

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

KALP KRİZİNİN ERKEN TEŞHİSİ İÇİN EKG'DEKİ ST SEGMENTİ
DEĞİŞİMLERİNİN ZAMAN-FREKANS DÖNÜŞÜMLERİYLE TESPİTİ

YÜKSEK LİSANS TEZİ

Bilgisayar Müh. İlknur KAYIKÇIOĞLU

MAYIS 2017
TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**KALP KRİZİNİN ERKEN TEŞHİSİ İÇİN EKG'DEKİ ST SEGMENTİ DEĞİŞİMLERİNİN
ZAMAN-FREKANS DÖNÜŞÜMLERİYLE TESPİTİ**

Bilgisayar Mühendisi İLKNUR KAYIKÇIOĞLU

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
"BİLGİSAYAR YÜKSEK MÜHENDİSİ"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 02 / 05 / 2017

Tezin Savunma Tarihi : 22 / 05 / 2017

Tez Danışmanı : Yrd. Doç. Dr. Güzin ULUTAŞ

Trabzon 2017

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalında
İlknur Kayıkçoğlu tarafından hazırlanan

KALP KRİZİNİN ERKEN TEŞHİSİ İÇİN EKG'deki ST SEGMENTİ DEĞİŞİMLERİNİN
ZAMAN-FREKANS DÖNÜŞÜMLERİYLE TESPİTİ

başlıklı bu çalışma, Enstitü Yönetim Kurulunun 02 / 05 / 2017 gün ve 1700 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
YÜKSEK LİSANS TEZİ
olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Prof. Dr. Cemal KÖSE

Üye : Doç. Dr. Mehmet Sıraç ÖZERDEM

Üye : Yrd.Doç.Dr. Güzin ULUTAŞ



Prof. Dr. Sadettin KORKMAZ
Enstitü Müdürü

ÖNSÖZ

Dünyada olduğu gibi ülkemizde de en çok ölüme ve sakatlığa neden olan yaşam kalitesini olumsuz yönde etkileyen halk sağlığı sorunu bulaşıcı olmayan hastalıklardır. Bulaşıcı olmayan hastalıklar içerisinde birinci sırada kalp damar hastalıkları ve kalp damar hastalıklarından kaynaklı oluşan kalp krizi yer almaktadır. Kalp krizinin teşhis edilebilmesi için EKG kayıtlarının analizi ve yorumlanması yapılmaktadır. Kalp krizinde EKG kayıtlarının doğru şekilde analiz edilmesi kalp krizinin önlenmesinde ve kalp krizi oluştuktan sonra doğru teşhis ve tedavinin yapılması için oldukça önemlidir.

Tez çalışmasında EKG işaretinde ST segmenti değişiminin (yükselmesinin veya düşmesinin) tespitiyle kalp krizinin erken teşhisi yapılmıştır. Önerilen yöntemlerde zaman-frekans dağılımlarına dayalı öznitelikler kullanılarak; ST segmenti değişimli bölgenin sınıflandırma yöntemleriyle tespiti yapılmıştır. En iyi zaman frekans analizi ve sınıflandırma yöntemi belirlenmiş ve literatürdeki çalışmalarla kıyaslanmıştır. Geliştirilen sistemdeki bileşen ve yöntemler güncel yaklaşımlar olup geliştirilmekte olan Teletıp sistemin bir parçası olabilecek düzeydedir. Bu çalışma 1003 programı kapsamındaki 114E452 nolu projeyle TÜBİTAK tarafından desteklenmiştir.

Çalışmalarında danışmanlığımı üstlenen hocam Yrd.Doç.Dr. Güzin ULUTAŞ'a ilgi, destek ve tecrübelerinden dolayı teşekkürlerimi borç bilirim. Yüksek lisans süresince tecrübelerini paylaştığı için babam Prof.Dr. Temel KAYIKÇIOĞLU'na ve çalışma arkadaşım Fulya AKDENİZ'e ayrıca teşekkür ederim. Yüksek lisans eğitimim boyunca sabır, destek ve sevgileriyle yanımda olan sevgili aileme çok teşekkür ederim.

İlknur KAYIKÇIOĞLU
Trabzon 2017

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Kalp Krizinin Erken Teşhisi İçin EKG’deki ST Segmenti Değişimlerinin Zaman-Frekans Dönüşümleriyle Tespiti” başlıklı bu çalışmayı baştan sona kadar danışmanım Yrd.Doç.Dr. Güzin ULUTAŞ’IN sorumluluğunda tamamladığımı, deneyleri/analizleri ilgili laboratuarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

