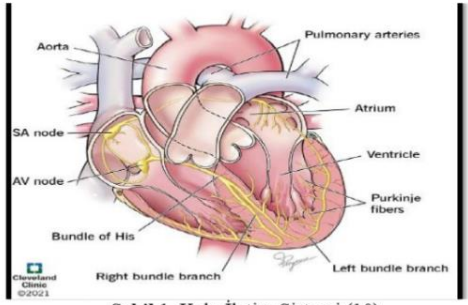
Çalışmamız klinik pratiğimizde karşılaştığımız; ayrımı her zaman mümkün olmayan hatta ayrım için değişik algoritmaların olduğu VT ile SVT ritimlerinin bir Derin öğrenme (DL) modeli kullanılarak analiz edilmesine dayanmaktadır. Hedefimiz, yorumlamalardaki insan hata faktörünü ortadan kaldırarak; otomasyonu ve standardizasyonu sağlamak; doğru, hızlı bir şekilde ritim analizi yaparak doğru tedavinin başlanmasını sağlamaktır. Bu uygulamalar sayesinde klinisyenlerin iş yükü azaltılarak konumuz olan disritmiler ve KVH'ler de dahil olmak üzere birçok hastalığın erken teşhisi mümkün kılınabilir. Erken teşhisler, azalan hastane yatış süreleri ve yerinde tedaviler sayesinde mortalite ve morbiditeler önlenerek medikal giderler azaltılabilir.

2. GENEL BİLGİLER

2.1. KALBİN YAPISI VE ELEKTRİKSEL İLETİM SİSTEMİ

Kalp, göğüs kafesi içerisinde oblik olarak durur. Dolaşım sistemimizin merkezini oluşturan kalp, vücudumuzun en önemli organlarından birisidir. Sağ atriyum ve sol atriyum yukarıda; sağ ventrikül ve sol ventrikül altta olmak üzere dört bölmesi vardır (8).

Kalp, elektriksel sinyallerle çalışan kendine özgü kas sisteminden oluşur ve bu elektriksel sinyaller, kalbin düzenli bir şekilde kasılmasını; böylelikle kanın vücuda pompalamasını sağlar. Kalp elektriksel uyarılarının üretimi, kalbin doğal bir özelliği olan otonom sinir sistemi tarafından kontrol edilir. Kalbin elektriksel uyarılarının kaynağı, sağ atriyumun üst kısmındaki Sinoatriyal (SA) düğümdür; hatta bu düğüme kalbimizin doğal kalp pili de denir. SA düğümü, spontan olarak dakikada 60-100 defa sinyal üretir. Bu sinyaller, kalp kasları boyunca iletilerek kalbin kasılmasını sağlar. SA düğümünden gelen elektriksel sinyaller, sağ ve sol atriyumları kasarak kanın kalbin ventriküllerine pompalanmasını sağlar. Daha sonra, bu sinyaller Atriyoventriküler (AV) düğüme doğru ilerler ve burada bir anlık gecikme yaşanır. Bu gecikme, kalbin sağ ve sol ventriküllerini eş zamanlı olarak kasmasını sağlamak için gereklidir. AV düğümden çıkan sinyaller, His demeti adı verilen bir lif demetine geçer ve son olarak Purkinje lifleriyle kalbin sağ ve sol ventriküllerine yayılır. Kalp kasları, bu elektriksel sinyallerin kasılma dalgalarını oluşturmasıyla kasılır ve kanın vücudumuzun her yerine pompalanmasını sağlar. Kalbin elektriksel uyarılarının kaynağı ve iletimi, kalp hastalıklarının teşhis ve tedavisinde önemli bir rol oynar (8,9).



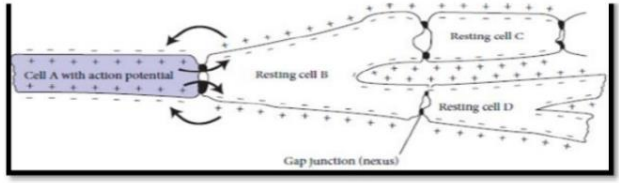
Şekil 1. Kalp İletim Sistemi (10)

2.2. KALBİN ELEKTROFİZYOLOJİSİ

Hücre düzeyindeki elektrokimyasal olaylar ve elektriksel yüklerdeki farklılıklar sayesinde oluşan elektrik akımlarının kalbe yayılışı ne kadar iyi anlaşılabilir ise EKG'nin mantığı da o kadar iyi anlaşılır. Vücudumuzda bulunan herhangi bir hücrenin, uyarılmadığı zamanlarda içi negatif; dışı ise pozitif yüklüdür ve bu haldeki hücre durumu polarize olarak adlandırılır. Hücre içi ve dışı arasında bu şekilde bir elektriksel yük farkı olması ise istirahat membran potansiyeli olarak adlandırılır. Hücre içi ile dışı arasındaki voltaj farkı -90 mili volttur. Hücrenin uyarılması depolarizasyon; hücrenin eski dinlenme haline dönmesi ise repolarizasyon olarak adlandırılır. Elektriksel yük dengesinin sağlanması ise iyon kanalları aracılığı ile sağlanır. Sodyum (Na) bağımlı iyon kanalı depolarizasyonda, Potasyum (K) kanalı repolarizasyonda, Kalsiyum (Ca) kanalları ise kasılmada görev alır (11).

Kalp kası hücreleri uyarı sonrası depolarize olur ve bunun olduğu yerde hücre dışı negatif hücre içi ise pozitif hale gelir. Uyarılan hücre komşuluğunda olan uyarılmamış hücrelerin dış yüzleri arasında bir elektriksel akım oluşur ve uyarı, hücreden hücreye boşluk bağlantıları adı verilen gap junctionların da yardımı ile aynı domino taşlarındaki iletime benzer şekilde iletilir. Normalde tüm kalp kası hücreleri belli bir ahenk içinde çalışır; polarize halden depolarize hale geçiş; oradan repolarizasyon gözlenmesi EKG'de gözlediğimiz elektriksel akımın oluşmasını sağlar (11,12).

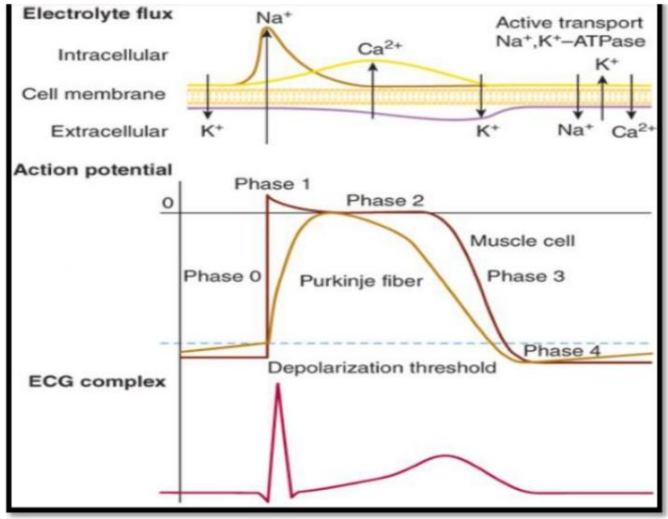
Kalp boyunca oluşan elektriksel uyarıların izlemiş olduğu yayılma eksenine kalbin elektriksel aksı denir. Normalde -30 +90 derece arasında sağdan sola ve yukarıdan aşağı yaklaşık 45 derecelik bir açıyla DII'ye paraleldir. Aksta oluşabilecek farklılıklar sağ ya da soldaki kaslardan hangisinin daha aktif olduğu ritim bozuklukları ve kalp yetmezliği gibi durumların habercisi olabilir (13) .



Şekil 2. Kardiyak Miyositlerdeki Elektriksel İletim (13)

2.3. MİYOKARD AKSİYON POTANSİYELİ

Miyositlerde aksiyon potansiyeli 5 fazda incelenir. Faz 0: Na kanallarının açılmasıyla içeri giren Na miktarı artar ve depolarizasyon gözlenir. Faz 1: Aksiyon potansiyeli tepe değeri olan +20 mv'a ulaşır, Na kanalları bunun üzerine kapanırken K kanalları açılır; böylelikle K çıkışı artar ve hızlı depolarizasyon gözlenir. Faz 2: Hızlı K kanalları kapanırken Ca kanalları açılır; böylece Ca geçirgenliği artmış olur ve bu faz plato fazı olarak adlandırılır. Faz 3: Ca kanalları kapanırken sona doğru yavaş K kanalları açılır, bu faza hızlı repolarizasyon fazı da denir. Faz 4: Önceki fazın sonunda açılan yavaş K kanalları sayesinde K dışarı çıkar ve membran potansiyeli -90 mv düzeyine gelir. EKG'de Faz 1, QRS dalgası olarak yansırken Faz 2 ST segmentine denk gelir; Faz 3 T dalgası oluşumuna Faz 4 ise T dalgası ile QRS arasında gözlenen miyokard istirahat potansiyeline denk gelir (14) .



Şekil 3. Hücre Zarı Boyunca Elektrolitler, Aksiyon Potansiyeli, EKG Kaydı (14)

2.4. EKG VE TARİHÇESİ

EKG kalbin elektriksel aktivitesinin kaydedilmesi için kullanılan bir testtir. EKG cihazı deriye yerleştirilen özel yüzey elektrotları aracılığıyla, kalbin elektriksel aktivitesini ölçer ve bu aktivitenin bir grafiksel temsilini oluşturur. Bu grafik, elektrokardiyogram adı verilen bir çizgi şeklindeki kayıtta görülebilir (15).

EKG'nin tarihi ise 1786 yılında Dr. Luigi Galvani'nin iskelet kaslarında bulunan elektriksel akımı kaydetme fikriyle başlar. Günümüz EKG makinelerinin öncülü 1901 yılında Willem Einthoven tarafından geliştirilmiş bir galvanometredir ve yaklaşık olarak 270 kilogram (kg) ağırlığındadır. Einthoven bu cihaz ile ilk kez bir insana ait kalbin elektriksel aktivitesini kayıt altına almıştır. Günümüzde kullandığımız ekstremite derivasyonları ve EKG'yi tanımlamaya yönelik PQRST sistemi de Einthoven tarafından oluşturulmuştur (16).

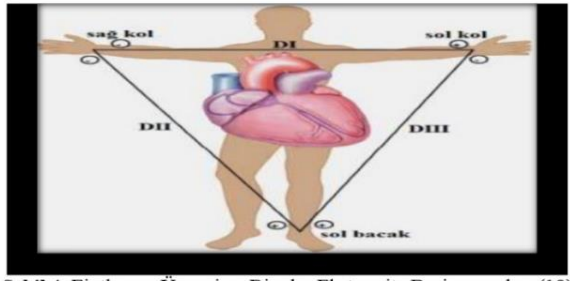
1934 yılında V1-V6 arasındaki göğüs derivasyonlarının tanımlanmasına ek olarak 1942 yılında Goldberg'in tek kutuplu ekstremite derivasyonları aVR, aVL, aVF'yi tanımlaması; bugün bildiğimiz 12 derivasyonlu EKG şekillenmesini sağlamıştır (17).

2.5. EKG ÇEKİMİ VE DERİVASYONLAR

EKG çekimi, bir futbol maçının kamera ile kaydedilmesine benzer; öyle ki nasıl bir futbol maçı tek bir açıdan kaydedilemez; EKG çekerken de farklı açılardan bakılmaz ise yeterli ve doğru bilgi elde edilemez böylece önemli noktalar atlanabilir. EKG derivasyonları kalp aktivitesinin kaydedilmesinde kullanılan elektrot kombinasyonlarını ifade eder ve bu derivasyonlar sayesinde kalbin farklı bölgelerindeki elektriksel aktiviteler ölçülebilir (18).

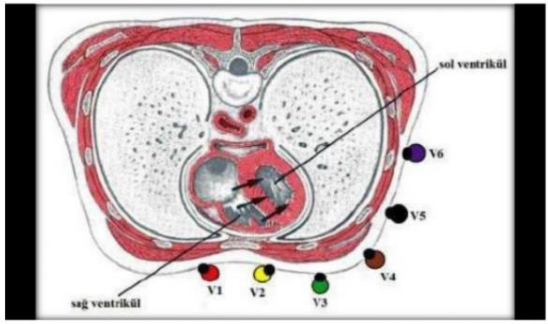
Günümüzde birçok klinikte 12 derivasyonlu EKG'ler kullanılmaktadır. 12 derivasyonun 6 tanesi ekstremite derivasyonu; 6 tanesi göğüs derivasyonu (prekordiyal derivasyon) olarak konumlandırılmıştır .

Ekstremite derivasyonları da kendi aralarında bipolar (I, II, III) ve unipolar (aVR, aVL, aVF) olarak iki alt gruba ayrılır.



Şekil 4. Einthoven Üçgeni ve Bipolar Ekstremite Derivasyonları (18)

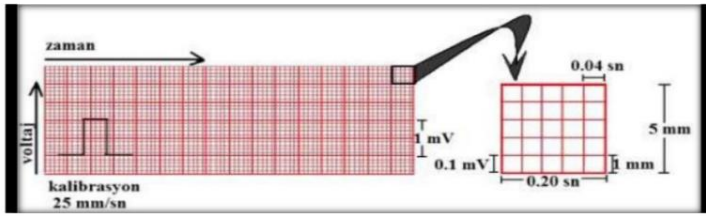
Göğüs derivasyonları göğüs duvarı üzerine yerleştirilen 6 adet elektrodun kullanılmasıyla elde edilir ve bunlar kalbin horizontal düzlemdeki aktivitesi hakkında bize bilgi verir.V1 ve V2 sağ ventrikülün elektriksel aktivitesini ölçmede kullanılırken V3, V4, V5 ve V6 sol ventrikülün aktivitesini ölçer (18).



Şekil 5. Göğüs Derivasyonları (18)

2.6. EKG KAĞIDI VE ÖZELLİKLERİ

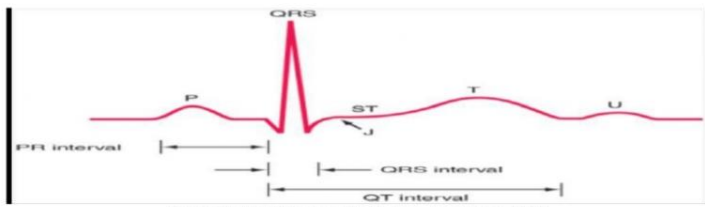
EKG genelde hız 25 milimetre (mm) / saniye (sn) olacak şekilde özel bir kağıda kaydedilir. Bu kağıt üzerindeki yatay çizgiler zamanı temsil eder ve her bir çizgi genelde 1 saniyelik zaman dilimini gösterir. EKG çizelgesi genellikle 10 saniyelik bir kayıt içerir. Yatay çizgiler EKG dalgalarının zamanlama ve ritim özelliklerinin değerlendirilmesine yardımcı olmaktadır. Dikey çizgiler ise genellikle 5 mm aralıklarla çizilir ve voltajı (kalp elektrik aktivitesinin büyüklüğünü) temsil eder. Bu çizgiler, EKG dalgalarının yüksekliğini ölçmek ve kalp ritim bozukluklarını tespit etmek için kullanılır. Örneğin, ST segmentinde yükselme ya da depresyon gibi anormallikler dikey çizgiler üzerinden belirlenebilmektedir (18).



Şekil 6. EKG Kağıdı (18)

2.7. EKG DALGA, SEGMENT VE ARALIKLARI

Einthoven tarafından oluşturulan PQRST sistemi, günümüzde de ortak bir dil oluşturması ve EKG'yi anlamamızı sağlamasından ötürü kullanılmaya devam etmektedir. Belirlenmiş olan dalga, segment ve aralıkları bilmek EKG yorumlayabilmek için olmazsa olmazdır. Temel EKG dalgaları alfabetik sırayla işaretlenmiştir ve bu adlandırma P dalgası ile başlar. QRS kompleksi ventriküler depolarizasyonu temsil ederken; ST segmenti, T dalgası ve U dalgası ventriküler repolarizasyonu temsil eder. QRS kompleksinin sonu ile ST segmentinin başlangıcı arasındaki bağlantı noktasına da J noktası denir (19).



Şekil 7. EKG Dalga Biçimi ve Aralıkları (19)

2.7.1. P Dalgası

Atriyumların depolarizasyonu ve kasılması sırasında oluşur. İlk olarak sağ sonrasında sol atriyum depolarize olur. DIII ve V1'de bifazik, aVR'de negatif olarak gözlenir. Ekstremite derivasyonlarında normal olarak değerlendirilen P dalgası amplitüdü 2.5 mm süresi ise 120 milisaniyedir (msn). Sol atriyumda genişleme olduğunda P dalga süresi uzar ve bu durum P mitrale olarak adlandırılır. P dalgasının amplitüdünde artma gözlenirse bu sağ atriyal genişlemenin göstergesidir ve P pulmonale olarak adlandırılır (19,20).

2.7.2. PR Aralığı

P dalgasının başlangıcından QRS kompleksinin başlangıcına kadar olan süredir. Normalde bu aralık 0.12-0.20 sn olarak ölçülür ve kalbin elektriksel iletim sistemindeki işleyişin normal olup olmadığını göstermesi bakımından önem taşır. PR aralığının uzaması birinci derece AV bloklar ve digoksin toksisitesi gibi durumlarda gözlenebilir. Bu aralığın kısalması ise Wolf Parkinson White (WPW) gibi preeksitasyon sendromlarına ya da AV nodal ritime (AVNRT) bağlı olarak gözlenebilir (21).

2.7.3. QRS Kompleksi

QRS kompleksi, ventrikül depolarizasyon fazını gösteren dalgalar kompleksidir. Kompleksi oluşturan dalgalardan Q dalgası septum depolarizasyonunu gösteren bir negatif defleksiyon dalgasıyken; R dalgası sol ventrikül kasının depolarizasyonunu gösterir ve pozitif yönlüdür. S dalgası ise Q dalgası gibi negatif yönlüdür ve yüksek lateral duvarın depolarizasyonuna karşılık gelir. Normal QRS genişliği 70-100 ms olarak gözlenir. QRS genişliğine göre QRS kompleksinin sinüs, atriyal ya da ventriküler kaynaklı olup olmadığı belirlenebilir. Genellikle 100 msn'den az olan dar komplekslerin supraventriküler kökenli olduğu düşünülür.

100 msn'den geniş komplekslerin ise ventriküler kökenli oldukları ya da supraventriküler komplekslerin anormal iletimine bağlı geliştikleri düşünülür.

Trisiklik antidepresanlar gibi Na kanal bloke edici ajanlar, dal blokları, hiperkalemi ve WPW'de QRS sürelerinin uzaması beklenir (22).

2.7.4. ST Segmenti

QRS kompleksinin sonundan başlayarak T dalgası başlangıcında sona eren aralıktır. Ventriküllerin depolarizasyonu ile repolarizasyonu arasındaki elektriksel olarak sessiz süreyi temsil eder. ST segmentinin ekstremite derivasyonlarında izoelektrik hatta göre 0.5 mm ya da 1 mm eleve yada deprese olması normal olarak değerlendirilir. ST segmentinde meydana gelen elevasyon ya da depresyonların en sık nedenleri akut miyokard infarktüsleridir (AMI). ST segmentinde meydana gelen elevasyonlar benin erken repolarizasyon, dal blokları, perikardit, ventriküler pace ritimleri, koroner vazo spazm, ventriküler anevrizma ve daha birçok durumda görülebilir. ST segment depresyonları ise digoksin toksisitesi durumları, posterior MI, ST eleve AMI'de resiprokal değişiklik ve supraventriküler taşikardiler gibi birçok durumda görülebilir (23).

2.7.5. T Dalgası

Normal bir EKG'de QRS kompleksinden sonra gözlenen pozitif sapma ventrikül repolarizasyonuna denk gelen dalga, T dalgası olarak adlandırılır. aVR ve V1 haricindeki derivasyonlarda pozitiftir. Normal şartlarda T dalga yüksekliği, ekstremite derivasyonlarında 5mm'nin, göğüs derivasyonlarında ise 10 mm'nin altındadır.

Hiperkalemi, AMI, erken repolarizasyon durumlarında bu yükseklikler artabilir ve yüksek T dalgaları görülebilirken; subaraknoid kanama, pediyatrik gruplar, dijital etkisi gibi durumlarda T dalga negatifliği, yani ters T görülebilir. T dalgaları çeşitli sebeplerden ötürü bifazik, ters, düzleşmiş şekilde, deve hörgücü ya da hiper akut T şeklinde prezante olabilir (24).

2.7.6. QT Aralığı

Q dalgası başından T dalgası sonuna kadar olan; yani ventrikül depolarizasyonu ve repolarizasyonu arasındaki süreye, QT aralığı denir. QT aralığı yaş, cinsiyet ve kalp hızı ile değişkenlik gösterebilir kalp hızı arttıkça QT kısalır azaldıkça uzar. Bu yüzden Bazett formülü ile kalp hızına göre düzeltilmiş QT (QTc) hesaplanmaktadır. Bazeet formülünde toplam QT mesafesi, RR mesafesinin karekköüne bölünür ve normalde QTc: 0.36 sn – 0.44 sn gözlenir. Hipokalemi, hipokalsemi, hipomagnezemi, hipotermi gibi durumlarda ve konjenital QT sendromunda uzamış QT gözlenirken hiperkalsemi, digoksin etkisi ve kısa QT sendromunda da QT aralığı kısalmış olarak gözlenir (25,26).

2.7.7. U Dalgası

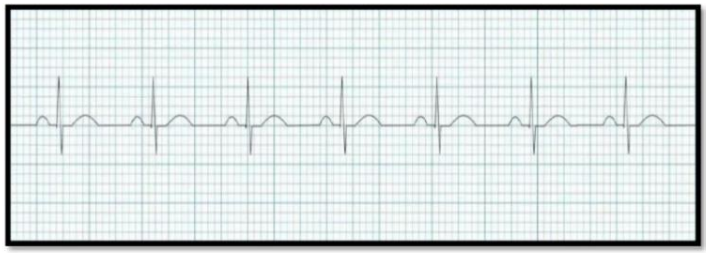
U dalgası T dalgasının genellikle peşinden gelen ve her zaman görülmeyen amplitüdü 2 mm'den küçük bir dalgadır bu düşük amplitüd sayesinde T dalgasından ayrımı çok zor olmaz. Hipokalemide, bradikardide, intrakraniyal hemorajide ve bazı ilaçların kullanımında U dalga görülme sıklığı artar (27).

2.8. EKG RİTİM ANALİZİ VE NORMAL SİNÜS RİTMİ (NSR)

Standart 12 derivasyonlu bir EKG'de ritim analizi, en iyi ekstremite derivasyonlarından DII'ye bakılarak yapılabilir. Elbette diğer derivasyonlardaki bulgular da bu derivasyondan elde ettiklerimizle karşılaştırılmalı ve doğruluğu test edilmelidir. Ritim analizi yapılırken ilk olarak hız değerlendirmesi yapılmalıdır. Normal bir EKG'de kalp hızının dakikada 60-100 atım arasında olması beklenir. Hız değerlendirmesinden sonra QRS komplekslerinin patern ve morfolojilerine bakılır QRS kompleksleri düzenli düzensiz ve dar geniş olmaları açısından incelenir. Ritim analizinde diğer önemli noktalar; P dalgalarının olup olmaması ve P dalgaları ile QRS kompleksleri arasındaki ilişkidir.

Bu basamaklar izlenerek EKG'nin Normal Sinüs Ritminde (NSR) olup olmadığı, bir ritim anomalisi var ise de bunun ne olduğu bulunabilir (28,29).

NSR, normal çalışan bir kalbin standart ritmidir. Bu ritim impulsların SA düğümden çıkarak AV düğüm ile His demetleri ve Purkinje lifleri üzerinden ventriküllere iletilmesini ifade eder. Karakteristik olarak dakikada 60-100 arası vuru gözlenir. Normal bir P dalgası vardır ve her P sonrası QRS kompleksi gözlenir, QRS komplekslerinin genişliği normal ve aralıklar eşittir (30).



Şekil 8. Normal Sinüs Ritmi (30)

2.9. KARDİYAK ARİTMİLER

Acil servise başvuran ve EKG'leri çekilen hastaların önemli bir kısmında ritim bozuklukları gözlenmektedir. Bu durumlarda yaklaşımımız, durumun aciliyeti ve hastanın kliniğine göre şekillenir. Eğer söz konusu hastada hipotansiyon, bilinç bulanıklığı, senkop, şok, kalp yetmezliği, göğüs ağrısı, şiddetli nefes darlığı gibi unstabilite bulguları varsa hastaya acil müdahale kaçınılmazdır. Stabil bir hastada ise değerlendirme için daha fazla zaman vardır. EKG'nin tüm derivasyonlarına, elektrotların doğru yerleştirilip yerleştirilmediğine bakılır. Mümkün olduğu kadar bilgi edinilmesi, tanı açısından mühimdir. Kardiyak aritmiler kaynaklandıkları bölgeye ya da mevcut ritmin çeşidine göre sınıflandırılabilmektedir (31).

2.10. TAŞİARİTMİLER

Taşiaritmi, yetişkin grupta kalp hızının dakikada 100 vurudan fazla olması; çocuklarda ise belirlenen yaş aralığına göre kalp hızının daha fazla olmasıdır. Tüm unstabil taşiaritmili hastalarda öncelik, senkronize kardiyoversiyon yapılması olmalıdır. Ritmin spesifik teşhisi sonradan yapılabilir çünkü başlangıç tedavi yaklaşımlarında fark yoktur.

Son yıllarda hastalar, stabil ya da unstabil olarak değerlendirilmekten ziyade; hemodinamik olarak stabil olmaları ve kardiyak fonksiyonlarının korunmuş olup olmamalarına yönelik değerlendirilmektedir. Taşiaritmiler QRS morfoloji ve paternlerine göre düzenli düzensiz; dar geniş olarak sınıflandırılmıştır. SVT'ler, AV nodun üstü ya da içindeki bir odaktan kaynaklanır ve QRS kompleksleri dar olarak gözlenir. VT'ler ise AV nodun altında ventrikül kısmındaki miyokardlardan kaynaklanır ve QRS kompleksleri geniş olarak gözlenir (31).

2.11. DAR KOMPLEKS (SUPRAVENTRİKÜLER) TAŞİARİTMİLER

Sıklıkla konjenital kalp hastalığı olmayan sağlıklı insanlarda görülen çoğu benign karakterdeki ritimlerdir. Ancak yaşamı tehdit edebilecek şekilde de karşımıza çıkabilirler. Kendi içlerinde de düzenli ve düzensiz olmalarına göre ayrılırlar (32).

2.11.1. Sinüs Taşikardisi

Ritim düzenlidir ve normal P dalgaları mevcut olup PR aralıkları sabittir. Genelde yetişkinlerde dakikada 100 üzerinde atım olması beklenir. Fizyolojik olarak gözlenebileceği gibi kullanılan ilaçlara bağlı olarak; ya da ateş, hipoksi, anemi, pulmoner emboli gibi durumlarda görülebilir. Spesifik bir tedavisi yoktur. Yaklaşım altta yatan nedeni çözmeye yöneliktir (33).



Şekil 9. Sinüs Taşikardisi (33)

2.11.2. Atriyal Taşikardi

Atriyum içerisinden fakat sinüs düğümü dışından kaynaklanan, paroksismal ya da unifokal atriyal taşikardi olarak da bilinen düzenli bir ritimdir. Atriyal flutter ve multifokal atriyal taşikardi atriyal taşikardinin alt gruplarıdır. Paroksismal ya da sürekli olabilir ve sıklıkla bir ektopik odaktan kaynaklanır.

Dijital toksisitesinde, katekolamin alımı sonrasında ve konjenital kardiyak patolojilerde ve daha birçok durumda görülebilir. Sinüs taşikardisinden farklı olarak P dalgaları anormal morfolojide gözlenir. Atriyal atım dakikada 100 vuru üzerindedir (34).



Şekil 10. Atriyal Taşikardi (34)

2.11.3. Atriyal Fibrilasyon

En sık görülen aritmi çeşidi olup insidansı her geçen gün artış göstermektedir. Düzensiz ve birden fazla ektopik odaktan kaynaklanan bir ritimdir. P dalgası gözlenmez, QRS kompleksi normal genişliktedir, RR mesafeleri düzensizdir. 40 yaşın üzerinde Atriyal fibrilasyon (AF) görülme riski yaklaşık %25 oranındadır. İskemik kalp hastalıkları, pulmoner emboli, preeksitasyon sendromları, akut enfeksiyonlar, elektrolit bozuklukları ve daha birçok durum AF'ye neden olabilir (35).

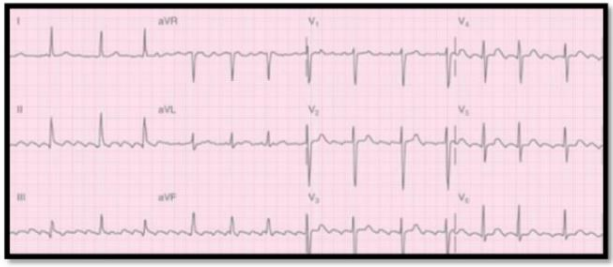
AF gözlendiği süre ve klinik prezantasyonuna göre sınıflandırılır. Semptom ve süreye bakılmaksızın ilk kez gözlenirse ilk epizod olarak; 2'den fazla kez görülürse rekürren AF olarak adlandırılır. 7 güne kadar kendiliğinden yok olursa paroksismal AF; 7 günden fazla olan ve kendi kendine yok olmayan AF ise inatçı AF olarak adlandırılır. 1 yıldan uzun süren AF inatçı uzun süreli AF; müdahalelerin başarısız olduğu 1 yıldan fazla süren AF'ye kalıcı AF denir. Ritim kontrolü, antikoagülasyon gerekliliğinin değerlendirilmesi ve altta yatan hastalıkların tedavisi AF yönetiminde temel basamakları oluşturur (36).



Şekil 11. Atriyal Fibrilasyon (36)

2.11.4. Atriyal Flutter

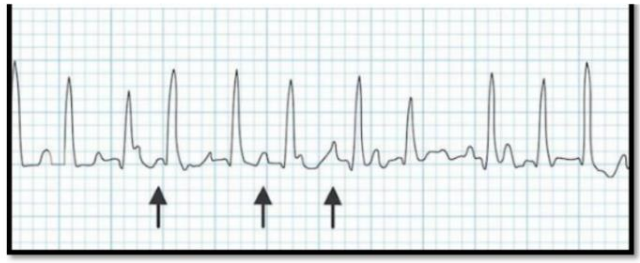
Sağ atriyumdan köken alan, atriyal hızın dakikada 250-300 arasında olduğu, P dalgalarının testere dişi şeklinde gözlendiği düzenli bir ritimdir. AV noddan dakikada 200' den fazla geçemediğinden oluşan P dalgalarının hepsi ventriküllere iletilemez ve bu durum sıklıkla 2:1, 3:1 ve 4:1 AV blok oluşmasına neden olur. Hatta bazen bu bloklar da anlık değişkenlik gösterebilir ve bu durum değişken bloklu atriyal flutter olarak adlandırılır. Tedavi yine AF'de olduğu üzere ritim kontrolü, hız kontrolü ve antikoagülasyon basamaklarından oluşur (37,38).



Şekil 12. Atriyal Flutter (37)

2.11.5. Multifokal Atriyal Taşikardi (MAT)

Atriyumda birçok odaktan gelen uyarılarla oluşan, düzensiz karakterde bir ritim olup kaotik atriyal taşikardi de denir. Artan atriyal otomasiteye bağlı olarak genelde kalp hızı dakikada 100-150 vuru olarak gözlenir. Tek derivasyonda en az 3 değişik P dalga tipi gözlenebilmektedir. En sık kalp yetmezliği ya da koah tanılı solunum sıkıntısı yaşayan hastalarda gözlenir. Tedavi yine altta yatan nedeni düzeltmeye yöneliktir (39).

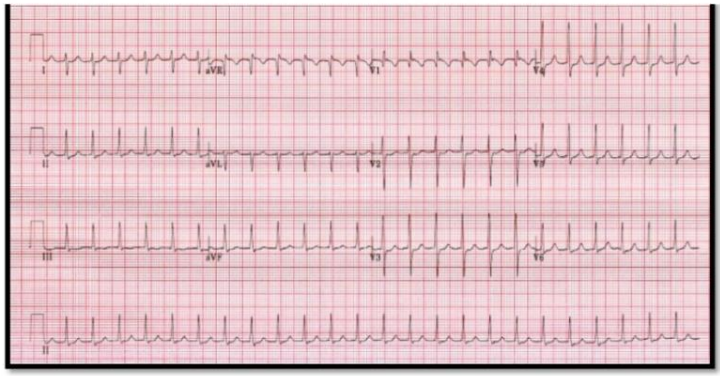


Şekil 13. Multifokal Atriyal Taşikardi (39)

2.11.6. AV Nodal Re – Entran Taşikardi (AVNRT)

AVNRT, yapısal kalp hastalığı olmayanlarda en sık çarpıntı nedenlerindendir. Tüm popülasyonda en sık görülen SVT çeşididir. Kadınlarda daha sık gözlenir ve kalp hızına bakıldığında dakikada 140 ile 280 arası bir atım söz konusudur. Efor sonrasında ya da kafein, sempatomimetik, beta agonist kullanımı sonrasında ortaya çıkabileceği gibi spontan olarak da görülebilir. Tipik olarak ani başlayan çarpıntılar gözlenir ve devamında bir senkop ya da presenkop durumu olabilir. Genellikle tedavi gereksinimi olmadan sonlansa da altta yatan kalp hastalığı olanlarda anjina benzeri göğüs ağrısına neden olabilir (40,41).

AVNRT'de dal bloğu ya da aberran ileti olmadıkça, diğer SVT ritimlerindeki gibi dar QRS kompleksleri görülür. P dalgaları genellikle QRS komplekslerinde gömülü olduklarından görülemezler. AVNRT alt gruplandırması yapılırken de P dalgaları dikkate alınır. P dalgası görülmeyen grup %90'ını oluşturur ve yavaş-hızlı AVNRT olarak adlandırılır. Bu ritim de bir SVT çeşidi olduğundan tedavisi de önce vagal manevra ile başlar, yanıt alınamadığında adenozine geçilir sonraki seçimler ise beta blokörler, Ca kanal blokörleri ve amiodorondur. Çok nadir olarak kardiyoversiyona gidilir. Devamlı gözlenen ve medikal tedavinin yetersiz olduğu durumlarda kateter ablasyonu yapılabilir (41).



Şekil 14. Tipik Yavaş-Hızlı AV Nodal Re-Entran Taşikardi (41)

2.11.7. AV Re – Entran Taşikardi (AVRT)

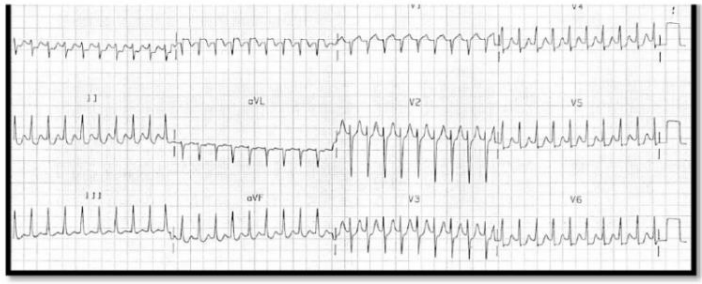
AVRT, normal AV iletim sisteminin yanına aksesuar bir yol eklenmesiyle meydana gelen bir SVT çeşididir. AVRT'de, normal iletim sistemi sayesinde uyarı AV düğümden ventriküllere her zamanki gibi geçer ancak burada anormal olarak iletilmiş uyarı, oluşmuş aksesuar yolu kullanarak atriyumun kasılmasına neden olur.Uyarı buradan tekrar AV düğüme döner ve böylece döngü başlamış olur. Bu mekanizma ortodromik iletimli AVRT'nin mekanizmasıdır ve antidromik olan tipine göre daha sık görülür (42,43).

Antidromik tipte, anterograd iletim diğerinin tersine aksesuar yoldan, retrograd iletim ise AV düğüm üzerinden olur. Antidromik iletimli AVRT, WPW hastalarının %5'inde gözlenebilir ve ortodromik AVRT'den farklı olarak QRS'ler geniştir. Bu da ventriküler taşikardi ile karışmalarına neden olabilir. Antidromik AVRT'li, hemodinamisi stabil, hastalarda prokainamid veya ibutilid verilebilirken lüzum halinde kardiyoversiyon düşünülebilir (42,43).

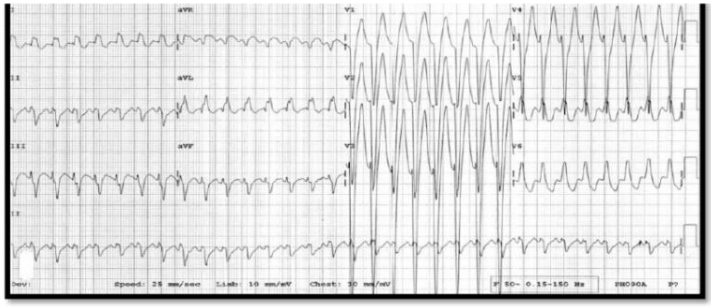
Ortodromik EKG'de kalp hızı genelde dakikada 200 ile 300 vuru arasında değişir. P dalgaları ise genelde QRS içerisinde ya da retrograd şekilde gözlenebilir.

Ayrıca EKG'de yaygın T dalga inversiyonları ve ST depresyonları da gözlenebilmektedir. Ortodromik AVRT tedavisi yaklaşımı ise SVT tedavi yaklaşımı

gibi olup önce vagal manevra ardından adenozin, beta blokör, Ca kanal blokörü ve lüzum halinde kardiversiyon önerilmektedir (42,43).



Şekil 15. Ortodromik AVRT (43)



Şekil 16. Antidromik AVRT (43)

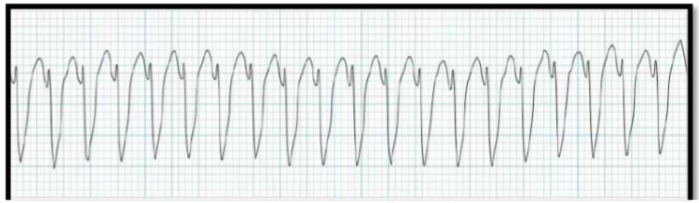
2.12. GENİŞ KOMPLEKS TAŞİKARDİLER

WCT , QRS komplekslerinin geniş olarak izlendiği; VT'ler ile anormal iletimli SVT'leri kapsar. Hemodinamisi stabil bir hastanın WCT'sini sonlandırmak için ilk tercih olarak prokainamid; sonrasında amiodoron, lidokain ve magnezyum önerilmektedir. Yine hemodinamisi unstabil olan hastalarda kardiyoversiyon önerilir (44).

2.12.1. Monomorfik Ventriküler Taşikardi

Ventrikül kaynaklı olduğu düşünülen ve WCT'lerin olduğu tek bir odaktan kaynaklanan düzenli bir ritimdir. Kardiyak nedenli ölümlerin önemli kısmından sorumlu olan ölümcül bir aritmi çeşididir. Her atımdaki QRS kompleksleri aynı morfolojidedir. Sıklıkla QRS genişlikleri 160 ms'den fazladır. P dalgaları ve QRS komplekslerinin hızları birbirinden farklı olup atriyoventriküler ayrışma gelişebilir buna AV disosiyasyon denir. Prekordiyal derivasyonların tamamı ya negatif ya da pozitif olur ve RS gözlenmez (45).

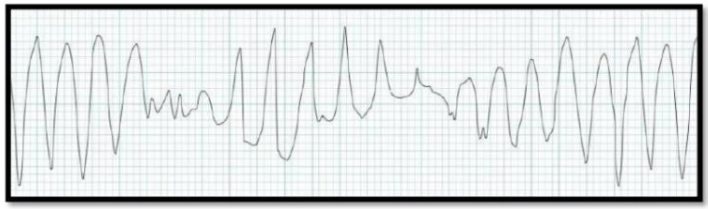
Atriyal atımlar ile ventriküler atımların çakışıp oluşturduğu hibrit vurular, füzyon vuruları olarak adlandırılır ve görülmeleri VT lehinedir. Brugada belirtisi, QRS başlangıcından S dalgasının en altına olan mesafenin 100 ms'den fazla olmasını kapsar ve VT ayrımında kullanılabilir. Bir başka VT lehine bulgu ise Josephon işareti olup yine S noktasının D III'te en alt noktasına yakın çentiklenmeyi ifade eder. İskemik kalp hastalıkları ve kardiyomiyopatilerde gözlenebilir. VT ritmi akut kalp yetmezliği ve hipotansiyon ile kalp debisinin bozulmasına neden olabilir; azalan debi sonrası ritmin VF'ye dönme ve kalp kasının perfüzyonunun bozulma ihtimalleri yükselir. Bu yüzden ritmin hızlıca tanınarak lüzum halinde kardiyoversiyon yapılması hayati öneme sahiptir. Stabil VT'de ventrikül fonksiyonu korunmuşsa prokainamid, amiodoron, sotalol ya da lidokain tercih edilebilir. Ritmin analizi net olmasa dahi VT şüphesi varsa VT olarak yaklaşım önerilir (45,46).



Şekil 17. Monomorfik VT (46)

2.12.2. Polimorfik Ventriküler Taşikardi ve Torsades de Pointes

Birden fazla ventriküler odağın olduğu; QRS komplekslerinin farklı amplitüd, genişlik ve eksende olduğu bir VT çeşididir. En yaygın olarak miyokard enfarktüslerine bağlı olarak gelişir. Eğer bu ritme QT uzaması da eşlik edecek olursa Torsades de Pointes olarak adlandırılır. En sık görülen Polimorfik VT çeşididir. Genellikle kendiliğinden sonlanmasına rağmen VF'ye dönüşebilmesi açısından tehlikeli bir disritmidir. QT uzaması elektrolit bozukluklarını akla getirir ve monomorfik VT'den farklı olarak tedavide Mg da kullanılır (47).



Şekil 18. Torsades de Pointes (47)

2.12.3. Ventriküler Fibrilasyon (VF)

VF her zaman ölümcül olan, hızlı bir şekilde ileri yaşam desteği gerektiren ve şoklanabilir bir kardiyak arrest ritmidir. P dalgası, QRS kompleksi ya da T dalgası ayırt edilemez ve düzensiz kaotik sapmalar gözlenir. Ventriküller dakikada 500'den fazla vuru ile kasılmaya çalışır ancak bu hızlı ve düzensiz uyarılar ventrikül kasılmasının bozularak kardiyak outputun azalmasına neden olur. Kalp başıboş anlamsız kasılmalar yüzünden pompa görevini yitirir. İleri yaşam desteği geciktikçe ritim kaba VF'den ince VF'ye ondan da asistoliye dönüşür. Elektrolit bozuklukları, Brugada sendromu, miyokard iskemisi, kardiyak tamponad ve daha birçok nedenle

oluşabilir. VF asla 12 derivasyonlu bir EKG ile tanınmamalıdır, monitörde ritim görüldüğü gibi ileri yaşam desteğine başlanılmalıdır (48,49).



Şekil 19. Ventriküler Fibrilasyon (49)

2.13. BRADİARİTMİLER

Bradiaritmi, yetişkin grupta kalp hızının dakikada 60 vurudan az; çocuk yaş grubunda ise yaşa uygun kalp hızının altında gözlenmesi olarak ifade edilir. Genç ve atletik bir bireyde bu ritim normal kabul edilirken, başka hastalarda bir hastalık göstergesi olabilir. Burada durumun ciddiyeti ve semptom oluşup oluşmaması, kardiyak outputun etkilenip etkilenmemesi ile ilgilidir. Öyle ki kardiyak outputtaki azalma birçok organın beslenmesini bozabileceğinden birçok organda iskemi ve yetmezlik meydana gelir. Kalp hızı, hastanın yaşına ve ek hastalıklarına sahip olduğu klinik duruma göre farklılık gösterir.

Bradiaritmiler, bradikardiler ve AV bloklar şeklinde sınıflandırılır. En sık görülen bradikardi sinüs bradikardisi olup ikinci sıklıkta ise kavşak ritmi gözlenir.

Diğer bradiaritmi grubu olan AV bloklarda ise en sık ikinci derece AV blok gözlenir ancak hemodinamik olarak unstabil bir hastada en çok üçüncü derece AV blok gözlenmektedir (50).

Tedavi yaklaşımı tıpkı taşiaritmilerdeki gibi hastanın hemodinamisinin stabil ya da unstabil oluşuna göre şekillenir. Semptomları olan bradikardik hasta derhal gözleme alınarak monitörize edilmelidir. Hemodinami unstabil ise ilk seçenek olarak atropin önerilir; sonrasında dopamin ve epinefrin tedavilerine geçilebilir.

Hemodinami hala düzelmemiş olursa transkutan pace endikasyonu mevcut olur (50,51).

2.13.1. Sinüs Bradikardisi

P dalgalarının ve QRS komplekslerinin normal olarak gözlendiği; yetişkinde kalp hızının dakikada 60 vurudan az olduğu düzenli ritimdir. Hipotiroidizm, artmış vagal tonus, uyku hali; organofosfat zehirlenmesi, opioid alımı gibi durumlarda gözlenebilir. Hemodinamik olarak stabil ve asemptomatik kişilerde müdahale edilmez (52).