İlknur KAYIKÇIOĞLU
Trabzon 2017

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET.....	XII
SUMMARY	XIII
ŞEKİLLER DİZİNİ	XIV
TABLolar DİZİNİ	XVI
SEMBOLLER DİZİNİ.....	XVII
1. GENEL BİLGİLER	1
1.1. Giriş.....	1
1.2. Kalp Kası ve Elektriksel İletim Sistemi	2
1.3. Elektrokardiyogram.....	5
1.4. EKG Ne İçin Kullanılır?.....	6
1.5. EKG Dalgaları ve Aralıkları.....	5
1.5.1. P Dalgası.....	6
1.5.2. PR Aralığı.....	7
1.5.3. QRS Kompleksi.....	7
1.5.4. ST Segmenti	7
1.5.5. T Dalgası	8
1.5.6. QT Aralığı	8
1.5.7. U Dalgası	8
1.6. EKG Derivasyonları.....	9
1.6.1. Ekstremitte Derivasyonları.....	9
1.6.1.1. Bipolar Derivasyonlar	10
1.6.1.2. Artırılmış Derivasyonlar	12
1.6.2. Göğüs Derivasyonları.....	13
1.6.3. Kalbin Hangi Yüzüne Hangi Derivasyonlar Bakmaktadır?	15
1.6.4. Neden 12 Derivasyona İhtiyaç Duyulur?	16
1.6.5. Hastalıklar ve Teşhisi.....	17

1.6.5.1.	Miyokardiyal İskemi ve Miyokard İnfarktüs	17
1.6.5.1.1.	ST Segmenti Yükselmesi (Elevasyonu).....	19
1.6.5.1.2.	ST Segmenti Düşmesi (Depresyonu)	20
1.6.5.2.	Sessiz Miyokard İnfarktüs.....	21
1.7.	Literatür Özeti.....	22
1.8.	Veritabanlarının Tanıtımı	27
1.9.	Öznitelik Çıkarımı Yöntemleri.....	29
1.9.1.	Zaman-Frekans Dağılımları.....	29
1.9.1.1.	Wigner-Ville Zaman Frekans Dağılımı	30
1.9.1.2.	Choi-Williams Zaman Frekans Dağılımı	31
1.9.1.3.	Born-Jordan Zaman Frekans Dağılımı.....	32
1.9.1.4.	Bessel Zaman Frekans Dağılımı	32
1.9.1.5.	Zhao-Atlas-Marks Zaman Frekans Dağılımı.....	34
1.10.	Sınıflandırma Yöntemleri.....	34
1.10.1.	Karar Ağacı Yöntemleri	35
1.10.1.1.	Önerilen Yöntemlerde Kullanılan Karar Ağacı Sınıflandırma Yöntemleri.....	37
1.10.1.1.1.	Simple Tree Yöntemi.....	37
1.10.1.1.2.	Medium Tree Yöntemi.....	37
1.10.1.1.3.	Kompleks Tree Yöntemi.....	38
1.10.2.	Destek Vektör Makinelerine Genel Bakış.....	38
1.10.2.1.	Doğrusal Olarak Ayrılabilen 2 Sınıflı Veriler İçin Doğrusal DVM	38
1.10.2.2.	Doğrusal Olarak Ayrılamayan 2 Sınıflı Veriler İçin Doğrusal DVM.....	41
1.10.2.3.	Doğrusal Olmayan Destek Vektör Makineleri	43
1.10.2.4.	Çok Sınıflı Veriler için Destek Vektör Makineleri.....	43
1.10.2.5.	Önerilen Yöntemlerde Kullanılan Destek Vektör Makineleri.....	44
1.10.2.5.1.	Linear (Doğrusal) Destek Vektör Makinesi.....	45
1.10.2.5.2.	Fine Gaussian (Radyal Tabanlı) Destek Vektör Makinesi.	45
1.10.2.5.3.	Medium Gaussian (Radyal Tabanlı) Destek Vektör Makinesi	45
1.10.2.5.4.	Coarse Gaussian (Radyal Tabanlı) Destek Vektör Makinesi.....	45
1.10.2.5.5.	Kubik Destek Vektör Makinesi.....	46
1.10.2.5.6.	Kuadratik Destek Vektör Makinesi.	46
1.10.3.	K En Yakın Komşu Sınıflandırma Algoritması.....	46
1.10.3.1.	Önerilen Yöntemlerde Kullanılan K-EYK Yöntemleri.	46

1.10.3.1.1.Fine K-EYK Yöntemi.....	47
1.10.3.1.2.Medium K-EYK Yöntemi.....	47
1.10.3.1.3.Coarse K-EYK Yöntemi.....	47
1.10.3.1.4.Kosinüs K-EYK Yöntemi.....	48
1.10.3.1.5.Kubik K-EYK Yöntemi.....	48
1.10.3.1.6.Weighted K-EYK Yöntemi.....	48
1.10.4. Topluluk Sınıflandırıcıları Yöntemleri.....	49
1.10.4.1. Boosted Trees.....	49
1.10.4.2. Bagged Tress.....	49
1.10.4.3. Subspace K-EYK.....	50
1.11. Önerilen Yöntemlerin Performans Değerlendirmesi.....	50
2. YAPILAN ÇALIŞMALAR.....	53
2.1. Önerilen Yöntemlerde Kullanılan Veritabanları.....	54
2.2. Önerilen Yöntemlerde Kullanılan Ön İşleme.....	58
2.3. Önerilen Yöntemlerde Kullanılan Öznitelik Çıkartma.....	59
2.4. Önerilen Yöntemlerde Kullanılan Sınıflandırma Yöntemleri.....	74
2.5. Deneysel Sonuçlar ve Karşılaştırma.....	76
3. SONUÇLAR VE TARTIŞMA.....	97
4. ÖNERİLER.....	98
5. KAYNAKLAR.....	99
ÖZGEÇMİŞ	

Yüksek Lisans Tezi

ÖZET

KALP KRİZİNİN ERKEN TEŞHİSİ İÇİN EKG'DEKİ ST SEGMENTİ
DEĞİŞİMLERİNİN ZAMAN-FREKANS DÖNÜŞÜMLERİYLE TESPİTİ

İlknur KAYIKÇIOĞLU

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Danışman: Yrd. Doç. Dr. Güzin ULUTAŞ
2017 104 Sayfa

EKG işaretinde ST segmenti yükselmeleri ve düşmelerinin önceden tespit edilmesi miyokardiyal iskeminin önlenmesi ve ilerleyen zamanlarda oluşabilecek kalp krizinin (miyokard infarktüs) önlenmesi açısından oldukça önemlidir. Tez çalışmasında EKG R-R aralığındaki ST segmenti yükselmelerini veya düşmelerini önceden tespit etmek amacıyla zaman frekans dönüşümlerine dayalı yöntemler geliştirilmiştir. Tez çalışmasının ilk aşamasında; bir sınıf hastalıklı ve sağlıklı R-R aralıklarından, diğer sınıf ise ST segmenti değişimleri olan R-R aralıklarından oluşturulmuştur. İkinci aşamadaysa sağlıklı, hastalıklı, ST segmenti düşmesi ve ST segmenti yükselmesi olan R-R aralıkları dört sınıf olacak şekilde seçilmiştir.

Tez çalışması veritabanının oluşturulması, öznitelik çıkarılması ve sınıflandırma aşamalarından oluşmaktadır. Çalışmada MIT-BIH Aritmi, European ST-T ve Long Term ST veritabanlarından EKG R-R aralıkları seçilerek üretilen büyük veritabanları kullanılmıştır. Öznitelik çıkarma aşamasında Yumuşatılmış Wigner-Ville, Choi-Williams, Born-Jordan, Bessel ve Zhao-Atlas-Mark zaman frekans dönüşümlerinden yararlanılmıştır. Sınıflandırma performans sonuçları Karar Ağacı, Destek Vektör Makineleri, K en yakın komşuluk ve Topluluk Sınıflandırıcısı yöntemleriyle incelenmiştir. Sınıflandırma sonuçları literatürdeki çalışmalara ait değerlerin üstündedir. Ayrıca önerilen algoritmanın hızı tele-tıp sistemleri için oldukça uygundur. Tez çalışması geliştirilemekte olan Teletıp sisteminde Karar Destek sisteminin bir parçası olacaktır.

Anahtar Kelimeler: Elektrokardiyogram (EKG), ST segmenti değişimleri, Kalp Krizi, Zaman-Frekans Dönüşümleri, Örüntü Tanıma.

Master Thesis

SUMMARY

DETECTION OF ECG ST SEGMENT CHANGES USING TIME FREQUENCY
TRANSFORMS FOR THE EARLY DIAGNOSIS OF MYOCARDIAL INFARCTION

İlknur KAYIKÇIOĞLU

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Supervisor: Yrd. Doç. Dr. Güzin ULUTAŞ
2017 104 Pages

Early detection of ST segment's depression or elevation is very important for prevention of myocardial ischemia and it is very important to prevent a myocardial infarction that may occur in the future. In the thesis study, methods based on time-frequency transforms have been developed in order to early detection of ST segment's depressions or elevations in the ECG R-R interval. In the first phase of the thesis study; a class was formed from RR intervals with healthy and arrhythmia and the other class was formed from RR intervals with ST segment changes. In the second phase; R-R intervals with arrhythmia, healthy, ST segment depression and ST segment elevation were selected to be four classes.

The thesis study consist of database construction, feature extraction and classification. In the study large databases produced by selecting ECG R-R intervals from MIT-BIH Arrhythmia, European ST-T and Long Term ST databases were used. Smoothed Wigner-Ville, Choi-Williams, Born-Jordan, Bessel ve Zhao-Atlas-Mark time frequency transforms were used in the feature extraction. The classification performance results analyzed using Decision Tree, Support Vector Machines, K