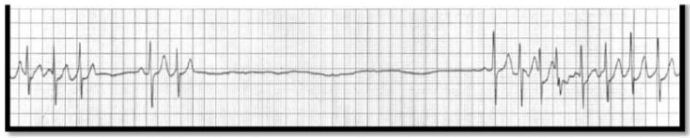


Şekil 20. Sinüs Bradikardisi (52)

2.13.2. Hasta Sinüs Sendromu

Sinüs düğümünün çalışması ve fonksiyonunda meydana gelen patoloji nedeniyle oluşan bradikardi ve kalp yetmezliği durumudur. Elektrolit bozuklukları, hipotiroidizm, idiyopatik dejeneratif fibroz kaynaklı olabildiği gibi; dijital kullanımı, beta blokör ve Ca kanal blokörü kullanımına sekonder de gözlenebilir. EKG bulguları değişken olabilmektedir. Sinüs bradikardisi ya da sinüs düğümü uyarılarının 3 sn'den uzun süre geçici olarak durduğu, sinüs arresti ya da bradikardi-taşikardi sendromu (uzun sinüs duraklamaları arasında görülen taşiaritmiler) ile prezante olabilir. Kardiyak ouputun azalmasına bağlı olarak hipoperfüzyondan kaynaklı senkop ve çarpıntı görülebilir. Eğer semptomatik ve dökümante edilmiş bir

bradikardi varsa ve uygulanan medikal tedavilere yeterli cevap alınamazsa kalıcı pace takılması sınıf I öneridir (53,54).

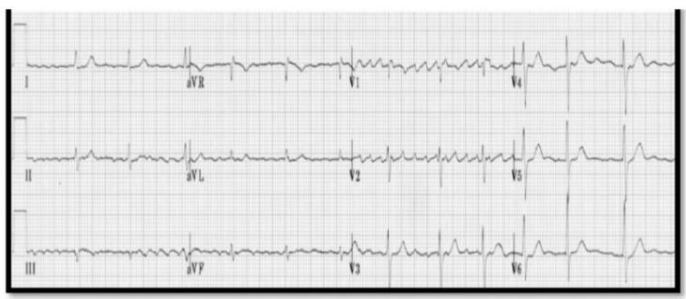


Şekil 21. Hasta Sinüs Sendromu - Bradikardi Taşikardi Sendromu (54)

2.13.3. Kavşak Kaçış Ritmi

Normal şartlarda SA nod tarafından dakikada 60-100 arasında olacak şekilde üretilen impulsların yavaşlamasından; ya da AV noda iletilememesinden kaynaklanan ve aktive olan kavşak kaçış atımları; dakikada 40-60 atım olacak şekilde impuls üretmeye başlar ve oluşan bu ritme AV nodal ritim ya da kavşak kaçış ritmi denir. QRS kompleksleri genelde dar gözlenir ve genelde öncesinde P dalgası gözlenmez. Şiddetli sinüs bradikardisi, SA çıkış bloğu, üçüncü derece AV blok, toksidromlar ve elektrolit bozukluklarında görülebilir.

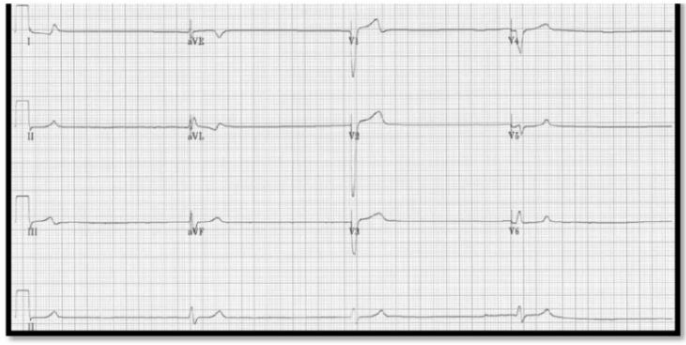
Tek başına olan kavşak ritimlerinde tedavi önerilmezken; semptomatik olanlarında altta yatan sebebin tedavisi önerilir. Atropin SA nod deşarjını ve AV nod iletimini arttırıp düzenleyebileceğinden kullanılabilir (55,56).



Şekil 22. Kavşak Kaçış Ritmi (56)

2.13.4. İdiyoventriküler Kaçış Ritmi

Ventriküllerdeki miyokard ya da purkinje liflerinden köken alan; herhangi bir atriyal aktivite bulgusu göstermeyen WCT'lerin olduğu düzenli bir bradiaritmi çeşididir. Normalde hız dakikada 40 vuruşun altındayken; akselere idiyoventriküler ritimde bu hız 50-110 arasında gözlenmektedir. İdiyoventriküler ritim, en sık ST eleve miyokard enfarktüsü (STEMI) geçiren hastalarda gözlenir. Semptom olarak senkop, hipotansiyon, dispne, çarpıntı gözlenebilir. Hızlanmış yani akselere olan çeşidi ise daha çok kokain dijital gibi ilaçların toksidromunda ve de elektrolit bozukluklarında görülür; genellikle tek başına semptom oluşturmaz ancak azalan kardiyak debi ve hipoperfüzyona sekonder hemodinami bozulabilir. Semptomatik ve hipoperfüzyona bağlı bulgular gözlenen idiyoventriküler ritimde, kalp hızını arttıran ilaçlar kullanılması önerilir. Atropinin ise tedavide etkinliği düşük bulunmuştur yine de uygulanması kontrendikasyon oluşturmaz (55,57).



Şekil 23. Ventriküler Kaçış Ritmi ile Sinüs Arresti (57)

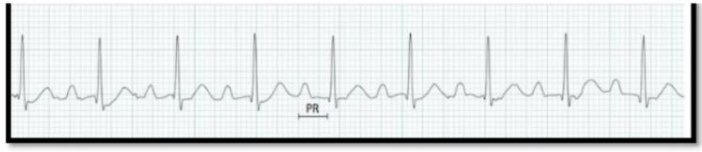
2.14. KALP BLOKLARI VE İLETİM ANORMALLİKLERİ

SA düğümden çıkan uyarıların AV düğüme, oradan da His demetleri ve Purkinje liflerine iletimi sırasında, herhangi bir aşamada oluşabilecek patoloji; bize

oluştuğu yerle ilgili iletim anormalliği ve ritim bozukluğu olarak yansır. Kalp blokları his demetinde meydan gelen engellenme ya da iletimin gecikmesi sonrası ventriküllerin anormal şekilde kasılmasına neden olan durumlardır. Kalp blokları ve iletim anormallikleri çarpıntı, baş dönmesi, dispne, göğüs ağrısı gibi semptomlara neden olabilirler (58).

2.14.1. Birinci Derece AV Blok

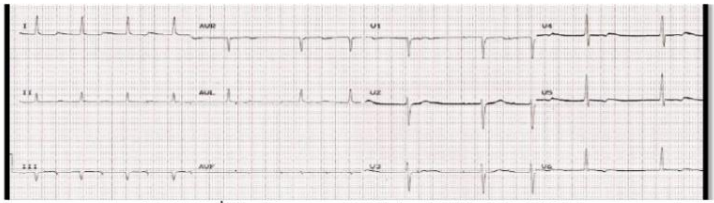
AV iletide gecikme mevcuttur ve buna bağlı olarak PR aralığı 0.20 sn'den uzun gözlenir. Ancak her ileti ventriküle iletilmeye devam eder, bu yüzden düzenli bir ritimdir ve her P dalgasını bir QRS kompleksi izler. Artmış vagal tonus, toksidromlar ve AMI'da gözlenebilir. Altta yatan hastalığı olmayanlarda selim seyrederken halihazırda kardiyak hastalıkları olanlarda AV tam blok açısından yüksek riske işaret eder (58).



Şekil 24. Birinci Derece AV Blok (59)

2.14.2. İkinci Derece AV Blok – Mobitz Tip 1

AV nod iletiminin aralıklı bozulmasıyla, EKG'de PR aralığının giderek uzadığı ve en son bir P dalgasının iletilmediği blok tipidir. Wenckebach fenomeni olarak da bilinir. Artmış vagal tonus, kalp kapak operasyonları, inferior MI; digoksin, b blokör benzeri ilaç kullanımları durumlarında izlenebilir. Genellikle tedaviye yanıt olmayan selim bir ritimdir ancak az da olsa tam bloğa ilerleme riski vardır. Semptomatik hastalar genelde atropine yanıt verir çok nadiren kalıcı pace gereksinimi olur (60,61).



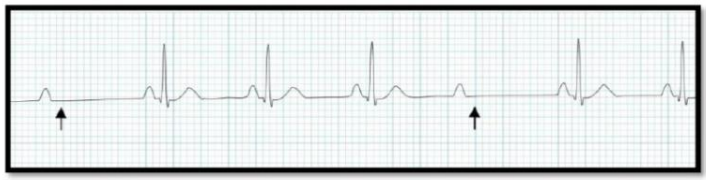
Şekil 25. İkinci Derece AV Blok - Mobitz Tip 1 (61)

2.14.3. İkinci Derece AV Blok – Mobitz Tip 2

Genellikle infranodal yani His ya da Purkinje liflerinden köken alan aralıklı bir iletim bozukluğu mevcuttur. PR aralığı normal olarak gözlenir ancak iletim sırasında QRS kompleksinin eşlik etmediği P dalgaları gözlenir.

Birden fazla bu şekilde P dalgası görülürse yüksek dereceli AV blok olarak adlandırılır. Sıklıkla dal blokları ve fasiküler blok eşlik ettiğinden gözlenen QRS kompleksleri geniştir.

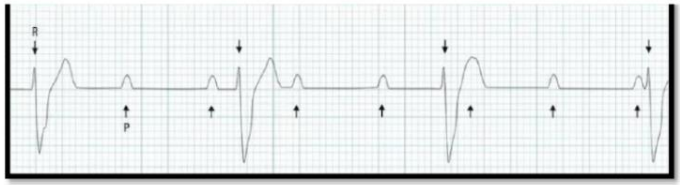
Mobitz tip 2 bloklar daima patolojik olup infranodal iletim sisteminde yapısal anormaliyi düşündürür. Bu blokların beraberinde miyokardda iskemi de olursa tam bloğa ilerleme riski yüksektir. Hastanın acil servisteki gözleminde olası bir ihtiyaç için trans kutan pace pedleri uygulanmalıdır; hipoperfüzyon bulguları gözlenir gözlenmez pace uygulamasına geçilmelidir. Atropin, etkilerinin tutarlı olmaması nedeniyle çok önerilmemektedir, miyokard iskemisi gözlenen hastada son seçenek transvenöz kalp pilidir (62).



Şekil 26. İkinci Derece AV Blok - Mobitz Tip 2 (63)

2.14.4. Üçüncü Derece AV Blok (Tam Blok)

AV nodda iletimin tamamen bozulması nedeniyle atriyoventriküler disosiyasyon yani ayrışma gerçekleşir. Bu durum EKG'de P dalgaları ve QRS kompleksi arasındaki ilişkinin bozulması olarak karşımıza çıkar. P dalgaları düzenli şekilde oluşurken onları bir QRS kompleksi izlemez. Atriyal hız dakikada yaklaşık olarak 100 atım olarak izlenirken ventriküler hız dakikada yaklaşık 40 atım olarak gözlenir. Tam blok ritmi, ventrikül arresti ve ani kardiyak ölüm açısından çok risklidir. Tedavi yaklaşımında öncelikli olarak geçici pace devamında da sıklıkla kalıcı pace takılması önerilir (64).

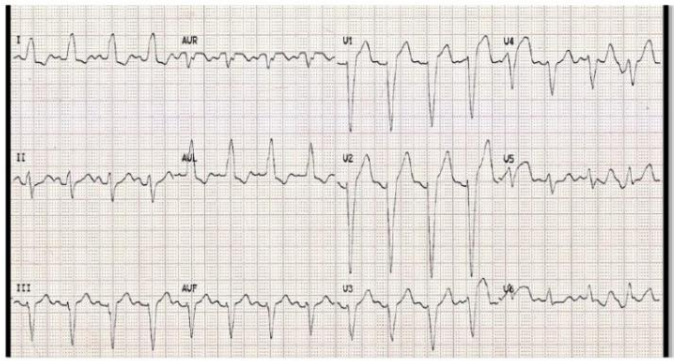


Şekil 27. Üçüncü Derece AV Blok (64)

2.14.5. Sol Dal Bloğu (LBBB)

İletim sisteminde meydana gelen dejenerasyon ya da miyokardiyal hasar sonrası gözlenir. Normal elektriksel iletimde impulslar sağ ve sol demette eşit ilerlerken; septum soldan sağa uyarılır ama LBBB'de ileti gecikmesinden ötürü ventriküler depolarizasyon sağdan sola gözlenir. QRS kompleksleri 120 ms'den geniş olarak gözlenir ve V1'de S dalgası baskındır. Lateral derivasyonlar olan DI, aVL, V5-6'da geniş ve çentikli R dalgası gözlenir, ancak Q dalgası gözlenmez. Bunlara ek olarak V5-6'da R dalgasına ait tepe süresi 60 milisaniyeden fazla görülür. QRS kompleksi ile ST/T dalgaları arasındaki diskordans normal olarak gözlenir. Genellikle LBBB'ye altta yatan organik bir patoloji eşlik eder. Nedenleri arasında aort darlığı, iskemik kalp hastalığı, elektrolit bozukluğu, dijital toksisitesi

sıralanabilir (65). Göğüs ağrısı ile prezante olan yeni LBBB önceden STEMI eşdeğeri kabul edilirken son çalışmalar ve edinilen veriler ışığında bu yaklaşım terk edilmiştir. Ancak yine de akut koroner sendroma (AKS) eşlik etmesi yüksek riskli olarak sınıflandırılmaktadır. AKS şüphesinde Sgarbossa kriterlerine başvurulabilir (66).

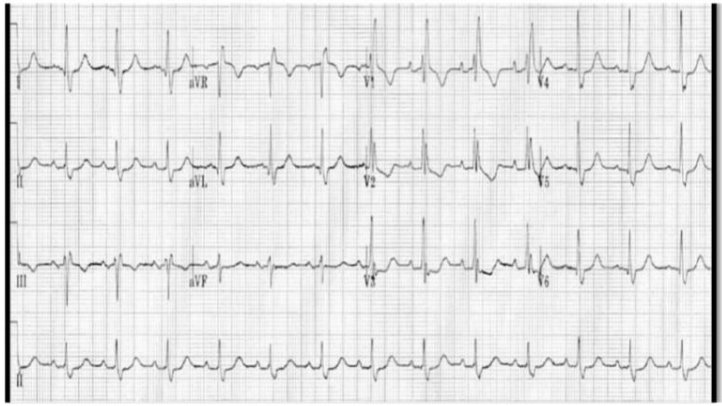


Şekil 28. Sol Dal Bloğu (66)

2.14.6. Sağ Dal Bloğu (RBBB)

RBBB'de bu kez depolarizasyon, septum ve sol ventrikül üzerinden sağa doğru olur bu yüzden de sağ ventrikülün uyarılması gecikir. Sol ventrikülün uyarılması normal olduğundan QRS kompleksinin ilk parçasında değişiklik gözlenmez. Geciken sağ ventrikül uyarımı nedeniyle sağ göğüs derivasyonları olan V1-3'te R' olarak adlandırılan yeni bir R dalgası gözlenir. Lateral derivasyonlarda ise geniş,uzun S dalgası gözlenir. Ayrıca yine sağ göğüs derivasyonlarında ST depresyonu ve T dalga inversiyonu beklenir. QRS kompleksi yine 120 ms'den geniş gözlenir. İskemik kalp hastalıklarında, pulmoner embolide, kardiyovasküler hastalıklarda ve sağ ventrikül hipertrofisinde görülebilir. Son dönemde artan sayıda

literatürde, yeni geliştiği düşünülen RBBB'nin göğüs ağrısı ile birlikte olmasının kötü prognoz habercisi olduğu ve reperfüzyon için potansiyel bir endikasyon olduğu vurgulanmaktadır (67,68).



Şekil 29. Sağ Dal Bloğu (68)

2.15. VT – SVT AYRIMI

VT-SVT ayrımını yapmak, hastaya uygulanacak tedavi yaklaşımımızı belirleyeceğinden son derece önemlidir. Bu konuda birçok çalışma yapılmasına ve konu üzerine algoritmalar oluşturulmasına rağmen ne yazık ki yanlış teşhisler hala çok yaygındır (69).

Ritim analizi sağlıklı yapılamayan bir hastaya AV düğüm bloke edici ajan verilirse ve ritim VT ise hemodinaminin bozularak hastanın kötüleşmesine neden olabilirken; ritim SVT ise aynı ilaç bu kez doğru yerde ve hastanın faydasına kullanılmış olur. VT şüphesi olan bir durumda ritmin VT kabul edilerek buna göre tedavi edilmesi önerilmektedir (70).

EKG yorumlarken ritmi VT olarak düşündürebilecek bazı özellikler :

- LBBB ya da RBBB gözlenmemesi
- Aksta meydana gelen fazla sapma, kuzeybatı aksının gözlenmesi, D1 ve aVF'de negatif QRS kompleksi gözlenirken aVR'de pozitif QRS kompleksi gözlenmesi
- QRS komplekslerinin genişliklerinin 160 ms'den fazla olması
- AV disosiyasyon da denilen atriyoventriküler ayrışmaya bağlı olarak, P dalgaları ile QRS komplekslerinin birbirinden bağımsız olması
- Ventrikülün aynı anda hem ventriküler hem de supraventriküler uyarı alarak kasılması sonucu oluşan hibrit karakterdeki füzyon atımlarının olması
- Normal QRS üretebilmek için SA nodun AV disosiyasyon sırasında geçici olarak ventrikülleri yakalamasıyla oluşan yakalama vurularının olması
- Göğüs derivasyonlarının tamamında QRS komplekslerinin ya pozitif ya negatif olması anlamına gelen negatif ya da pozitif konkordans varlığı ve yine bu derivasyonların tamamında RS kompleksinin olmaması
- QRS kompleksi başından S dalgasının en altına olan uzaklığın 100 ms' den fazla olması olarak adlandırılan Brugada işaretinin olması
- S dalgasın en alt ucu komşuluğunda oluşan çentiklenme yani Josephson işaretinin olması
- Sol tarafta daha uzunca bir tavşan kulağına eşlik eden RSR' kompleksinin varlığının olması ise VT için en patognomonik bulgudur (71,72).

Yukarıda bahsedilenlere ek olarak hastanın yaşının 35'ten büyük olması; iskemik ya da konjenital bir KVH varlığı; ailede erken yaşta kardiyak sebepli ölüm öyküsü olması da VT olasılığını arttırır. VT-SVT ayrımı için çeşitli algoritmalar

geliştirilmiştir bunlardan en yaygın kullanılan ve bilinenleri ise Brugada ve Vereckei aVR algoritmalarıdır (71,72).

2.15.1. Brugada Algoritması

Bu algoritmada ilk maddelerden sona doğru gidilir; maddelerden herhangi birinde pozitiflik olması durumunda VT tanısı konmuş olur.

1. Göğüs derivasyonlarının hiçbirinde RS kompleksinin olmaması
2. Herhangi bir göğüs derivasyonunda RS arası mesafenin 100 ms'den fazla olması
3. AV ayrışma yani disosiyasyonun olması
4. QRS kompleksinin V1-2 ve V6'de gözlenen morfolojisine bakılır V1'de R dalgası baskınsa RBBB benzeri kriterlere, S dalgası baskınsa LBBB benzeri kriterlere göre karar verilir (71,72).

2.15.2. Vereckei Algoritması

Bu algoritma birçok bakımdan Brugada algoritması ile örtüşür. Ancak en büyük artısı aVR'deki QRS kompleksini ele almasıdır. Brugada'da olduğu gibi yukarıdan aşağı basamak şeklinde ilerlenir ve herhangi bir kriter pozitif olursa VT tanısı konulmuş olur (73,74).

1. AV disosiyasyon var ise VT tanısı konur yok ise diğer basamağa geçilir
2. aVR'de ilk R dalgası mevcut ise VT düşünülür yok ise diğer basamağa geçilir.
3. Dal blokları ya da fasiküler bloklardan farklı bir QRS kompleks morfolojisi var mı bakılır varsa VT olarak değerlendirilir aksi halde son basamağa geçilir.

4. QRS kompleksinin ilk 40 ms'deki voltaj değişim değeri olan Vi'nin; son 40 ms'deki voltaj değişim değeri olan Vt'ye oranı 1'e eşit ya da ondan küçükse, VT düşünülür aksi halde tanıdan uzaklaşılır (73,74).

2.16. TIPTA YAPAY ZEKA

AI bilgisayar sistemlerinin tıpkı insanlar gibi düşünüp öğrenmesine ve karar vermesine olanak sağlayan bilim dalıdır. Temelde insanların bilişsel fonksiyonları, yaptıkları işler ve verdikleri kararlar taklit edilerek oluşturulmuştur. Matematik, istatistik, bilgisayar bilimleri ve mühendislik gibi birçok disiplinden destek alınarak hayata geçirilmiştir (75).

1950'lerde ilk kez Alan Turing ve John McCarthy tarafından insan zekasına sahip akıllı makineler yapılması fikri ile gündeme gelse de, oluşturulan ilk modellerdeki bazı problemler ve sınırlamalar nedeniyle başlarda yaygın olarak kabul görmemiştir. Haliyle bu sınırlamalar ve problemler yüzünden, tıp alanında da sahneye çıkışı zaman almıştır. İlk zamanlarda daha çok insansı çıkarımlar yapıp kararlar verilebilecek makinelerin yapılmasına odaklanılmıştır. 1960-1970 arasında, adım adım komutları takip edebilen endüstriyel robot kol, sonrasında insan konuşmasını taklit edebilen bir robot yapılmıştır. Sonrasında ise Shakey isimli talimatları yorumlayabilen hareketli bir robot dahi yapılmıştır ki bu robot, AI ve robot bilimi için büyük bir başarı olarak kabul edilmiştir. Mühendislikte gözlenen tüm bu gelişmelerin yanında tıp alanında yapay zeka etkileri uzunca bir süre görülememiştir. 1970'e gelindiğinde nihayet CASNET adı verilen glokom için bir veri tabanı tasarlanmıştır. Bu model belirlenen hastalık hakkında öğretilen bilgiler ile doktorlara hasta yönetimi hakkında bilgiler sağlayabilmiştir. 1980'de ayırıcı tanıda kullanılan programlar ve elektronik ders kitapları oluşturulmuş; AI uygulamaları yaygınlaşmaya başlamıştır. 2000'li yıllarda ML ve DL alt disiplinlerinin gelişmesiyle tıpta AI kullanım alanları giderek fazlalaşmıştır (76).

Günümüzde AI, hastalıkların tanı ve teşhislerinin yapılmasına yönelik radyolojik görüntü ve biyopsi sonuçlarının değerlendirilmesinde; tedavi planları, ilaç doz ve sürelerini hesaplamada; hastalıkların önceden tahmini konusunda kanser gibi

hastalıkların erken teşhisinde; sağlık kayıtları, tıbbi veriler ve kayıtların analizi için sağlık yönetiminde ve daha birçok basamakta kullanılabilmektedir. Robotik cerrahi operasyonları daha hassas ve invazif olacak şekilde AI destekli gerçekleştirilebilmektedir. Kardiyoloji, radyoloji, cerrahi ve birçok alanda hali hazırda AI destekli çalışmalar yapılmıştır ve yapılmaya devam etmektedir (77).

2.17. MAKİNE ÖĞRENMESİ

ML, bir bilgisayarın veri setleri üzerinden öğrenmesini sağlayan AI alt disiplinidir. Doğal bir insan davranışı olan öğrenme, makinelerin de özelliği haline getirilmiştir. ML algoritmaları veri setleriyle beslenmeye sonrasında bu verileri kullanarak öğrenmeye dayalıdır. Doğru ya da yanlış yanıtlar gibi geri bildirimlerle sistem beslenerek, deneyime dayalı başarısını arttırarak öğrenir. ML'nin ilgili görevleri çözmek ve otomatikleştirmek için soruna özgü eğitim verilerinden beslenmesi gerekir. ML görüntü işleme, doğal dil işleme, finans, tıp, otomotiv endüstrisi ve daha birçok alanda kullanılır hale gelmiştir (78).

Günümüzde farklı veri türleri ve işleme gereksinimleri olan ve her birinde farklı ML algoritmaları kullanılan ML çeşitleri mevcuttur :

Denetimli ML: Veri setleri üzerinde belirli özellikler etiketlenir ve sonrasında bu etiketler modelin girdi verilerini doğru tahmin etmesine olanak sağlar. Örneğin bir resim sınıflandırması modeli oluşturulacağı zaman; önce resim içerisinde bulunan nesnelerin etiketlenmesi gerekir. Bu öğrenmede bilgisayara örnek girdiler ve istenen çıktılar sunulur.

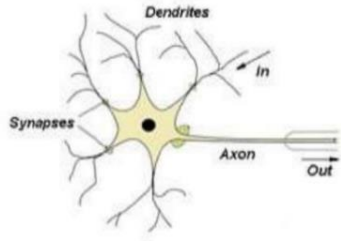
Denetimsiz ML: Bu türde veri setlerinde herhangi bir etiketleme yapılmaz. Model kendi kendine belirlemiş olduğu veri kalıplarını ve benzerlikleri, kümeleme ya da boyut indirgemede kullanabilir. Burada verilen girdiler içerisindeki yapıyı bulup tanımlamak algoritmanın kendi işidir.

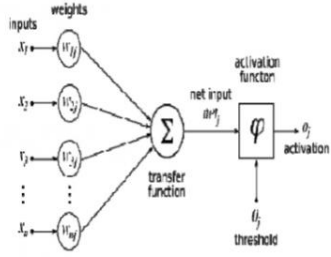
Pekiştirmeli ML: Model belirlenen görevi geliştirmek için çevre ile etkileşime girer. Ödül ve ceza sistemi kullanılarak modelin çevreyi keşfetmesi sağlanır. Böylelikle en iyi sonucu elde edebilmek adına model çıktılarını optimize eder.

Transfer ML: Model bir görevi öğrenmek için başka bir görevden önceden öğrenilmiş bilgileri kullanır. Böylece eğitim süresi kısaltılmış ve daha az veri ile daha iyi sonuçlar elde edilmesinin önü açılmış olur (79).

2.18. DERİN ÖĞRENME

DL, bir dizi algoritmanın kullanılmasıyla karmaşık problemleri çözebilen bir ML dalıdır. DL algoritmaları insanlarda bulunan nöronların yapısını taklit eden ve YSA olarak adlandırılan çok katmanlı bir yapıya sahiptir. YSA birbirine bağlı çok sayıda yapay nörondan oluşur her bir yapay nöron girdi verilerini işleyerek bir sonraki katmana iletir. Bu iletim, YSA'daki sinirlerin ağırlıkları ve Bias adı verilen düzeltme terimlerinin yine YSA tarafından otomatik olarak ayarlaması sayesinde olur. DL algoritmaları kullanılarak belirlenen görev için en iyi sonuçlar üretilmesi amaçlanır. DL algoritmaları genelde YSA'lardaki bağlantıların güçlendirilmesi, gevşetilmesi ya da yeniden yapılandırılması yoluyla eğitilir. Böylelikle verilerin tüm karmaşık özelliklerine kadar daha doğru anlaşılarak daha doğru sonuçların elde edilmesi sağlanır (80).





Şekil 30. Solda Biyolojik Nöron Yapısı, Sağda Yapay Nöron Yapısı (81)

DL algoritmaları gerçekleştirilirken farklı tiplerde sinir ağları kullanılabilir. Örneğin görüntü işlemek için CNN kullanılarak bir fotoğraftaki nesneleri tanımlamak ya da yüz tanınması mümkündür. Doğal dil işlemek için Rekürren sinir ağları (RNN) kullanılarak bir metinde dil modeli oluşturmak ya da bir metindeki anlamı anlamak tercüme edebilmek mümkündür. Yine RNN kullanılarak ses ve konuşma tanınması sağlanıp, konuşma modeli oluşturulabilir. Zaman serileri üzerinde çalışılacak ise Uzun-kısa süreli bellek sinir ağları (LSTM) kullanılabilir (82) .

2.19. DERİN ÖĞRENMENİN MAKİNE ÖĞRENMESİNE ÜSTÜNLÜKLERİ

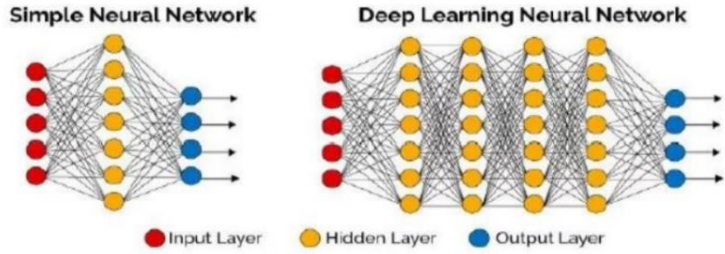
DL, ML'nin bir alt dalı olmasına rağmen diğer ML yöntemlerine göre yaklaşım ve algoritma olarak farklılıklar içerir. ML verilerin özelliklerini analiz ederek model oluşturmayı öğrenen bir AI yöntemidir. ML algoritmaları, verileri analiz ederek model oluşturur ve bu modele dayanarak öngörülebilir sonuçlar üretir. DL ise biyolojik nöronların çalışmasını taklit ederek karmaşık veri yapılarını daha etkili bir şekilde işleyebilen bir AI yöntemidir (83).

DL önceden programlanmamış veri özelliklerini öğrenme kabiliyetine sahiptir. Bu özellik sayesinde otomatik öznitelik öğrenme sağlanılarak zaman alıcı bir süreç atlanmış olur. Öğrenilen özellikler sayesinde veriler daha iyi

sınıflandırılmış olur. DL algoritmaları yüksek düzeyde doğruluk sağlayabilecek çok sayıda öğrenilebilir parametreye sahip olduğu için ML'ye göre daha yüksek doğruluk oranları elde edilmektedir. Ayrıca DL modelleri ML'ye göre daha iyi oranda genelleştirme yeteneğine sahiptir. Bu sayede eğitim verileri dışındaki yeni veriler üzerinde de iyi sonuçlar elde edilebilmektedir.

DL aynı anda birden fazla görevi çözebilir; örneğin bir görüntü üzerinde bulunan nesneleri tanımlarken bir yandan da bu nesnelerin pozisyonlarını da belirtebilir.

DL modelleri her an güncellenebilir; yeni verilerle sürekli olarak sürekli güncellenmeye devam edilir. Böylece daha doğru sonuçların üretilmesi mümkün kılınır. DL'nin tüm bu üstünlüklerine rağmen algoritmalarının daha karmaşık olması, eğitimleri için daha fazla bilgi ve uzmanlık gerektirir. Ayrıca eğitim ve hesaplama maliyetleri de daha yüksektir (83,84).



Şekil 31. Derin Sinir Ağı (84)

2.20. RESİDUAL NEURAL NETWORK (RESNET) SİNİR AĞI

ResNet derin öğrenme alanında kullanılan bir CNN modelidir. 2015 yılında Microsoft Research tarafından geliştirilmiştir. Diğer popüler sinir ağı modelleri ile

karşılaştırıldığında farklı olarak; daha derin ağların eğitilmesi sırasında ortaya çıkan ''degradasyon'' sorununu çözmek için özel bir yapı kullanır. Degradasyon, derin öğrenme modellerinde daha derin ağların kullanılmasıyla doğruluk oranlarının beklenenden daha az olması durumunu ifade eder. Degradasyon, ağın daha derin hale gelmesiyle modelin öğrenme hızının yavaşlaması, eğitim süresinin artması ve modelin genelleme yeteneğinin azalması gibi problemlere yol açabilir. Bu nedenle ResNet gibi mimarilerde kullanılan artıklık bağlantıları gibi teknikler bu sorunun üstesinden gelmek için tasarlanmıştır (85). ResNet, özellikle görüntü sınıflandırma ve nesne tespiti gibi görsel işleme problemlerinde başarılı sonuçlar verir.

ResNet, derin sinir ağlarındaki aşırı öğrenme (overfitting) sorununu aşmak için rezidüel (artık) bağlantıları kullanır. Bu bağlantılar önceki katmanlardaki özelliklerin bir sonraki katmana geçmesine izin verir. Ağın daha derin olmasının, teorik olarak performansı arttırarak daha yüksek doğruluk oranları elde etmeyi sağladığı düşünülür; ancak pratik uygulamada bu durum tersine dönebilmektedir. Teoride derinliği arttırılan ağlarda eğitim hatalarının azalması gerekirken; gerçekte doğruluk doymayı takiben büyük bir hızda düşer, böylece eğitim hataları da artmış olur. Bu durumun aslında, DL modellerinin eğitim sürecinde karşılaşılan bozulma-optimizasyon probleminden kaynaklandığı düşünülmektedir. ResNet birçok farklı boyutta ve derinlikte kullanılabilen bir mimariye sahiptir. Basitçe ifade edilecek olunursa bu mimari birkaç bloğun bir araya getirilmesiyle oluşur. Her blok katmanlardan oluşur ve her katmanda birkaç konvolüsyon katmanı, bir normalleştirme katmanı ve bir aktivasyon fonksiyonu vardır. Ayrıca her blok önceki bloğun çıktısına atlayan bir bağlantı içerir. ResNet'in bulundurduğu katman sayısına göre çeşitleri mevcut olup içerdiği katman ne kadar çok ise versiyonun da bir o kadar güçlü olması beklenir (86).



Şekil 32. ResNet Mimari Yapısı (87)

3. GEREÇ-YÖNTEM

3.1. ÇALIŞMANIN TÜRÜ, KAPSAMI VE ÖRNEKLEMİ

Retrospektif olarak yürütülen çalışmamız, 1 Kasım 2021 – 1 Mart 2023 tarihleri arasında, Ankara Bilkent Şehir Hastanesi Erişkin Acil Tıp Kliniği'ne başvuran ve Tablo 1'de gösterilen, dahil edilme kriterlerini karşılayan hastalar dahil edilerek gerçekleştirilmiştir. Bu çalışma, 2 numaralı etik kurula başvurumuza istinaden 23/11/2022 tarihinde verilmiş olan, E2- 22- 2645 No'lu onay kararını takiben gerçekleştirilmiştir. Çalışmamızda öncelikle çalışmaya dahil edilmesi kararlaştırılan EKG'ler toplanmış; sonrasında ise tarafımızca NSR ve taşiaritmik olarak değerlendirilen EKG'ler, karışık şekilde kardiyoloji uzman hekimlerine verilerek, VT-SVT ve NSR olarak EKG'leri etiketlemeleri istenilmiştir. Bu değerlendirme sonrasında çalışma ekibinde bulunan bilgisayar mühendislerine, EKG'ler ve kardiyoloji uzman hekimleri tarafından belirlenen etiketler iletilmiş olup modelin beslenerek, karar verebilir hale getirilmesi beklenmiştir. Model hazır olduğunda modelden EKG ritimlerini analiz ederek VT-SVT ayrımı yapması beklenilmiştir. Son olarak kardiyoloji uzman hekimlerinin değerlendirmeleri ile derin öğrenme algoritmasının prediksiyonları ile kıyaslanmış olup, derin öğrenmenin VT-SVT ayrımındaki başarısı değerlendirilmiştir.

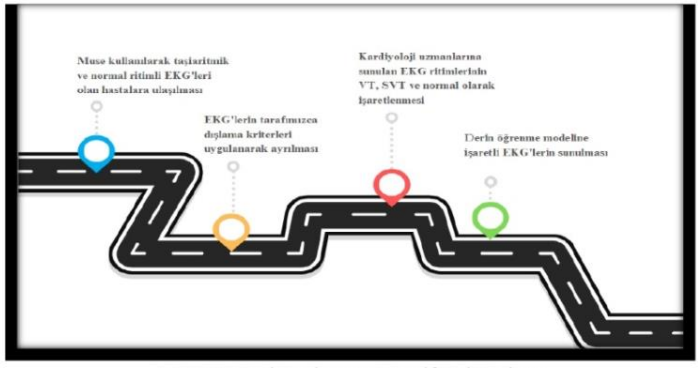
Tablo 1. Araştırmaya dahil edilme ve dışlanma kriterleri

Dahil edilme kriterleri
• 18 yaş üstü olmak • Çarpıntı, baş dönmesi, dispne, göğüs ağrısı ve senkop semptomlarının en az biri nedeniyle acil servise başvurulmuş olması • Başvuruyu takiben EKG çekilmiş olması • Çekilen EKG'de taşiaritmi saptanması
Dışlanma kriterleri
• 18 yaş altı olmak • EKG'ye sistem üzerinden ulaşılamaması • EKG'nin uygun yöntemle çekilmemesi (artefakt içermesi, elektrotların doğru bağlanmaması

Çalışmaya alınan hastaların EKG'leri General Electric™ Healthcare Mac 200 marka ve modelli EKG cihazları kullanılarak çekilmiş olup hastaların EKG'lerine MUSE™ V9 sistemi aracılığıyla ulaşılmıştır. Edinilen EKG'ler tarafımızca tasnif edilmiş olup taşiaritmi içeren EKG'ler kardiyoloji uzmanlarımıza değerlendirme için verilmiştir.

3.2. VERİLERİN TOPLANMASI VE TASNİFİ

MUSE™ V9 sistemi kullanılarak 01.11.2021- 01.03.2023 tarihleri arasında, 18 yaşında olup hastanemize başvurmuş; çekilen EKG'lerinde taşiaritmi saptanan 848 hasta ile yine bu tarihler arasında hastanemize başvurusu olup çekilen EKG'lerinde NSR gözlendiği düşünülen 250 hasta değerlendirmeye alınmıştır. Değerlendirmeye alınan hastaların mükerrer EKG'leri çalışma dışı bırakılmıştır. Değerlendirme sonrası yukarıda belirtilen dahil edilme kriterlerine uymayan hastalar elenmiş ve taşiaritmili 652 hasta ile normal sinüs ritmi olduğu düşünülen 248 hasta EKG'si kardiyoloji uzman hekimlerine karışık olarak iletilmiştir. Kardiyoloji uzman hekimleri tarafından EKG ritimleri incelenerek VT, SVT ve NSR olarak işaretlenmiştir. Tasnifi ve işaretlenmesi bitirilen EKG'ler derin öğrenme modelinde kullanılmak üzere mühendislerimize iletilmiştir (Şekil- 32).



Şekil 33. Veri Toplama ve Tasnif Yol Haritası

3.3 DERİN ÖĞRENME AŞAMASI

Çalışmamızda, hastaların kardiyoloji uzman hekimlerince etiketlenerek tasnif edilmiş verileri; DL alanında kullanılan bir CNN modeli olan ResNet'in farklı türlerinin (ResNet 18, ResNet 34 ve ResNet 50) eğitimi ve testinde kullanılmıştır.

Çalışmamız süresince Python programlama dili kullanılmıştır. Kullandığımız DL modeli ise açık kaynaklı bir Python kütüphanesi olan PyTorch ile oluşturulmuştur. PyTorch tensör işleme ve dinamik hesaplamalar için optimize edilmesi sayesinde modelleri hızlı bir şekilde eğitip test etmeye olanak sağlar. Bu kütüphane ayrıca esneklik, kolay kullanım ve yüksek performans gibi özellikleri nedeniyle popülerdir.

PDF içerisinden resim çıkartma : Bu aşamada ilk olarak kardiyoloji uzmanları tarafından işaretlenerek tasnifi yapılmış PDF formatındaki EKG'lerin görüntüleri uygun formatta çıkarılmıştır. Bunun için Ubuntu işletim sistemindeki pdf'ten ppm'e adlı program kullanıldı. Görüntülerde yer alan EKG verilerinde, işlem sırasında uygulanacak olan sıkıştırmada kayıp olmaması için 150 DPI çözünürlüğündeki PNG resim formatı kullanılmıştır.

Eldeki her bir hastaya ait EKG görüntüsü bu şekilde PNG formatına çevrildikten sonra kullanılacak görüntü bölgesi tespit edilerek yalnızca bu bölgelerin görüntü içerisinden çıkarılıp kullanıma uygun hale gelmesi sağlanmıştır.

XML dosyalarından cinsiyet ve yaş aralığı çıkartma : Bu aşamada ise çalışmaya alınan hastaların yaş aralıkları ve cinsiyet bilgileri, xml dosyalarından yine Python dili içerisindeki xml kütüphanesi kullanılarak çıkartılmıştır. Hastaların yaş aralıkları, aşağıda gösterilen One Hot vektörlere çevrilerek modele haline getirilmiştir. Yaş aralıklarını bu şekilde temsil etmemizin temel sebebi ise yaş sınıfları arasındaki uzaklıkları eşit hale getirmektir.

"18-40 yaş" -> [1,0, 0]

"41-50 yaş" -> [0, 1, 0]

"50 yaş üzeri" -> [0, 0, 1]

Ayrıca cinsiyetler de benzer şekilde vektörlere çevrilerek modelimiz tarafından kullanılabilir hale getirilmiştir.

"Erkek" -> [0]

"Kadın" -> [1]

Son olarak ise kardiyoloji doktorları tarafından oluşturulmuş veri etiketleri (VT-SVT- Normal sinüs ritmi), yaş ve cinsiyet bilgilerinde yapıldığı gibi One Hot vektör haline getirilmiştir.

"Normal" -> [1,0,0]

"VT" -> [0,1,0]

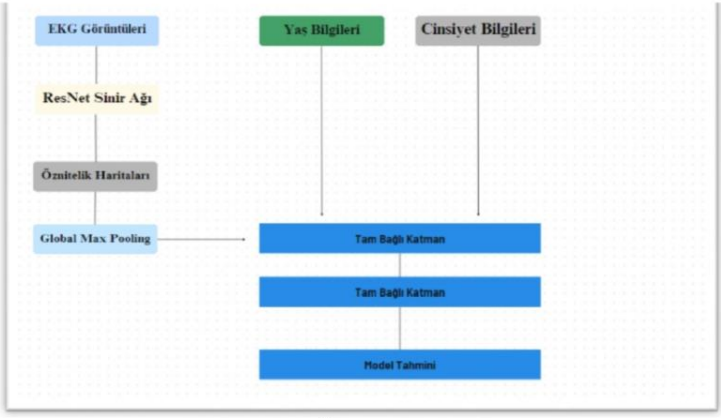
"SVT" -> [0,0,1]

Resim ön işleme: Hazırlanan resimler ile oluşturulan model beslenmeden önce bilineer interpolasyon kullanılarak resimleri 224 ve 112 boyutlarında yeniden boyutlandırılmıştır. Girdi resimlerinde herhangi bir veri arttırımı (augmentation) yapılmamıştır.

Yukarıda bahsettiğimiz diğer girdiler olan cinsiyet ve yaş bilgileri ise hiçbir değişiklik yapılmadan modelin beslenmesinde kullanılmıştır.

Model seçimi : Birer CNN mimarisi olan ResNet 18-34 ve 50 versiyonları çalışmamızda kullanılmıştır. ResNet DL alanında sıkça kullanılan bir modeldir. Özellikle görüntü nesne işleme işlemlerinde sıkça kullanılan etkili bir sınıflandırma modelidir.

Öznitelik haritaları ve global max pooling : CNN mimarilerinde özellik haritalarından bir öznitelik çıkarmak için kullanılan havuzlama işlemine global max polling adı verilir. Bu işlem ResNet ve benzeri CNN'lerde sıklıkla kullanılır. Havuzlama işlemleri, özellik haritalarını boyutunu azaltarak hesaplama yükünü azaltmak; overfitting sorununu önlemek; özelliklerin çevirme değişmezliklerini (translation invariance) arttırmak gibi nedenlerle kullanılır. Bu işlem sayesinde CNN'nin sınıflandırma performansı arttırılmış olur. Bu nedenle çalışmamızda tercih edilmiştir.



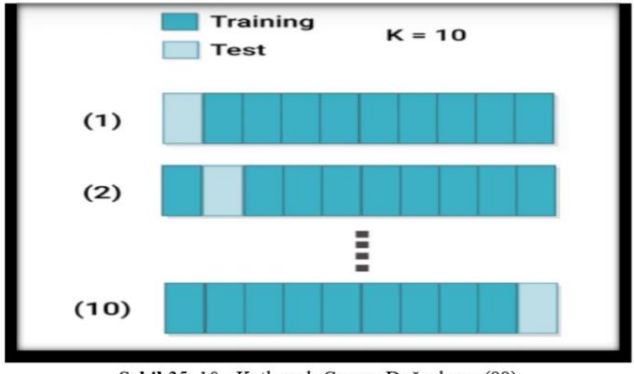
Şekil 34. Derin Öğrenme Model Mimarisi

Dengesiz veri seti sorunu : Dengesiz veri seti farklı sınıfların veya sonuçların örnekler arasında dengesiz bir şekilde dağıldığı bazı veri setlerinde görülür. Bir sınıfa ait örnek sayısı diğer sınıflara kıyasla çok daha fazla veya çok daha az olabilmektedir. Çalışmamızda olduğu gibi, bir tıbbi teşhis uygulamasında, normal grup ve hastalık ya da özellik içeren gruplar olduğunda, veri setinde normal grup ya da başka bir özellik taşıyan grup ötekinden sayıca fazlaysa bu set dengesiz bir veri seti olarak kabul edilir. Dengesiz veri setleri, model performansını etkileyerek yanlı sonuçlara neden olabilir. Böyle durumlarda veri setini yeniden dengelemek veya örneklemek gibi teknikler kullanılabilir.

Eğitim parametreleri : Çalışmada ele alınan VT, SVT ve NSR olarak sınıflandırılan verilerin sayı bakımından birbirinden farklı olması ve özellikle VT grubunun sayı bakımından diğer gruplara göre daha az olması nedeniyle oluşan dengesizlik problemini çözmek için Weighted Cross Entropy Loss kullanılmıştır.

Böylece NSR olarak değerlendirilen girdilerdeki hatalar 0.2; SVT girdilerindeki hatalar 0.1; VT girdilerindeki hatalar ise 0.7 ağırlığıyla çarpılarak hesaplanmıştır.

K- Katlamalı çapraz doğrulama: K-fold cross-validation ML modellerinin performansını değerlendirmek için kullanılır. Bu yöntemde veri seti rastgele şekilde K adet parçaya bölünmektedir. Sonrasında her bir parça sırayla test seti olarak kullanılırken, geri kalan parçalar bir araya getirilerek eğitim seti oluşturulur. Bu işlem K defa tekrar edilir ve her seferinde farklı bir parça test seti olarak kullanılır. Böylece, veri setinin tamamı hem eğitim hem de test için kullanılmış olur ve modelin performansı daha güvenilir bir şekilde ölçülebilir. Sonuçta, K farklı test sonucu elde edilirken bu sonuçların ortalaması ile modelin performansı belirlenir. Çalışmamızda K=10 olarak ayarlanarak 10-katlamalı çapraz doğrulama kullanılmıştır.



Şekil 35. 10 - Katlamalı Çapraz Doğrulama (88)

Performans Metrikleri : DL modelinin sınıflandırma ya da regresyon performansının ölçülerek modelin ne ölçüde duyarlı ve tutarlı olduğunu ve de çıkarımların doğruluğunu belirlememize yardımcı olan ölçütlerdir. Çalışmamızda bu metriklerden doğruluk, kesinlik ve duyarlılık ile F1 skoru kullanılmıştır.

- **Doğruluk (Accuracy) :** Sınıflandırma problemlerinde en yaygın olarak kullanılan performans metriği olup modelin doğru sınıflandırma yüzdesini ölçer; doğru sınıflandırılmış alanların toplam veri setine bölünmesi ile hesaplanır.
- **Kesinlik (Precision) :** Gerçek pozitif örneklerin yanlış pozitif örneklerden ne kadar ayrıldığını ölçer.
- **Duyarlılık (Recall) :** Gerçek pozitif örneklerin yanlış negatif örneklerden ne kadar ayrıldığını ölçer.
- **F_1 skoru :** Kesinlik ve duyarlılık değerlerinin harmonik ortalamasının alınması ile hesaplanır.

$$F1 = 2x\frac{kesinlikxduyarlılık}{kesinlik + duyarlılık}$$

Doğru Gerçek Negatif (GN)	Yanlış Yanlış pozitif (YP)	Doğruluk	Kesinlik	Duyarlılık
Yanlış Yanlış Negatif (YN)	Doğru Gerçek Pozitif (GP)	$\frac{GN + GP}{GN + YN + GP + YP}$	$\frac{GP}{GP + YP}$	$\frac{GP}{GP + YN}$

Şekil 36. Doğruluk, Kesinlik ve Duyarlılık Metriklerinin Hesaplanması

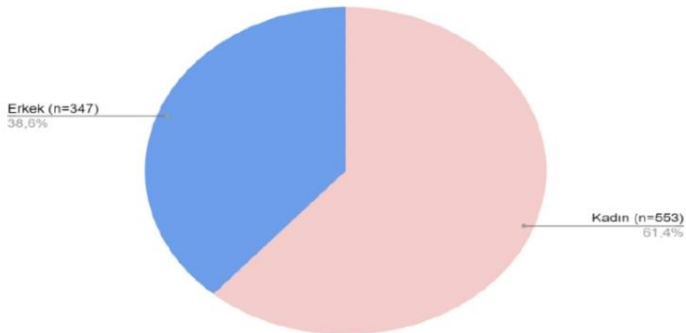
3.4. İSTATİKSEL METOT

Çalışmamızda istatistiksel analizler için IBM SPSS Statistics for Windows, Version 20.0 (Armonk, NY: IBM Corp) programı kullanılmıştır. Öncelikle demografik veriler ve frekans dağılımları analiz edilmiştir. Kategorik verilerin oran karşılaştırmaları için Pearson Ki-Kare testi kullanılmıştır. Sürekli (sayısal) verilerin normallik analizleri Shapiro-Wilk testi kullanılarak yapılmıştır. İkiden fazla bağımsız grup karşılaştırılırken normal dağılım göstermeyen parametreler için Kruskall Wallis testi; bu grupların alt grup analizleri için Bonferroni düzeltmesi kullanılmıştır. İki ayrı değerlendiricinin dikotom bir parametre için uyum analizi Cohen's Kappa testi ile yapılmıştır. Kappa katsayısı değerlendirilirken 0.41-0.60 arasında orta derecede, 0.61-0.80 arasında iyi derecede ve 0.81-1.00 arasında çok iyi derecede uyum olduğu kabul edilmiştir. Dört (2x2) gözlü tablolar ile beraber tanısal değerlilik istatistikleri (özgüllük, duyarlılık, negatif olabilirlik oranı, pozitif olabilirlik oranı, negatif prediktif değer, pozitif prediktif değer ve doğruluk oranı) verilmiştir. İstatistiksel anlamlılık düzeyi için $P<0.05$ kullanılmıştır.

4. BULGULAR

4.1. HASTA VERİLERİNİN ANALİZİ

Retrospektif çalışmamıza dahil edilme kriterlerimize uygun olarak 900 hasta alınmış olup; bunların % 61.4'ü (n=553) kadın olarak gözlenmiştir (Şekil 37).



Şekil 37. Hastaların Cinsiyet Dağılımları

Çalışmadaki tüm hastaların yaş ortalaması 57±17 yıl olarak gözlenmiş olup yaş aralığının, en küçük 18'den en büyük 97'ye kadar değiştiği gözlenmiştir. Cinsiyete göre yaş dağılımları incelendiğinde ise kadınlarda 57±17; erkeklerde 58±18 olarak gözlenmiştir (Tablo 2).

Tablo 2. Hastaların Cinsiyet ve Yaş Dağılımları

		Yaş				
		Ort	SS	Med	Min	Max
Tüm hastalar		57	17	60	18	97
Cinsiyet	Kadın	57	17	60	18	93
	Erkek	58	18	60	18	97

Çalışmaya dahil edilen hastaların EKG'lerinin kardiyoloji uzman hekimlerince değerlendirilmesi sonrası, 900 hastanın % 64.8'inin (n=583) SVT; % 7.7'sinin (n=69) VT; % 27.6'sının (n=248) ise NSR olarak etiketlendiği gözlenmiştir (Tablo 3).

Tablo 3. EKG'lerin Kardiyoloji Uzmanlarınca Etiketlenmesi

		Sayı (n)	Yüzde (%)
Etiketler	SVT	583	64.8
	VT	69	7.7
	NSR	248	27.6

Çalışmaya dahil edilen hastaların EKG'leri ile yaşları birlikte değerlendirilecek olursa, EKG'leri SVT ritmi olarak değerlendirilen hastaların yaş ortalaması 63±15 olarak gözlenmiştir; en küçük hasta 18, en büyük hasta ise 97 yaşındadır. EKG'leri VT ritmi olarak değerlendirilen hastaların yaş ortalaması 62±15 olarak gözlenmiştir; en küçük hasta 19, en büyük hasta ise 88 yaşındadır.

EKG'leri NSR olarak değerlendirilmiş hastaların yaş ortalaması ise 44±15 olup; en küçük hastanın 18 yaşında en büyüğünün ise 88 yaşındadır (Tablo 4).

Tablo 4. EKG Ritimleri ve Yaş Dağılımları

		Yaş				
		Ort	SS	Med	Min	Max
Etiketler	SVT	63	15	64	18	97
	VT	62	15	66	19	88
	Normal	44	15	43	18	88
Kruskall Wallis test; p<0.001 Subgrup analizinde farklı olan grubun "Normal" grup olduğu tespit edildi; Bonferroni düzeltmesi kullanıldı.						

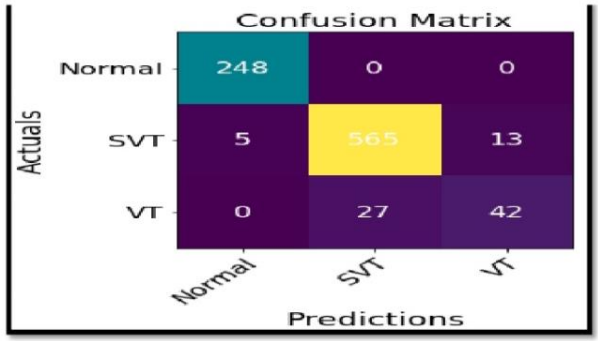
Çalışmaya dahil edilen hastaların EKG'leri ile cinsiyetleri birlikte değerlendirilecek olursa; EKG'leri SVT ritminde etiketlenen hastaların %60'ı (n=350) kadın iken; %40'ı (n=233) erkek olarak gözlenmiştir. EKG'leri VT ritminde etiketlenen hastaların % 68.1'i (n=47) kadın iken; %31.9'u (n=22) erkek olarak gözlenmiştir. EKG'leri NSR olarak etiketlenen hastaların % 62.9'u (n=156) kadın iken; %37.1'i (n=92) erkek olarak gözlenmiştir (Tablo 5).

Tablo 5. EKG Ritimleri ve Cinsiyete Göre Dağılımları

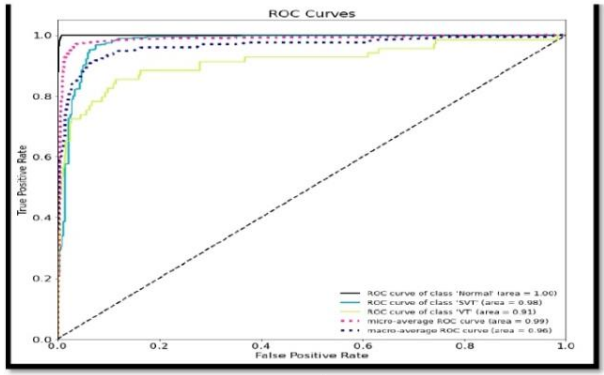
		Cinsiyet			
		Kadın		Erkek	
		N	%	N	%
Etiketler	SVT	350	60.0	233	40.0
	VT	47	68.1	22	31.9
	Normal	156	62.9	92	37.1
Pearson Ki-Kare test; 0.366					

4.2. RESNET 18 İLE EKG RİTİM ANALİZİ PREDİKSİYONLARI

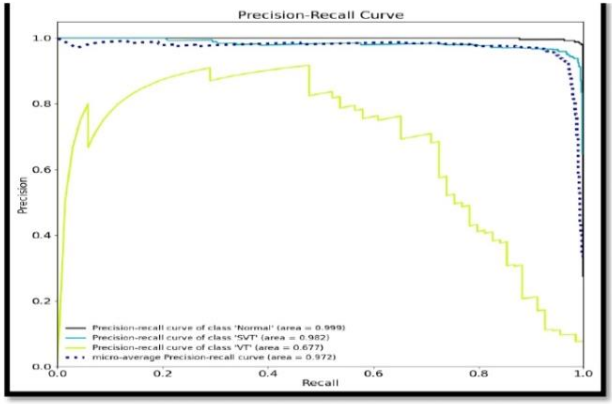
ResNet 18, 18 katmanlı bir CNN modeli olup görüntü sınıflandırma görevinde son derece başarılıdır. Oluşturulan modelin test verisiyle elde edilmiş olan performansına yönelik hata matrisi (confusion matrix) Şekil 38'de; ROC eğrisi Şekil 39'da; kesinlik-duyarlılık eğrisi Şekil 40'ta ve modelin performans metrikleri Tablo 6'da verilmiştir.



Şekil 38. ResNet 18 İçin Hata Matrisi



Şekil 39. ResNet 18 İçin ROC Eğrisi



Şekil 40. ResNet 18 İçin Kesinlik- Duyarlılık Eğrisi

Tablo 6. ResNet 18 İçin Performans Metrikleri

F1 Ağırlıklı	0.95
F1 Mikro	0.95
F1 Makro	0.87
Kesinlik Ağırlıklı	0.95
Kesinlik Mikro	0.95
Kesinlik Makro	0.85
Duyarlılık Ağırlıklı	0.95
Duyarlılık Mikro	0.95
Duyarlılık Macro	0.89
Doğruluk	0.95

ResNet 18 modeli kullanılarak elde edilen ve EKG'lerin normal ya da taşiaritmik olarak sınıflandırılmasının prediksiyonuna yönelik istatistik verileri, Tablo 7 ve Tablo 8'de verilmiştir. Bu prediksiyonlarda kardiyoloji uzman hekimlerininin yapmış olduğu etiketlemeler altın standart olarak kabul edilmiştir.

Tablo 7. ResNet 18'in Taşiaritmik-NSR EKG Prediksiyon Yüzdeleri

ResNet 18					
			Etiketler		Toplam
			Taşiaritmi	NSR	
ResNet 18	Taşiaritmi	N	647	0	647
		%satır	100.0	0.0	100.0
		%sütun	99.2	0.0	71.9
		%toplam	71.9	0.0	71.9
	NSR	N	5	248	253
		%satır	2.0	98.0	100.0
		%sütun	0.8	100.0	28.1
		%toplam	0.6	27.6	28.1
Toplam		N	652	248	900
		%satır	72.4	27.6	100.0
		%sütun	100.0	100.0	100.0
		%toplam	72.4	27.6	100.0
Cohen' s Kappa testi; Kappa değeri = 0.986; iki değerlendirici arasındaki uyum "Çok iyi" derecesindedir.					

Tablo 8. ResNet 18'in Taşiaritmik-NSR Tanısal Değerlilik İstatistikleri

ResNet 18		
İstatistikler	**Değer**	**95% (CI)**
Sensitivite	99.23	98.22 - 99.75
Spesifite	100.00	98.52 - 100.00
Pozitif olabilirlik oranı		
Negatif olabilirlik oranı	0.01	0.00 - 0.02
Hastalığın sıklığı	72.44	69.40 - 75.34
Pozitif tahmini değer	100.00	
Negatif tahmini değer	98.02	95.39 - 99.17
Doğruluk	99.44	98.71 - 99.82
CI: Confidence Interval (Güven Aralığı)		

ResNet 18 modeli kullanılarak elde edilen ve EKG'lerin SVT ya da VT olarak sınıflandırılmasının prediksiyonuna yönelik istatistik verileri; Tablo 9 ve Tablo 10'da verilmiştir. Bu prediksiyonlarda kardiyoloji uzmanlarının yapmış olduğu etiketlemeler altın standart olarak kabul edilmiştir.

Tablo 9. ResNet 18'in VT-SVT EKG Prediksiyon Yüzdeleri

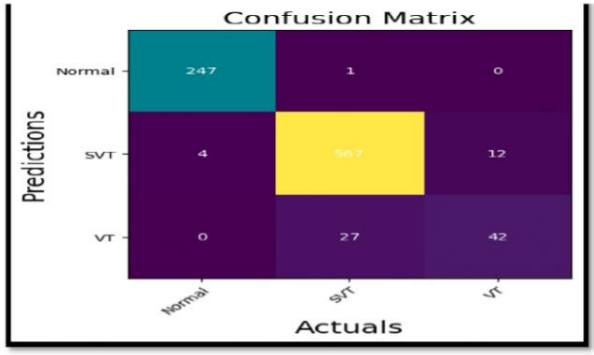
ResNet 18					
			Etiketler		Toplam
			VT	SVT	
ResNet 18	VT	N	42	13	55
		%satır	76.4	23.6	100.0
		%sütun	60.9	2.2	8.4
		%toplam	6.4	2.0	8.4
	SVT	N	27	570	597
		%satır	4.5	95.5	100.0
		%sütun	39.1	97.8	91.6
		%toplam	4.1	87.4	91.6
Toplam		N	69	583	652
		%satır	10.6	89.4	100.0
		%sütun	100.0	100.0	100.0
		%toplam	10.6	89.4	100.0
Cohen's Kappa testi; Kappa değeri = 0.644; iki değerlendirici arasındaki uyum "İyi" derecededir.					

Tablo 10. ResNet 18'in VT-SVT Tanısal Değerlilik İstatistikleri

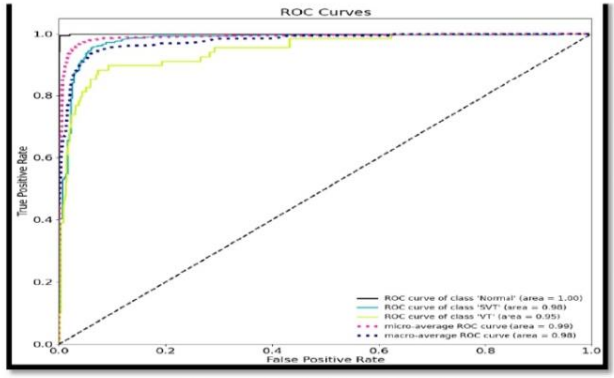
ResNet 18		
İstatistik	**Değer**	**95% (CI)**
Sensitivite	60.87	48.37 - 72.40
Spesifite	97.77	96.22 - 98.81
Pozitif olabilirlik oranı	27.30	15.44 - 48.26
Negatif olabilirlik oranı	0.40	0.30 - 0.54
Hastalığın sıklığı	10.58	8.33 - 13.20
Pozitif tahmini değer	76.36	64.63 - 85.10
Negatif tahmini değer	95.48	94.02 - 96.59
Doğruluk	93.87	91.74 - 95.58

4.3. RESNET 34 İLE EKG RİTİM ANALİZİ PREDİKSİYONLARI

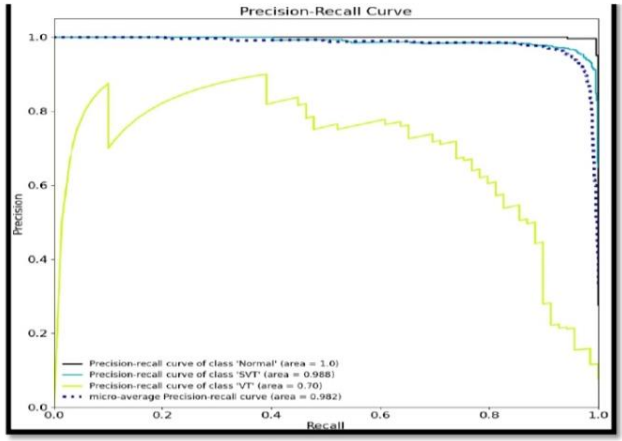
ResNet 34, 34 katmanlı bir CNN modeli olup nispeten daha küçük veri kümeleri üzerinde eğitildiğinde iyi sonuçlar verir. Oluşturulan modelin test verisiyle elde edilmiş olan performansına yönelik hata matrisi Şekil 41'de; ROC eğrisi şekil 42'de; kesinlik-duyarlılık eğrisi Şekil 43'te ve modelin performans metrikleri Tablo 11'de verilmiştir.



Şekil 41. ResNet 34 İçin Hata Matrisi



Şekil 42. ResNet 34 İçin ROC Eğrisi



Şekil 43. ResNet 34 İçin Kesinlik-Duyarlılık Eğrisi

Tablo 11. ResNet 34 İçin Performans Metrikleri

F1 Ağırlıklı	0.94
F1 Mikro	0.95
F1 Makro	0.87
Kesinlik Ağırlıklı	0.94
Kesinlik Mikro	0.95
Kesinlik Makro	0.90
Duyarlılık Ağırlıklı	0.95
Duyarlılık Mikro	0.95
Duyarlılık Macro	0.85
Doğruluk	0.95

ResNet 34 modeli kullanılarak elde edilen ve EKG'lerin normal ya da taşiaritmik olarak sınıflandırılmasının prediksiyonuna yönelik istatistik verileri, Tablo 12 ve Tablo 13'te verilmiştir. Bu prediksiyonlarda kardiyoloji uzman hekimlerinin yapmış olduğu etiketlemeler altın standart olarak kabul edilmiştir.

Tablo 12. ResNet 34'ün Taşiaritmik-NSR EKG Prediksiyon Yüzdeleri

ResNet 34					
			Etiketler		Toplam
			Taşiaritmi	NSR	
ResNet 34	Taşiaritmi	N	648	1	649
		%satır	99.8	0.2	100.0
		%sütun	99.4	0.4	72.1
		%toplam	72.0	0.1	72.1
	NSR	N	4	247	251
		%satır	1.6	98.4	100.0
		%sütun	0.6	99.6	27.9
		%toplam	0.4	27.4	27.9
Toplam		N	652	248	900
		%satır	72.4	27.6	100.0
		%sütun	100.0	100.0	100.0
		%toplam	72.4	27.6	100.0
Cohen's Kappa testi; Kappa değeri = 0.986; iki değerlendirici arasındaki uyum "Çok iyi" derecesindedir.					

Tablo 13. ResNet 34'ün Taşiaritmik-NSR Tanısal Değerlilik İstatistikleri

ResNet 34		
İstatistik	**Değer**	**95% CI**
Sensitivite	99.39	98.44 - 99.83
Spesifite	99.60	97.77 - 99.99
Pozitif olabilirlik oranı	246.48	34.86 - 1742.94
Negatif olabilirlik oranı	0.01	0.00 - 0.02
Hastalığın sıklığı	72.44	69.40 - 75.34
Pozitif tahmini değer	99.85	98.92 - 99.98
Negatif tahmini değer	98.41	95.88 - 99.39
Doğruluk	99.44	98.71 - 99.82

ResNet 34 modeli kullanılarak elde edilen ve EKG'lerin SVT ya da VT olarak sınıflandırılmasının prediksiyonuna yönelik istatistik verileri Tablo 14 ve Tablo 15'te verilmiştir.

Tablo 14**.** ResNet 34'ün VT-SVT EKG Prediksiyon Yüzdeleri

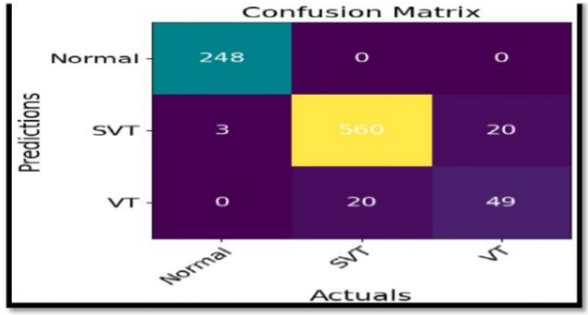
ResNet 34					
			Etiketler		
			VT	SVT	Toplam
ResNet 34	VT	N	42	12	54
		%satır	77.8	22.2	100.0
		%sütun	60.9	2.1	8.3
		%toplam	6.4	1.8	8.3
	SVT	N	27	571	598
		%satır	4.5	95.5	100.0
		%sütun	39.1	97.9	91.7
		%toplam	4.1	87.6	91.7
Toplam		N	69	583	652
		%satır	10.6	89.4	100.0
		%sütun	100.0	100.0	100.0
		%toplam	10.6	89.4	100.0
Cohen's Kappa testi; Kappa değeri = 0.650; iki değerlendirici arasındaki uyum "İyi" derecededir					

Tablo 15**.** ResNet 34'ün VT-SVT Tanısal Değerlilik İstatistikleri

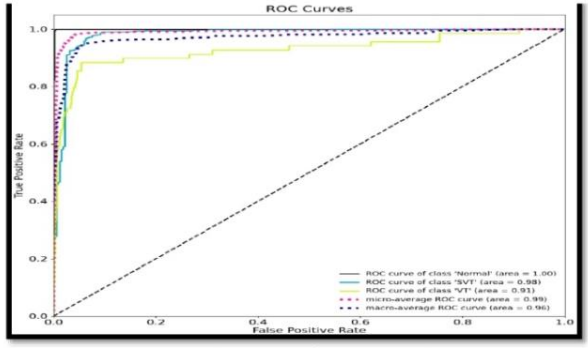
ResNet 34		
İstatistik	**Değer**	**95% CI**
Sensitivite	60.87	48.37 - 72.40
Spesifite	97.94	96.43 - 98.93
Pozitif olabilirlik oranı	29.57	16.38 - 53.40
Negatif olabilirlik oranı	0.40	0.30 - 0.54
Hastalığın sıklığı	10.58	8.33 - 13.20
Pozitif tahmini değer	77.78	65.96 - 86.34
Negatif tahmini değer	95.48	94.03 - 96.60
Doğruluk	94.02	91.91 - 95.71

4.4. RESNET 50 İLE EKG RİTİM ANALİZİ PREDİKSİYONLARI

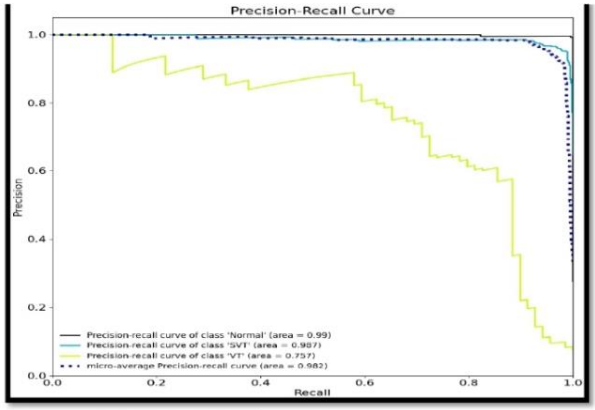
ResNet 50, 50 katmanlı bir CNN modeli olup özellikle görüntü sınıflandırma, nesne tanıma ve yüz tanıma gibi görsel işleme görevlerinde çok iyi sonuçlar verir. Önceki modellere kıyasla derin ağlar daha eğitilebilir haldedir ve daha yüksek doğruluk oranları elde edilebilmektedir. Oluşturulan modelin test verisiyle elde edilmiş olan performansına yönelik hata matrisi Şekil 44'te; ROC eğrisi Şekil 45'te; kesinlik-duyarlılık eğrisi Şekil 46'da ve modelin performans metrikler Tablo 16'da verilmiştir.



Şekil 44. ResNet 50 İçin Hata Matrisi



Şekil 45. ResNet 50 İçin ROC Eğrisi



Şekil 46. ResNet 50 İçin Kesinlik-Duyarlılık Eğrisi

Tablo 16. ResNet 50 İçin Performans Metrikleri

F1 Ağırlıklı	0.95
F1 Mikro	0.95
F1 Makro	0.88
Kesinlik Ağırlıklı	0.95
Kesinlik Mikro	0.95
Kesinlik Makro	0.88
Duyarlılık Ağırlıklı	0.95
Duyarlılık Mikro	0.95
Duyarlılık Macro	0.89
Doğruluk	0.95

ResNet 50 modeli kullanılarak elde edilen ve EKG'lerin normal ya da taşiaritmik olarak sınıflandırılmasının prediksiyonuna yönelik istatistik verileri Tablo 17 ve Tablo 18'de verilmiştir. Bu prediksiyonlarda kardiyoloji uzman hekimlerinin yapmış olduğu etiketlemeler altın standart olarak kabul edilmiştir.

Tablo 17. ResNet 50'nin Taşiaritmik-NSR EKG Prediksiyon Yüzdeleri

ResNet 50					
			Etiketler		Toplam
			Taşiaritmik	NSR	
ResNet 50	Taşiaritmik	N	649	0	649
		%satır	100.0	0.0	100.0
		%sütun	99.5	0.0	72.1
		%toplam	72.1	0.0	72.1
	NSR	N	3	248	251
		%satır	1.2	98.8	100.0
		%sütun	0.5	100,0	27.9
		%toplam	0.3	27.6	27.9
Toplam		N	652	248	900
		%satır	72.4	27.6	100.0
		%sütun	100.0	100.0	100.0
		%toplam	72.4	27.6	100.0
Cohen's Kappa testi; Kappa değeri = 0,992; iki değerlendirici arasındaki uyum "Çok iyi" derecesindedir.					

Tablo 18. ResNet 50'nin Taşiaritmik-NSR Tanısal Değerlilik İstatistikleri

ResNet 50		
İstatistikler	**Değer**	**95% CI**
Sensitivite	99.54	98.66 - 99.91
Spesifite	100.00	98.52 - 100.00
Pozitif olabilirlik oranı		
Negatif olabilirlik oranı	0.00	0.00 - 0.01
Hastalığın sıklığı	72.44	69.40 - 75.34
Pozitif tahmini değer	100.00	
Negatif tahmini değer	98.80	96.39 - 99.61
Doğruluk	99.67	99.03 - 99.93

ResNet 50 modeli kullanılarak elde edilen ve EKG'lerin SVT ya da VT olarak sınıflandırılmasının prediksiyonuna yönelik istatistik verileri Tablo 19 ve Tablo 20'de verilmiştir.

Tablo 19. ResNet 50'nin VT-SVT EKG Prediksiyon Yüzdeleri

ResNet 50					
			Etiketler		Toplam
			VT	SVT	
ResNet 50	VT	N	49	20	69
		%satır	71.00	29.00	100.00
		%sütun	71.00	3.40	10.60
		%toplam	7.50	3.10	10.60
	SVT	N	20	563	583
		%satır	3.40	96.60	100.00
		%sütun	29.00	96.60	89.40
		%toplam	3.10	86.30	89.40
Toplam		N	69	583	652
		%satır	10.60	89.40	100.00
		%sütun	100.00	100.00	100.00
		%toplam	10.60	89.40	100.00
Cohen's Kappa testi; Kappa değeri = 0.676; iki değerlendirici arasındaki uyum "İyi" derecededir.					

Tablo 20. ResNet 50'nin VT-SVT Tanısal Değerlilik İstatistikleri

ResNet 50		
İstatistikler	**Değer**	**95% CI**
Sensitivite	71.01	58.84 - 81.31
Spesifite	96.57	94.75 - 97.89
Pozitif olabilirlik oranı	20.70	13.12 - 32.67
Negatif olabilirlik oranı	0.30	0.21 - 0.43
Hastalığın sıklığı	10.58	8.33 - 13.20
Pozitif tahmini değer	71.01	60.82 - 79.45
Negatif tahmini değer	96.57	95.11 - 97.60
Doğruluk	93.87	91.74 - 95.58

Çalışmamızda kullanılan 3 farklı ResNet modelinin VT-SVT ayrımı prediksiyonlarına ilişkin istatistiki verileri karşılaştırmalı olarak Tablo 21'de verilmektedir. Bu karşılaştırmaya göre ResNet 34 modeller arasında en spesifik ve en

doğru tahminlerde bulunan model olarak gözlenirken en duyarlı model ResNet 50 olarak gözlenmektedir.

Tablo 21. Farklı ResNet Modellerinin VT-SVT Prediksiyonlarının İstatistiki Olarak Karşılaştırılması

	Sensitivite	Spesifite	Pozitif olabilirlik oranı	Negatif olabilirlik oranı	Pozitif tahmini değer	Negatif tahmini değer	Doğruluk
ResNet 18	60.87 (48.37-72.40)	97.77 (96.22-98.81)	27.30 (15.44-48.26)	0.40 (0.30-0.54)	76.36 (64.63-85.10)	95.48 (94.02-96.59)	93.87 (91.74-95.58)
ResNet 34	60.87 (48.37-72.40)	97.94 (96.43-98.93)	29.57 (16.38-53.40)	0.40 (0.30-0.54)	77.78 (65.96-86.34)	95.48 (94.03-96.60)	94.02 (91.91-95.71)
ResNet 50	71.01 (58.84-81.31)	96.57 (94.75-97.89)	20.70 (13.12-32.67)	0.30 (0.21-0.43)	71.01 (60.82-79.45)	96.57 (95.11-97.60)	93.87 (91.74-95.58)

5.TARTIŞMA

AI uygulamalarıyla ilgili olarak tıp ve mühendislik alanlarında çok fazla sayıda çalışma bulunmaktadır ve yapılan çalışmaların sayısı her geçen gün artmaktadır. Her ne kadar çok sayıda çalışma ve makaleye ulaşılsa da henüz alınacak yolumuzun olduğu aşikardır. Tıp alanında AI okur yazarlığı ve yapılan çalışmalar ne yazık ki mühendislik alanının gerisinde kalmıştır. Çalışmamızla ilgili olarak literatürü taradığımızda; AI uygulamalarının EKG ritimlerinin analizinde kullanıldığı çalışmalar mevcut olsa da, bu çalışmaların büyük bir kısmı mühendisler tarafından yapılmış olup onların bakış açısını içermiştir. Oysa ki bu çalışmalar multidisipliner olarak planlanırsa; klinisyenlerin bakış açıları ve sahadan gerçek, anlık veriler elde edilebilir. Bu sayede çalışmaların başarı oranları daha da arttırılabilir.

WCT vakalarında doğru tanı koymak ise birçok klinisyen için hala zor bir konudur. Brugada, Vereckei gibi WCT ayrımında kullanılan algoritmaların kendilerine göre güçlü ve zayıf olduğu yönleri mevcut olup bu ve benzeri algoritmalar üzerinde yapılan çalışmalar ile güçlü yönlerinin bir araya getirilmesi sağlanarak yeni hibrit algoritmalar oluşturulmuştur. Ancak söz konusu yaklaşımlar ancak tecrübeli klinisyenlerce uygulanabilmekte ve değerlendirme uzun zaman almaktadır. AI ve EKG birlikteliği ile yapılan çalışmaların büyük bir kısmında hazır veri setleri kullanılmıştır. Bizim çalışmamızda farklı olarak hazır bir veri seti kullanılmamış olup sahadan toplayıp tasnif ettiğimiz gerçek hasta verisi olan EKG'ler kullanılmıştır.

Çalışmamızda kullandığımız ResNet modellerinin performans metrikleri kıyaslandığında; ResNet 18 ve ResNet 50 için F1 (ağırlıklı): %95; ResNet 34 için ise %94 olarak gözlenmiştir. Tüm ResNet modellerinin doğruluk ve duyarlılıkları %95 olarak hesaplanmıştır. Kesinlik (ağırlıklı) ise ResNet 18 ve ResNet 50 için %95; ResNet 34 için yine %94 olarak gözlenmiştir.

Chen ve arkadaşlarının yaptığı ve 2019 yılında yayımlanan çalışmaya, 2015-2018 tarihleri arasında Çin ve Amerika'daki merkezlerde WCT tanısı almış 528 hasta dahil edilmiş. 528 WCT vakasının 397'si VT ve 131'i SVT olarak değerlendirilmiştir. Elektrofizyolojik değerlendirme sırasında elde edilen EKG'ler; değerlendirme sonuçlarına ve hasta bilgilerine kör olacak şekilde iki elektrofizyoloğa gösterilmiştir. Elektrofizyologlardan Brugada, Vereckei, R dalgası tepe zamanı (RWPT) ve ekstremite derivasyonları algoritması (LLA) adlı 4 algoritmayı kullanarak EKG'leri değerlendirmeleri istenilmiştir. Basit, hızlı ve doğru bir şekilde VT ayrımı sağlayabilecek bir algoritma tespit edilmek istenilerek LLA'nın teşhis performansı diğer algoritmalarınki ile karşılaştırılmıştır. Çalışmada her LLA ile 528 vakanın 465'i doğru olarak tanımlanmıştır. Elektrofizyolojik değerlendirmenin altın standart kabul edildiği çalışmada LLA'ın genel doğruluğu %88.1 ile Brugada (%85.4) ve Vereckei'ye (%88.19) benzer iken RWPT'den (%70.8) üstün olarak gözlenmiştir.

LLA duyarlılık bakımından %87.2 ile Brugada (%94.0) ve Vereckei'den (%92.4) düşük performans göstermişken, RWPT'den (%67.8) üstün gözlenmiştir. LLA dört algoritma arasında %90.8 ile en yüksek özgüllüğe sahip olarak gözlenmiş olup diğer algoritmalara bakıldığında Brugada'da bu oran %59.5 iken Vereckei'de %76.3 olup, RWPT'de %80.2'dir. Sonuç olarak LLA WCT'leri değerlendirmede ve VT-SVT teşhisinde basit ama doğru bir yöntem olarak değerlendirilmiştir (89). Bu çalışmada altın standart olarak elektrofizyolojik değerlendirmeler kullanılırken bizim çalışmamızda altın standart olarak kardiyoloji uzmanlarının değerlendirmeleri kullanılmıştır. Bu çalışmadaki algoritmaların doğruluk oranları ile çalışmamızda yer alan modellerin doğruluk oranları kıyaslandığında ResNet 18 için % 93.87; ResNet 34 için %94.02; ResNet 50 için %93.87 değerleri ile DL modellerinin, Brugada, Vereckei ve RWPT gibi geleneksel algoritmalardan daha yüksek oranda doğru tahminde bulunduğu gözlenmiştir. Çalışmada yer alan algoritmalar ile bizim modellerimizin spesifitelerine yönelik değerlendirmelere bakıldığında: ResNet 18 için % 97.77; ResNet 34 için %97.94; ResNet 50 için %96.57 olarak görülür ki bu oranlar çalışmada yer alan tüm algoritmaların spesifitelerinden yüksektir. DL modellerimizin yalnızca duyarlılık konusunda (ResNet 18 ve ResNet 34 için %60.87; ResNet 50 için %71.01) bu çalışmada yer alan oranların gerisinde kaldığı gözlenmiştir.

Wu ve arkadaşlarının yaptığı ve 2021 yılında yayınlanan çalışmada, MIT-BIH veri tabanı kullanılmıştır. Wu ve arkadaşları çalışmalarında, veri tabanındaki verileri 5 ritim sınıfına ayırmış. Sonrasında sınıflandırma için YSA çeşidi olan backpropagation (BP), rastgele orman (RF) ve iki farklı CNN kullanılmıştır. Çalışmada en yüksek doğruluk oranı %97,41 ile önerilen CNN algoritmasında gözlenmiş olup bu değer, BP'den %10.16; RF'den %1.69 ve diğer CNN'den %3.34 daha yüksektir. Önerilen CNN diğerinden farklı havuzlanma ve filtrelenme sistemlerine tabi tutulmuştur. Ayrıca doğruluk açısından başarılı bulunan CNN duyarlılık ve özgüllük açısından da diğerlerinden üstün izlenmiştir (90). Bizim çalışmamızda kullandığımız veri seti tarafımızca oluşturulmuş olup; kardiyoloji uzmanlarımızca etiketlenmiştir ve sahadan gerçek veriler kullanılmıştır. Çalışmamızda bir DL türü olan ResNet'in farklı katmanlı versiyonları kıyaslanmış olup doğruluk oranı tüm modellerimizde %95 olarak gözlenmiştir. Çalışmamızda kullandığımız ResNet modellerinde diğer CNN modellerine kıyasla derin ağlar daha eğitilebilir haldedir ve özellikle görüntü sınıflandırmada çok iyi sonuçlar vermektedir. Bu yüzden bizim çalışmamızda daha yüksek doğruluk oranları elde edilebilmiştir.

Chang ve arkadaşlarının yaptığı ve 2020'de yayınlanan Çin merkezli çalışmada, 2009-2018 yılları arasında toplamda 38899 hastanın 65932 adet 12 derivasyonlu EKG sinyalinden yararlanılmış ve bu veri setinden elde edilen 12 tür ritim bir derin öğrenme modeli olan LSTM'nin eğitim, doğrulama ve testinde kullanılmıştır. LSTM özellikle dizisel verilerin işlenmesinde kullanılan bir YSA modelidir. LSTM hazır hale geldiğinde ise veri seti dışında 116 hastaya ait EKG, hem kardiyoloji uzmanları, dahiliye uzmanları ve acil uzmanlarının olduğu ekibe verilmiş; hem de LSTM modeline verilmiş ve model ile hekimlerin prediksiyonları karşılaştırılmıştır. 12 kalp ritminin her birinin sınıflandırılmasına yönelik LSTM modelinin doğruluğu ≥ 0.982 (0.982-1.0), kesinliği 0.692 ile 1 arasında, duyarlılığı ise 0.625 ile 1 arasında gözlenmiştir. F_1 skoru ≥ 0.777 (0.777-1.0) olarak görülmüştür. Modelin doğruluğu; dahiliye uzmanlarının (0.55), acil tıp uzmanlarının (0.73) ve kardiyoloji uzmanlarının (0.83) ortalama doğruluklarından üstün olarak gözlenmiştir. Ayrıca model ile doktorların EKG yorumlama süreleri kıyaslanmış olup kardiyoloji uzmanlarının EKG başına ortalama 30 sn harcadığı gözlenirken; modelin ortalama 5 sn gibi bir sürede analiz ettiği gözlenmiştir.

Sonuç olarak kardiyak ritim bozukluklarının erken teşhisi açısından LSTM gibi DL modellerinin kullanımı önerilmiştir (91). Bu çalışmanın diğer çalışmalara göre güçlü olduğu noktalardan bir tanesi bizim çalışmamızda olduğu gibi kendi veri setlerine sahip olmalarıdır. Gerçek EKG'ler üzerinde modelin test edilebilmesine vurgu yapıldığı gözlenmiştir.

Ayrıca bizim çalışmamızda olduğu gibi 12 derivasyonlu EKG'lerin kullanılmış olması da modelin başarısını arttırmıştır. Bizim çalışmamızdan farklı olarak bu çalışmada elektrot hareket artefaktı ve kas artefaktları da dahil olmak üzere EKG gürültüsü olarak adlandırılan durumlar çalışılmamıştır. Gerçek EKG tahminlerinde bu durumun bozulmalara neden olabileceği düşünülmüştür. Ayrıca test verisinin yalnızca 116 hastadan oluşması nadir görülen ritimlerin analizi ve tahmin doğruluğu açısından soru işaretlerine neden olmaktadır. Son olarak, bizim çalışmamızda hipotezimizin temeli olan WCT ayrımının bu çalışmada yapılamadığı; çünkü bu nadir ritmin veri setlerinde yeterince bulunulmadığı ifade edilmiştir. Bizim çalışmamızda da WCT'ye sahip EKG'ler ne yazık ki azınlıktadır ancak bu durum gerçek hasta verileri ve saha bilgileri ile uyuşmaktadır. Bu durum dengesiz veri seti problemine neden olmaktadır; çalışmamızda bunun önüne geçmek için nadir ritimlerde daha büyük çarpanlar kullanılmıştır.Yine de söz konusu başarı oranları dahi oldukça tatmin edici olup mevcut veri setine eklemeler yapıldığında model daha da yüksek oranda doğru tahminler yapabilecektir.

Bizim çalışmamızda bu çalışmadan yine farklı olarak kendi topladığımız EKG'lerin tamamı eğitim, doğrulama ve testte kullanılmış olup; modelden elde edilen sonuçlar, altın standart olarak kabul ettiğimiz kardiyoloji uzmanlarımızın etiketlemeleri ile kıyaslanmıştır.

Acharya ve arkadaşlarının yaptığı ve 2017'de yayınlanan çalışmada, St.-Petersburg veri tabanı ile Fantasia isimli veri tabanından yararlanılmıştır (Physionet veri tabanları). Bu çalışma iki farklı CNN modeliyle gerçekleştirilmiştir; Net 1 olarak adlandırılan ilk CNN'de 15300'ü normal, 80000'i ise KAH etiketli sinyallerden elde edilen 2 sn'lik EKG segmentleri ile çalışılmışken ; Net 2 olarak adlandırılan CNN'de ise 6120'si normal, 32000'i KAH etiketli 5 sn'lik EKG segmentleri çalışılmıştır. Net 1 %94.95 doğruluk ve %93.72 duyarlılık ile Net 2 ise %95.11 doğruluk, %91.13 duyarlılık ile normal ve anormal EKG'yi ayırt edebilmiştir.

Sonuç olarak çalışmada EKG sinyallerini kullanarak KAH tanısı koymaya yönelik DL mimarisi kullanılması önerilmiştir. Bu çalışmada görüntü analizi ve sınıflandırmasında çok iyi performans göstermesi sebebiyle CNN seçilmiştir. Çalışmada EKG sinyallerinin uzunluklarının eğitim ve test için CNN yapısına bağlı olarak sabitlenmesi önerilmiştir. Özellik çıkarma, seçme ve sınıflandırma gibi prosedürleri bir araya getirmesi ve QRS tespitinin gerekli olmayışı önerilen sistemin avantajları olarak yorumlanmıştır (92). Bizim çalışmamızda da kullanmış olduğumuz ResNet modelleri de birer CNN'dir. CNN'ler DL alanında kullanılan bir YSA türüdür.

CNN'ler çoklu katmanları sayesinde yüksek düzeyde özellik çıkarabilmektedir. Görüntü verilerinin tahmininlerinin de genellikle yüksek doğruluk oranlarına sahip olmalarından ötürü; hem bu çalışmada hem de bizim çalışmamızda CNN kullanılmıştır. Bu çalışmada da bizim çalışmamızda olduğu gibi tenfold doğrulama kullanılmıştır. Bu yöntem sonuçların güvenilir ve sağlam olmasını sağlar. Çalışmanın bizimkine kıyasla hazır veri setlerinden seçilerek yapılması; söz konusu modellerin eğitim verilerinde kullanılması; klinik uygulamalarda kullanılamaması çalışmanın zayıf olduğu bir noktadır. Tüm DL çalışmalarında ve bizde de olduğu gibi bu çalışmada da büyük veri seti gereksinimleri mevcuttur. Bizim çalışmamızdaki modellerin performans metriklerine bakacak olursak tüm ResNet modellerinde %95 doğruluk ve %95 duyarlılık (ağırlıklı) ile SVT-VT ayrımının yapılabildiği gözlenmiştir. Eğer modellerden bu ayrımı NSR-taşiaritmik şeklinde yapması beklenecek olursa en az katman sayısına sahip ResNet 18 için dahi doğruluk %99.44 iken duyarlılık %99.23 olarak gözlenmektedir.

Acharya ve arkadaşlarının yine 2017 yılında yaptığı diğer bir çalışmada, bu kez aritmiler üzerinde durulmuştur. Çalışmada kullanılan EKG sinyalleri açık kaynaklı PhysioBank MIT-BIH Arrhythmia veri tabanından elde edilmiştir. Çalışma için toplam 109449 EKG atımı çıkarılmış ve bu atımlar 5 grupta sınıflandırılmıştır. Orijinal vuruş setinin gürültülü olması sebebiyle gürültü giderme işlemi uygulanılmış; orijinal veri setine küme A, gürültüsü giderilmiş veri seti sinyallerine ise küme B denilmiştir. Bu çalışmada da hem kendi çalışmalarında olduğu gibi hem bizim çalışmamızda olduğu gibi CNN kullanılmıştır. CNN modeli önce A veri setiyle sonrasında ise B veri setiyle eğitime tabi tutulmuştur.

Bu çalışmada bizim çalışmamızdan farklı olarak dengesiz veri seti probleminin üstesinden gelmek adına atım grupları arasındaki sayıları eşitlemek için sentetik veriler üretilmiştir. Bu çalışmada da bizim çalışmamızda olduğu gibi tenfold doğrulama kullanılmıştır. Çalışmanın sonuçlarına bakıldığında ise orijinal veri seti olan A kümesinde doğruluk oranı %93.47; sensitivite ise %96.01 olarak gözlenirken; gürültüden arındırma işlemi uygulanmış veri seti olan küme B'de %94.03'lük bir doğruluk oranı; %96.71'lik bir sensitivite gözlenmiştir. A ve B kümelerindeki sonuçların bu denli birbirine yakın olması, modelin gürültülü kalp atışlarını oldukça iyi algılayabildiğini ve algoritmanın gerekli filtrelemeyi kendi başına öğrenerek EKG sinyallerindeki istenmeyen gürültüyü kendi başına ortada kaldırdığını düşündürmüştür. Sentetik veriler öncesinde yer alan dengesiz veri seti ile çalışıldığında ise; doğruluğun gürültülü EKG'ler için %89.07'ye, gürültü işlemine alınan EKG'ler için %89.3'e düştüğü gözlenmiştir.

Sonuç olarak uygun şekilde eğitilmiş olan bir CNN'in aritmik kalp atışlarının farklı türlerini ve sıklıklarını hızlı ve doğru bir şekilde belirleyebileceği düşünülmüştür (93). Çalışmanın güçlü taraflarından biri CNN modelinin EKG sinyal kalitesinden bağımsız sonuç verebilmesi olarak değerlendirilmiştir. Çalışmada kullanılan 9 katmanlı CNN'in, bizim de çalışmamızda kullandığımız ResNet modelindeki gibi, tam otomatik bir model olmasından ötürü; ek bir özellik çıkarımı ya da seçimine gerek olmaması çalışmanın diğer bir artısıdır. Ayrıca hem önceki çalışmalarında kullandıkları; hem bizim çalışmamızda kullandığımız tenfold kullanımı yine çalışmaya güvenilirlik ve modele sağlamlık katmıştır. Kullanılan CNN modelinin ve bizim çalışmamızdaki ResNet modellerinin prediksiyon başarılarını kıyaslayacak olursak; bizim çalışmamızda incelemiş olduğumuz SVT-VT ayrımını modellerimiz %95 doğruluk ve duyarlılık ile yapmış olup bu yönden Acharya ve arkadaşlarının yaptığı çalışmadaki prediksiyonlardan başarılı olduğu gözlenmiştir. Diğer DL çalışmalarında olduğu gibi modellerin stabil ve doğru prediksiyonlar yapabilmesi için gereken veri setinin büyüklüğü bu çalışmada da vurgulanmıştır.

Jo ve arkadaşlarının yaptığı ve 2021'de yayınlanan çok merkezli retrospektif çalışmada, paroksismal olması nedeniyle her zaman saptanamayan paroksismal SVT'nin, normal sinüs ritmi sırasında tanımlanması amaçlanmıştır.

Çalışmada 111'inde paroksismal SVT olan (58 AVNRT, 53 AVRT) toplam 12955 hasta kardiyologlar tarafından değerlendirilmiştir. Bu çalışmada kullanılan DL modeline bakıldığında bizim de çalışmamızda kullandığımız ResNet' te olduğu gibi reziduel blokların kullanıldığı bir CNN olduğu görülmektedir. Kullanılan DL modelinde paroksismal SVT gelişmesinde önemli etkisi olan EKG bölümlerini belirleyebilmek için duyarlılık haritası yöntemi kullanılmıştır. DL modelinin % 97 doğruluk, % 86 duyarlılık ile paroksismal SVT'yi ayırabildiği gözlenmiştir. Ayrıca model, delta dalgası ve QT aralığının paroksismal SVT'yi tanımlamada önemli olduğunu göstermiştir. DL modelinin başarı performansının oldukça yüksek olduğu çalışmada DL modelleri hızlı, ucuz ve hasta başı kullanılarak klinisyene yardımcı olabilecek bir araç olarak önerilmiştir (94). Hem bizim çalışmamızda hem de bu çalışmada retrospektif tasarımlarından ötürü veriler geriye dönük olarak kullanılmış ve doğrulanmış olup; ileriye dönük çalışmalar ve günlük verilerle modellerimizin doğrulanması çalışmalarımızı daha da değerli hale getirecektir. Bizim çalışmamız tek merkezde, bu çalışma ise iki merkezde yürütülmüş olup; çalışmalarımızda önerdiğimiz DL modellerinin çok merkezli olarak hatta farklı ülkelerde doğruluklarını test etmek modellerin gelişmesi ve güvenilirlikleri açısından önemlidir.

Bu çalışmada da bizim çalışmamızda olduğu gibi gerçek veri kullanılması ve çalışmamızdan fazla miktarda veri ile modelin eğitilmiş olması, modelin başarısına da yansımıştır. Çalışmada incelenen hasta EKG'leri dışında hastalarda paroksismal SVT epizodları olmadığını varsayılmıştır; ancak bu EKG'lere yansımayan durumlar da söz konusu olabilir. Bu nedenle uzun süreli EKG izlemesi yaparak bu bulguyu doğrulamak adına daha ileri çalışmalara ihtiyaç vardır.

Hannun ve arkadaşlarının yaptığı 2019'da yayımlanan ve retrospektif olarak planlanan çalışmada, Stanford Üniversitesi'ne 2013-2017 arasında başvuran 53877 hastanın kayıtlarına ulaşılmış ve eğitim veri seti oluşturulmuştur. Oluşturulan veri setinde 12 çeşit EKG ritmi önce gözden geçirilmiş ve AV blok gibi nadir ritimler için kasıtlı olarak fazla örnekleme yapılarak sınıflar eğitim veri setinde dengelenmeye çalışılmış ve dengesiz veri seti probleminin önüne geçilmek istenilmiş, test veri setinde ise her bir hastadan bir kayıt alınmıştır. Elde edilen veriler geliştirilen derin sinir ağını (DNN) eğitmek ve test etmek için kullanılmıştır.

Kullanılan DNN'de bizim çalışmamızda kullandığımız modeldeki ağa benzer katman ve bağlantılar kullanılmıştır. Ayrıca oluşturulan DNN modeli Physionet üzerinden ulaşılan verilerle de değerlendirilip yeniden eğitilerek modelde bazı modifikasyonlar yapılmıştır. Sonuçta geliştirilen DNN modeline ait F_1 skoru 0.837 olarak gözlenmiştir. Modelin prediksiyonları ile kıyaslanan kardiyolog prediksiyonları için hesaplanan F1 skoru ise 0.780 olarak gözlenmiştir. Çalışma sonucunda DNN modelinin çoğu ritimde kardiyologlardan daha doğru ve hızlı performans sergilediği; bu ve benzeri modellerin kullanılmakta olan bilgisayarlı EKG yorumlarına göre klinisyenlere daha çok yardımcı olabileceği ve acil durumlarda triyajın daha doğru yapılabilmesine katkı sağlayabileceği düşünülmüştür (95). Bizim çalışmamızda kullandığımız modellerimizden Resnet 18 ve 50 için F_1 skoru (ağırlıklı) 0.95 ; ResNet 34 için 0.94 olarak gözlenmiştir. Bu çalışmada kullanılan veri seti sayısı bizim çalışmamızdan fazla gözükse dahi çalışmamızda 12 derivasyonlu EKG'ler kullanılmışken, bu çalışmada tek derivasyonlu EKG'ler kullanılmıştır. Hem bu çalışmada hem bizim çalışmamızda veri setinin kardiyologlarca etiketlenme sürecinde, kayıtların nasıl etiketlendiğine dair farklılıklar sonucu etkileyebilmektedir. Bu çalışmanın da retrospektif olması klinik ortamlarda doğruluğunun tespit edilememiş olması çalışmanın kısıtlılıklarındandır. Yine ortak bir sorun olarak nadir ritimlerin az olmasından ötürü dengesiz veri seti probleminden bahsedilebilir. Bizim çalışmamızda bunun önüne geçilmek adına model eğitilirken nadir verilerin ceza katsayıları daha yüksek tutulmuştur. Bu çalışmada ise bunun önüne geçmek için nadir verilerden eğitim setine iki kayıt alınmışken, sayısı yeterli olan ritimlerden bir kayıt alınmıştır.

6. ÇALIŞMANIN KISITLILIKLARI

Tek merkezli ve retrospektif olarak gerçekleştirilen çalışmamızda, EKG veri setimizde bulunan VT EKG'leri, VT ritminin daha nadir görülmesinden dolayı sayıca SVT ve NSR EKG'lerinden oldukça azdır. Klinik pratiklerimiz ve literatürle uyumlu olan bu durum AI çalışmalarında yaygın bir problem olan dengesiz veri seti problemiyle uğraşmayı gerektirmiştir. Her geçen gün büyüyen EKG arşivleri sayesinde, veri setlerinde nadir ritimler de diğer ritimler kadar yer aldığında modellerin başarısı daha da artacaktır. Çok merkezli çalışmalarla veri setlerinin büyütülmesi de eğitim ve test kalitesini yükselterek doğru teşhis oranlarını arttırabilir. Bir diğer husus ise çalışmamızda kardiyoloji uzman hekimlerinin birbiriyle uzlaşmış olduğu EKG değerlendirmelerinin doğru teşhiste altın standart olarak alınmasıdır. Doğru teşhisler için kullanılacak altın standart tanı yöntemin elektrofizyolojik değerlendirmeler ile yapılması çalışmanın güvenilirliğini daha da arttıracaktır. Gelecek çalışmalarda retrospektif olarak değil de çok merkezli ileriye dönük olarak çalışılması ve hazır veri setlerinin yerineçalışmamızdaki gibi sahadan EKG verilerinin toplanması AI- EKG çalışmalarına yeni bir boyut getirerek yaygın klinik uygulamaların önünü açabilir.

7. SONUÇ

Dünya'da önde gelen, bulaşıcı olmayan ve önlenebilir ölüm sebeplerinden KVH'ları azaltmak için AI uygulamaları kritik bir rol oynayabilir. VT-SVT ayrımı, birçok algoritma ve yaklaşıma rağmen; tecrübeli klinisyenlerin dahi zorlandığı bir konuyken kullandığımız DL modelleri % 95 doğruluk ve duyarlılık ile VT-SVT ayrımı yapmıştır. Kullandığımız ResNet modellerinin hepsi SVT-VT ayrımını başarılı bir şekilde gerçekleştirebilmiştir. Bu uygulamalar sayesinde klinisyenlerin iş yükü azaltılarak birçok hastalığın erken teşhisi mümkün kılınabilir. Erken teşhisler, azalan hastane yatış süreleri ve yerinde tedaviler sayesinde mortalite ve morbiditeler önlenerek medikal giderler azaltılabilir.

8. KAYNAKLAR

1. The top 10 causes of death [Internet]. [cited 2023 Mar 3]. Available from: https://www.who.int/news-room/fact-sheets/detail/the-top-10-causes-of-death

2. Civek S, Akman M. Dünyada ve Türkiye'de kardiyovasküler hastalıkların sıklığı ve riskin değerlendirilmesi, Jour Turk Fam Phy [Internet]. 2022;13(1). Available from: www.turkishfamilyphysician.com

3. Electrocardiogram (ECG or EKG) - Mayo Clinic [Internet]. [cited 2023 Mar 3]. Available from: https://www.mayoclinic.org/tests-procedures/ekg/about/pac-20384983

4. Collet JP, Thiele H, Barbato E, Bauersachs J, Dendale P, Edvardsen T, et al. 2020 ESC Guidelines for the management of acute coronary syndromes in patients presenting without persistent ST-segment elevation. Vol. 42, European Heart Journal. Oxford University Press; 2021. p. 1289–367.

5. Lau EW, Pathamanathan RK, André Ng G, Cooper J, Douglas Skehan J, Griffith MJ. The Bayesian approach improves the electrocardiographic diagnosis of broad complex tachycardia. PACE - Pacing and Clinical Electrophysiology. 2000;23(10 I):1519–26.

6. Feeny AK, Chung MK, Madabhushi A, Attia ZI, Cikes M, Firouznia M, et al. Artificial Intelligence and Machine Learning in Arrhythmias and Cardiac Electrophysiology Running title: Feeny et al.; AI in EP [Internet]. Available from: http://ahajournals.org

7. Siontis KC, Noseworthy PA, Attia ZI, Friedman PA. Artificial intelligence-enhanced electrocardiography in cardiovascular disease management. Vol. 18, Nature Reviews Cardiology. Nature Research; 2021. p. 465–78.

8. Reichman, Eric. (2003). Emergency Medicine Procedures. Chapter 37: Cardiac Ultrasound.

9. Iaizzo, Paul. (2009). Handbook of Cardiac Anatomy, Physiology, and Devices. 10.1007/978-1-60327-372-5.

10. Padala SK, Cabrera J, Ellenbogen KA. Anatomy of the cardiac conduction system. Pacing and Clinical Electrophysiology [Internet]. 2021 Jan 12 [cited 2023 Mar 6];44(1):15–25. Available from: https://my.clevelandclinic.org/health/body/21648-heart-conduction-system

11. Electrophysiology of the Heart | Cardiology: An Integrated Approach | AccessMedicine | McGraw Hill Medical [Internet]. [cited 2023 Mar 7]. Available from: https://accessmedicine.mhmedical.com/content.aspx?sectionid=171660003&bookid=2224#171660031

12. Goldberger AL, Goldberger ZD, Shvilkin Alexei. Goldberger's clinical electrocardiography : a simplified approach. Elsevier/Saunders; 2013. 231 p.

13. ELECTROCARDIOGRAPHY: NORMAL HEART, ACUTE ISCHEMIA, AND CHRONIC DISEASE | Atlas of Cardiovascular Emergencies | AccessEmergency Medicine | McGraw Hill Medical [Internet]. [cited 2023 Mar 8]. Available from:

https://accessemergencymedicine.mhmedical.com/content.aspx?sectionid=72942822&bookid=1206#72942826

14. Cardiologic Principles I: Electrophysiologic and Electrocardiographic Principles | Goldfrank's Toxicologic Emergencies, 11e | AccessEmergency Medicine | McGraw Hill Medical [Internet]. [cited 2023 Mar 8]. Available from: https://accessemergencymedicine.mhmedical.com/content.aspx?bookid=2569&sectionid=210259136#216828793

15. Çekik R, Telçeken S. Anadolu Üniversitesi Bilim ve Teknoloji Dergisi A-Uygulamalı Bilimler ve Mühendislik. Anadolu University Journal of Science and Technology A-Applied Sciences and Engineering.

16. Tan SY. Merritt C. Willem Einthoven : father of electrocardiography. Singapore Med J. 2012;53:17-8. 2012.

17. Rautaharju PM. Eyewitness to history: Landmarks in the development of computerized electrocardiography. . J Electrocardiol ;49:1-6. 2016;

18. Ekg (elektrokardiografi) [Internet]. [cited 2023 Mar 6]. Available from: https://www.slideshare.net/Zuleyhakundak/ekg-elektrokardiografi-135934988

19. Electrocardiography | Harrison's Principles of Internal Medicine, 21e | AccessMedicine | McGraw Hill Medical [Internet]. [cited 2023 Mar 8]. Available from: https://accessmedicine.mhmedical.com/content.aspx?sectionid=265437018&bookid=3095#265437025

20. Ling Tan L, Guan Teo S, Keong Poh K. ECG P wave abnormalities CMEArticle Fig. 1 ECG shows bifid P waves in leads II, III and aVF. Vol. 54, Singapore Med J. 2013.

21. Bergenholm L, Parkinson J, Mettetal J, Evans ND, Chappell MJ, Collins T. Predicting QRS and PR interval prolongations in humans using nonclinical data. Br J Pharmacol. 2017;174(19):3268–83.

22. QRS Interval • LITFL • ECG Library Basics [Internet]. [cited 2023 Mar 9]. Available from: https://litfl.com/qrs-interval-ecg-library/

23. The ST Segment • LITFL • ECG Library Basics [Internet]. [cited 2023 Mar 9]. Available from: https://litfl.com/st-segment-ecg-library/

24. T wave • LITFL • ECG Library Basics [Internet]. [cited 2023 Mar 9]. Available from: https://litfl.com/t-wave-ecg-library/

25. QT Interval • LITFL • ECG Library Basics [Internet]. [cited 2023 Mar 9]. Available from: https://litfl.com/qt-interval-ecg-library/

26. Gaita F, Giustetto C, Bianchi F, Wolpert C, Schimpf R, Riccardi R, et al. Short QT syndrome: A familial cause of sudden death. Circulation [Internet]. 2003 Aug 26 [cited 2023 Mar 9];108(8):965–70. Available from: https://litfl.com/qt-interval-ecg-library/

27. Sovari AA, Farokhi F, Kocheril AG. Inverted U wave, a specific electrocardiographic sign of cardiac ischemia. American Journal of Emergency Medicine. 2007 Feb;25(2):235–7.

28. ECG Rhythm Evaluation • LITFL • ECG Library Basics [Internet]. [cited 2023 Mar 9]. Available from: https://litfl.com/ecg-rhythm-evaluation/

29. Blissett S, Cavalcanti R, Sibbald M. ECG rhythm analysis with expert and learner-generated schemas in novice learners. Advances in Health Sciences Education. 2015 Oct 13;20(4):915–33.

30. Normal Sinus Rhythm • LITFL Medical Blog • ECG Library Basics [Internet]. [cited 2023 Mar 10]. Available from: https://litfl.com/normal-sinus-rhythm-ecg-library/

31. James Buckley CI, Garcia B. Buckley II C, & Garcia B (2017). Cardiac arrhythmias. Stone C, & Humphries R.L.(Eds.), CURRENT Diagnosis & Treatment Emergency Medicine, 8e. McGraw Hill.

32. TANDOĞAN İ, YÜCEL O. Dar QRS'li Taşikardilerde Acil Yaklaşım. Türkiye Klinikleri Cerrahi Tıp Bilimleri Dergisi [Internet]. 2007 [cited 2023 Mar 10];3(46):74–82. Available from: https://www.turkiyeklinikleri.com/article/tr-dar-qrsli-tasikardilerde-acil-yaklasim-48322.html

33. Sinus tachycardia • LITFL • ECG Library Diagnosis [Internet]. [cited 2023 Mar 10]. Available from: https://litfl.com/sinus-tachycardia-ecg-library/

34. Focal Atrial Tachycardia (FAT) • LITFL • ECG Library Diagnosis [Internet]. [cited 2023 Mar 10]. Available from: https://litfl.com/atrial-tachycardia-ecg-library/

35. Medi C, Hankey GJ. Medi C, Hankey GJ, Freedman SB. Atrial fibrillation. Med J Aust. 2007 Feb 19;186(4)197-202. PMID 17309423 [Internet]. 2007. Available from: www.mja.com.au

36. Atrial Fibrillation • LITFL Medical Blog • CCC Cardiology [Internet]. [cited 2023 Mar 10]. Available from: https://litfl.com/atrial-fibrillation/

37. Atrial Flutter • LITFL • ECG Library Diagnosis [Internet]. [cited 2023 Mar 10]. Available from: https://litfl.com/atrial-flutter-ecg-library/

38. Wellens HJJ. Contemporary management of atrial flutter. Vol. 106, Circulation. 2002. p. 649–52.

39. Multifocal Atrial Tachycardia (MAT) • LITFL • ECG Library Diagnosis [Internet]. [cited 2023 Mar 10]. Available from: https://litfl.com/multifocal-atrial-tachycardia-mat-ecg-library/

40. Atrioventricular nodal reentry tachycardia (AVNRT) - Overview - Mayo Clinic [Internet]. [cited 2023 Mar 11]. Available from: https://www.mayoclinic.org/diseases-conditions/avnrt/cdc-20355254

41. Supraventricular Tachycardia (SVT) • LITFL • ECG Library Diagnosis [Internet]. [cited 2023 Mar 11]. Available from: https://litfl.com/supraventricular-tachycardia-svt-ecg-library/

42. Atrioventricular reentrant tachycardia (AVRT) associated with an accessory pathway - UpToDate [Internet]. [cited 2023 Mar 11]. Available from: https://www.uptodate.com/contents/atrioventricular-reentrant-tachycardia-avrt-associated-with-an-accessory-pathway

43. Atrioventricular Re-entry Tachycardia (AVRT) • LITFL • ECG Library Diagnosis [Internet]. [cited 2023 Mar 11]. Available from: https://litfl.com/atrioventricular-re-entry-tachycardia-avrt/

44. Cardiac Rhythm Disturbances | Tintinalli's Emergency Medicine: A Comprehensive Study Guide, 9e | AccessEmergency Medicine | McGraw Hill Medical [Internet]. [cited 2023 Mar 11]. Available from: https://accessemergencymedicine.mhmedical.com/content.aspx?sectionid=218687685&bookid=2353#257336160

45. Ventricular Tachycardia | The Atlas of Emergency Medicine, 5e | AccessEmergency Medicine | McGraw Hill Medical [Internet]. [cited 2023 Mar 11]. Available from: https://accessemergencymedicine.mhmedical.com/content.aspx?sectionid=250463215&bookid=2969&Resultclick=2

46. Ventricular Tachycardia – Monomorphic VT • LITFL • ECG Library [Internet]. [cited 2023 Mar 11]. Available from: https://litfl.com/ventricular-tachycardia-monomorphic-ecg-library/

47. Polymorphic VT and Torsades de Pointes (TdP) • LITFL [Internet]. [cited 2023 Mar 11]. Available from: https://litfl.com/polymorphic-vt-and-torsades-de-pointes-tdp/

48. Ten Tusscher, K H W J et al. "Organization of ventricular fibrillation in the human heart experiments and models." Experimental physiology vol. 94,5 (2009) 553-62. doi10.1113expphysiol.2008.044065.

49. Ventricular Fibrillation (VF) • LITFL • ECG Library Diagnosis [Internet]. [cited 2023 Mar 11]. Available from: https://litfl.com/ventricular-fibrillation-vf-ecg-library/

50. Brady WJ, Glass III G.F. (2020). Cardiac rhythm disturbances. Tintinalli J.E., & Ma O, & Yealy D.M., & Meckler G.D., & Stapczynski J, & Cline D.M., & Thomas S.H.(Eds.), Tintinalli's Emergency Medicine: A Comprehensive Study Guide, 9e. McGraw Hill. https://accessemergencymedicine.mhmedical.com/content.aspx?bookid=2353&sectionid=218687685 [Internet]. [cited 2023 Mar 12]. Available from: https://accessemergencymedicine.mhmedical.com/content.aspx?sectionid=218687685&bookid=2353

51. Sidhu S, Marine JE. Evaluating and managing bradycardia. Vol. 30, Trends in Cardiovascular Medicine. Elsevier Inc.; 2020. p. 265–72.

52. Sinus Bradycardia • LITFL • ECG Library Diagnosis [Internet]. [cited 2023 Mar 12]. Available from: https://litfl.com/sinus-bradycardia-ecg-library/

53. Moffett P& HG. EMRA EKG Guide. Annals of Emergency Medicine. 2018.

54. Sinus Node Dysfunction (Sick Sinus Syndrome) • LITFL • ECG Library [Internet]. [cited 2023 Mar 12]. Available from: https://litfl.com/sinus-node-dysfunction-sick-sinus-syndrome/

55. Brady W.J., & Glass III G.F. (2020). Cardiac rhythm disturbances. Tintinalli J.E., & Ma O, & Yealy D.M., & Meckler G.D., & Stapczynski J, & Cline D.M., & Thomas S.H.(Eds.), Tintinalli's Emergency Medicine: A Comprehensive Study Guide, 9e. McGraw Hill. [Internet]. [cited 2023 Mar 12]. Available from:

https://accessemergencymedicine.mhmedical.com/content.aspx?sectionid=218687685&bookid=2353

56. Junctional Escape Rhythm • LITFL • ECG Library Diagnosis [Internet]. [cited 2023 Mar 12]. Available from: https://litfl.com/junctional-escape-rhythm-ecg-library/

57. Ventricular Escape Rhythm • LITFL • ECG Library Diagnosis [Internet]. [cited 2023 Mar 12]. Available from: https://litfl.com/ventricular-escape-rhythm-ecg-library/

58. ARRHYTHMIAS | Atlas of Cardiovascular Emergencies | AccessEmergency Medicine | McGraw Hill Medical [Internet]. [cited 2023 Mar 12]. Available from: https://accessemergencymedicine.mhmedical.com/content.aspx?sectionid=72943351&bookid=1206#1105986873

59. First Degree Heart Block • LITFL • ECG Library Diagnosis [Internet]. [cited 2023 Mar 13]. Available from: https://litfl.com/first-degree-heart-block-ecg-library/

60. Hay J. BRADYCARDIA AND CARDIAC ARRHYTHMIA PRODUCED BY DEPRESSION OF CERTAIN OF THE FUNCTIONS OF THE HEART. The Lancet. 1906 Jan 20;167(4299):139–43.

61. Second-degree Atrioventricular block • LITFL • Medical Eponym Library [Internet]. [cited 2023 Mar 13]. Available from: https://litfl.com/second-degree-atrioventricular-block/

62. Cardiac Rhythm Disturbances | Tintinalli's Emergency Medicine: A Comprehensive Study Guide, 9e | AccessEmergency Medicine | McGraw Hill Medical [Internet]. [cited 2023 Mar 13]. Available from: https://accessemergencymedicine.mhmedical.com/content.aspx?sectionid=218687685&bookid=2353

63. AV Block: 2nd degree, Mobitz II (Hay block) • LITFL [Internet]. [cited 2023 Mar 13]. Available from: https://litfl.com/av-block-2nd-degree-mobitz-ii-hay-block/

64. AV block: 3rd degree (complete heart block) • LITFL • ECG Library [Internet]. [cited 2023 Mar 13]. Available from: https://litfl.com/av-block-3rd-degree-complete-heart-block/

65. Tan NY, Witt M, Oh JK, Cha YM. Circulation: Arrhythmia and Electrophysiology Left Bundle Branch Block Current and Future Perspectives. Circ Arrhythm Electrophysiol [Internet]. 2020 [cited 2023 Mar 13];13:8239. Available from: www.ahajournals.org/journal/circep

66. Left Bundle Branch Block (LBBB) • LITFL • ECG Library Diagnosis [Internet]. [cited 2023 Mar 13]. Available from: https://litfl.com/left-bundle-branch-block-lbbb-ecg-library/

67. Birnbaum Y, Nikus K, Atar D, Jneid H. Is RBBB the new LBBB? Are we going to repeat the same mistakes? Vol. 65, Journal of Electrocardiology. Elsevier B.V.; 2021. p. 34–6.

68. Right Bundle Branch Block (RBBB) • LITFL • ECG Library Diagnosis [Internet]. [cited 2023 Mar 13]. Available from: https://litfl.com/right-bundle-branch-block-rbbb-ecg-library/

69. Lau EW, Pathamanathan RK, André Ng G, Cooper J, Douglas Skehan J, Griffith MJ. The Bayesian approach improves the electrocardiographic diagnosis of broad complex tachycardia. PACE - Pacing and Clinical Electrophysiology. 2000;23(10 I):1519–26.

70. VT ile Aberran İletili SVT Ayrımı - Acilci.Net [Internet]. [cited 2023 Mar 15]. Available from: https://acilci.net/vt-svt-ayrimi/?_ga=2.86133535.642753254.1678283841-401427207.1655284602

71. VT versus SVT • LITFL Medical Blog • ECG Library Basics [Internet]. [cited 2023 Mar 15]. Available from: https://litfl.com/vt-versus-svt-ecg-library/

72. Dendi R, Josephson ME. A new algorithm in the differential diagnosis of wide complex tachycardia. Vol. 28, European Heart Journal. 2007. p. 525–6.

73. Algorithm VT versus SVT (Vereckei algorithm) - UpToDate [Internet]. [cited 2023 Mar 15]. Available from: https://sso.uptodate.com/contents/image/print?imageKey=CARD%2F79624

74. Blomström-Lundqvist C, Scheinman MM, Aliot EM, Alpert JS, Calkins H, Camm AJ, et al. ACC/AHA/ESC Guidelines for the Management of Patients with Supraventricular Arrhythmias - Executive Summary: A Report of the American College of Cardiology/American Heart Association Task Force on Practice Guidelines and the European Society of Cardiology Committee for Practice Guidelines (Writing Committee to Develop Guidelines for the Management of Patients with Supraventricular Arrhythmias). J Am Coll Cardiol. 2003 Oct 15;42(8):1493–531.

75. Haenlein M, Kaplan A. A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. Calif Manage Rev. 2019 Aug 1;61(4):5–14.

76. Kaul V, Enslin S, Gross SA. History of artificial intelligence in medicine. Vol. 92, Gastrointestinal Endoscopy. Mosby Inc.; 2020. p. 807–12.

77. Mintz Y, Brodie R. Introduction to artificial intelligence in medicine. Minimally Invasive Therapy and Allied Technologies. 2019 Mar 4;28(2):73–81.

78. P. P. Shinde, S. Shah. A Review of Machine Learning and Deep Learning Applications, 2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA), Pune, India, 2018, pp. 1-6, doi: 10.1109/ICCUBEA.2018.8697857. 2018.

79. T Akinsola JE, Jet A, O HJ. Supervised Machine Learning Algorithms: Classification and Comparison SQL Injection Attack (SQLIA) Detection and Prevention View project The Use Of BIG DATA in Mobile Analytics View project Supervised Machine Learning Algorithms: Classification and Comparison. International Journal of Computer Trends and Technology [Internet]. 2017;48. Available from: http://www.ijcttjournal.org

80. Pouyanfar S, Sadiq S, Yan Y, Tian H, Tao Y, Reyes MP, et al. A survey on deep learning: Algorithms, techniques, and applications. Vol. 51, ACM Computing Surveys. Association for Computing Machinery; 2018.

81. Gupta N. Network and Complex Systems Artificial Neural Network. 2013;3(1). Available from: www.iiste.org

82. Shrestha A, Mahmood A. Review of deep learning algorithms and architectures. Vol. 7, IEEE Access. Institute of Electrical and Electronics Engineers Inc.; 2019. p. 53040–65.

83. Jakhar D, Kaur I. Artificial intelligence, machine learning and deep learning: definitions and differences. Vol. 45, Clinical and Experimental Dermatology. Blackwell Publishing Ltd; 2020. p. 131–2.

84. Chahal A, Gulia P. Chahal, A., & Gulia, P. (2019). Machine learning and deep learning. Int. J. Innov. Technol. Explor. Eng, 8(12), 4910-4914. International Journal of Innovative Technology and Exploring Engineering. 2019 Oct 1;8(12):4910–4.

85. Gu J, Wang Z, Kuen J, Ma L, Shahroudy A, Shuai B, et al. Recent advances in convolutional neural networks. Pattern Recognit. 2018 May 1;77:354–77.

86. He F, Liu T, Tao D. Why ResNet Works? Residuals Generalize. IEEE Trans Neural Netw Learn Syst. 2020 Dec 1;31(12):5349–62.

87. Biyomedikal Görüntülerde Derin Öğrenme ile Mevcut Yöntemlerin Kıyaslanması. Comparison of Deep Learning and Existing Methods in Biomedical Imagery - PDF Ücretsiz indirin [Internet]. [cited 2023 Apr 3]. Available from: https://docplayer.biz.tr/143299201-Biyomedikal-goruntulerde-derin-ogrenme-ile-mevcut-yontemlerin-kiyaslanmasi-comparison-of-deep-learning-and-existing-methods-in-biomedical-imagery.html

88. Cross-Validation in Machine Learning: How to Do It Right - neptune.ai [Internet]. [cited 2023 Apr 1]. Available from: https://neptune.ai/blog/cross-validation-in-machine-learning-how-to-do-it-right

89. Chen Q, Xu J, Gianni C, Trivedi C, Della Rocca DG, Bassiouny M, et al. Simple electrocardiographic criteria for rapid identification of wide QRS complex tachycardia: The new limb lead algorithm. Heart Rhythm. 2020 Mar 1;17(3):431–8.

90. Wu M, Lu Y, Yang W, Wong SY. A Study on Arrhythmia via ECG Signal Classification Using the Convolutional Neural Network. Front Comput Neurosci. 2021 Jan 5;14.

91. Chang KC, Hsieh PH, Wu MY, Wang YC, Chen JY, Tsai FJ, et al. Usefulness of Machine Learning-Based Detection and Classification of Cardiac Arrhythmias With 12-Lead Electrocardiograms. Canadian Journal of Cardiology. 2021 Jan 1;37(1):94–104.

92. Acharya UR, Fujita H, Lih OS, Adam M, Tan JH, Chua CK. Automated detection of coronary artery disease using different durations of ECG segments with convolutional neural network. Knowl Based Syst. 2017 Sep 15;132:62–71.

93. Acharya UR, Oh SL, Hagiwara Y, Tan JH, Adam M, Gertych A, et al. A deep convolutional neural network model to classify heartbeats. Comput Biol Med. 2017 Oct 1;89:389–96.

94. Jo YY, Kwon JM, Jeon KH, Cho YH, Shin JH, Lee YJ, et al. Artificial intelligence to diagnose paroxysmal supraventricular tachycardia using electrocardiography during normal sinus rhythm. European Heart Journal. 2021 Jun 29;2(2):290–8.

95. Hannun AY, Rajpurkar P, Haghpanahi M, Tison GH, Bourn C, Turakhia MP, et al. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. Nat Med. 2019 Jan 1;25(1):65–9.

9. ÖZGEÇMİŞ

Adı Soyadı	: Can Berk İnan
Doğum Tarihi ve Yeri	: 26.11.1990/POLATLI
Medeni Durumu	: Evli
Adres	: Ankara Şehir Hastanesi / ANKARA
Telefon	:
Mail	:
Mezun Olduğu Tıp Fakültesi	: Kırıkkale Üniversitesi
Varsa Mezuniyet Derecesi	: -
Görev Yeri	: Polatlı Duatepe Devlet Hastanesi 2015-2019
	Ankara Şehir Hastanesi 2019-2023
Dernek Üyelikleri	: Türkiye Acil Tıp Derneği, Türk Eğitim Derneği
Yabancı Diller	: İngilizce

10. EKLER

T.C.
SAĞLIK BAKANLIĞI
İL SAĞLIK MÜDÜRLÜĞÜ
Ankara Şehir Hastanesi
2 Nolu Klinik Araştırmalar Etik Kurul Başkanlığı

Sayı : E.Kurul–E2-22-2645 No'lu çalışma

Ankara Bilkent Şehir Hastanesi Acil Tıp Kliniği'nde planlanan; Prof. Dr. Havva Şahin KAVAKLI'nın sorumlu araştırıcısı olduğu "Yapay Zeka Aracılığıyla Ventriküler Taşikardi (VT) ve Supraventriküler Taşikardi (SVT) Ayrımı" konulu çalışma incelenmiş olup, Etik açıdan oy birliği ile uygun görülmüştür.

23/11//2022

Prof. Dr. Fuat Emre Canpolat
2 Nolu Etik Kurul Başkanı

Etik Kurul Sekreterliği Üniversiteler Mah. Bilkent Cad. No:1 Çankaya/Ankara İrtibat; 2nolu Etik Kurul: B.Özkan K.Çetindağ
Tel: 0 (312) 552 66 00 Dahili:721197--721198

KLİNİK ARAŞTIRMALAR ETİK KURULU KARAR FORMU

ŞTIRMANIN AÇIK ADI	Yapay Zeka Aracılığıyla Ventriküler Taşikardi (VT) ve Supraventriküler Taşikardi (SVT) Ayrımı
RSA ARAŞTIRMANIN PROTOKOL KODU	-

ETİK KURUL BİLGİLERİ	ETİK KURULUN ADI	**Ankara Şehir Hastanesi 2 Nolu Klinik Araştırmalar Etik Kurul**
	AÇIK ADRESİ	Üniversiteler Mah. Bilkent Cad. No:1 ÇANKAYA /ANKARA
	TELEFON	0312 552 66 00
	FAKS	0312 552 99 82
	E-POSTA	ankarash.etikkurul2@sağlık.gov.tr

BAŞVURU BİLGİLERİ	KOORDİNATÖR/SORUMLU ARAŞTIRMACI UNVANI/ADI/SOYADI	Prof. Dr. Havva Şahin KAVAKLI			
	KOORDİNATÖR/SORUMLU ARAŞTIRMACININ UZMANLIK ALANI	Acil Tıp Kliniği			
	KOORDİNATÖR/SORUMLU ARAŞTIRMACININ BULUNDUĞU MERKEZ	**Ankara Bilkent Şehir Hastanesi**			
	VARSA İDARİ SORUMLU UNVANI/ADI/SOYADI	-			
	DESTEKLEYİCİ	-			
	PROJE YÜRÜTÜCÜSÜ UNVANI/ADI/SOYADI (TÜBİTAK vb. gibi kaynaklardan destek alanlar için)	-			
	DESTEKLEYİCİNİN YASAL TEMSİLCİSİ	-			
	ARAŞTIRMANIN FAZI VE TÜRÜ	FAZ 1	☐		
		FAZ 2	☐		
		FAZ 3	☐		
		FAZ 4	☐		
		Gözlemsel ilaç çalışması	☐		
		Tıbbi cihaz klinik araştırması	☐		
		İn vitro tıbbi tanı cihazları ile yapılan performans değerlendirme çalışmaları	☐		
		İlaç dışı klinik araştırma	☐		
		Diğer ise belirtiniz: **Retrospektif Çalışma** (Dr. Can Berk İNAN'ın tezi)			
	ARAŞTIRMAYA KATILAN MERKEZLER	TEK MERKEZ ☒	ÇOK MERKEZLİ ☐	ULUSAL ☐	ULUSLARARASI ☐

2 Nolu Etik Kurul Başkanının
Unvanı/Adı/Soyadı:Prof. Dr. Fuat Emre CANPOLAT
İmza:

KLİNİK ARAŞTIRMALAR ETİK KURULU KARAR FORMU

...ŞTIRMANIN AÇIK ADI	Yapay Zeka Aracılığıyla Ventriküler Taşikardi (VT) ve Supraventriküler Taşikard (SVT) Ayrımı
...RSA ARAŞTIRMANIN PROTOKOL KODU	-

	Belge Adı	Tarihi	Versiyon Numarası	Dili
DEĞERLENDİRİLEN BELGELER	ARAŞTIRMA PROTOKOLÜ			Türkçe ☐ İngilizce ☐ Diğer ☐
	BİLGİLENDİRİLMİŞ GÖNÜLLÜ OLUR FORMU			Türkçe ☐ İngilizce ☐ Diğer ☐
	OLGU RAPOR FORMU			Türkçe ☐ İngilizce ☐ Diğer ☐
	ARAŞTIRMA BROŞÜRÜ			Türkçe ☐ İngilizce ☐ Diğer ☐

	Belge Adı		Açıklama
DEĞERLENDİRİLEN DİĞER BELGELER	SİGORTA	☐	
	ARAŞTIRMA BÜTÇESİ	☐	
	BİYOLOJİK MATERYEL TRANSFER FORMU	☐	
	İLAN	☐	
	YILLIK BİLDİRİM	☐	
	SONUÇ RAPORU	☐	
	GÜVENLİLİK BİLDİRİMLERİ	☐	
	DİĞER:	☐	

KARAR BİLGİLERİ	**Karar No:E2-22-2645** **Tarih: 23/11/2022** Yukarıda bilgileri verilen başvuru dosyası ile ilgili belgeler araştırmanın/çalışmanın gerekçe, amaç, yaklaşım ve yöntemler dikkate alınarak incelenmiş ve uygun bulunmuş olup araştırmanın/çalışmanın başvuru dosyasında belirtilen merkezlerde gerçekleştirilmesinde etik ve bilimsel sakınca bulunmadığına toplantıya katılan etik kurul üye tam sayısının salt çoğunluğu ile karar verilmiştir. İlaç ve Biyolojik Ürünlerin Klinik Araştırmaları Hakkında Yönetmelik kapsamında yer alan araştırmalar/çalışmalar için Türkiye İlaç ve Tıbbi Cihaz Kurumu'ndan izin alınması gerekmektedir.

2 Nolu Etik Kurul Başkanının
Unvanı/Adı/Soyadı:Prof. Dr. Fuat Emre CANPOLAT
İmza:

KLİNİK ARAŞTIRMALAR ETİK KURULU KARAR FORMU

...TIRMANIN AÇIK ADI	Yapay Zeka Aracılığıyla Ventriküler Taşikardi (VT) ve Supraventriküler Taşikardi (SVT) Ayrımı
...A ARAŞTIRMANIN PROTOKOL KODU	-

KLİNİK ARAŞTIRMALAR ETİK KURULU	
KURULUN ÇALIŞMA ...	İlaç ve Biyolojik Ürünlerin Klinik Araştırmaları Hakkında Yönetmelik, İyi Klinik Uygulamaları Kılavuzu
...ANIN UNVANI / ADI / ...ADI:	Prof. Dr. Fuat Emre CANPOLAT

...vanı/Adı/Soyadı	Uzmanlık Alanı	Kurumu	Cinsiyet		Araştırma ile ilişki		Katılım *		İmza
...Dr. Fuat Emre ...IPOLAT	Çocuk Sağlığı ve Hastalıkları Neonatoloji	Ankara Bilkent Şehir Hastanesi	E ☒	K ☐	E ☐	H ☐	E ☐	H ☐	
...f. Dr. Ilkan TATAR	Anatomi	Hacettepe Üniversitesi Tıp Fakültesi	E ☒	K ☐	E ☐	H ☐	E ☐	H ☐	
...of. Dr. Dilek ŞAHİN	Kadın Hastalıkları ve Doğum /Perinatoloji	Ankara Bilkent Şehir Hastanesi	E ☐	K ☒	E ☐	H ☐	E ☐	H ☐	
...of . Dr. Mehmet Ali ...ahit ŞENDUR	Tıbbi Onkoloji	Ankara Bilkent Şehir Hastanesi (YBÜ)	E ☒	K ☐	E ☐	H ☐	E ☐	H ☐	
...rof. Dr. Bilgen BAŞGUT	Farmakoloji	Başkent Üniversitesi Eczacılık Fakültesi	E ☐	K ☒	E ☐	H ☐	E ☐	H ☐	
...rof. Dr. Özlem Yılmaz ...AŞDELEN	Fiziksel Tıp ve Rehabilitasyon	Ankara Bilkent Şehir Hastanesi	E ☐	K ☒	E ☐	H ☐	E ☐	H ☐	
Prof. Dr. Bedia DİNÇ	Tıbbi Mikrobiyoloji	Ankara Bilkent Şehir Hastanesi (S.B.Ü.)	E ☐	K ☒	E ☐	H ☐	E ☐	H ☐	
Doç. Dr. Hayriye Görde KANMAZ KUTMAN	Çocuk Sağlığı ve Hastalıkları Neonatoloji	Ankara Bilkent Şehir Hastanesi	E ☐	K ☒	E ☐	H ☐	E ☐	H ☐	
Doç. Dr. Gülhan KURTOĞLU ÇELİK	Acil Tıp	Ankara Bilkent Şehir Hastanesi (YBÜ)	E ☐	K ☒	E ☐	H ☐	E ☐	H ☐	
Doç. Dr. Ayça Tuba DUMANLI ÖZCAN	Anestezi ve Reanimasyon	Ankara Bilkent Şehir Hastanesi	E ☐	K ☒	E ☐	H ☐	E ☐	H ☐	
Doç.Dr. Dilek ÖZTAŞ	Halk Sağlığı	Ankara Bilkent Şehir Hastanesi (YBÜ)	E ☐	K ☒	E ☐	H ☐	E ☐	H ☐	
Doç. Dr. Muhammet Kadri ÇOLAKOĞLU	Gastroenteroloji Cerrahisi	Ankara Bilkent Şehir Hastanesi	E ☒	K ☐	E ☐	H ☐	E ☐	H ☐	
Sağ. Mens. Ölm. Üye. Mehmet Hilmi SEÇİLMİŞ	İktisat Maliye	Emekli	E ☒	K ☐	E ☐	H ☐	E ☐	H ☐	
Av. Mesut KELEKÇİBAŞI	Hukuk	Serbest Avukat	E ☒	K ☐	E ☐	H ☐	E ☐	H ☐	
Mühendis Merve ÖZYÜKSEL	Biyomedikal Mühendis	Türk Standartları Enstitüsü Direktifler Müdürlüğü	E ☐	K ☒	E ☐	H ☐	E ☐	H ☐	

*:Toplantıda Bulunma

2 Nolu Etik Kurul Başkanının
Unvanı/Adı/Soyadı:Prof. Dr. Fuat Emre CANPOLAT
İmza: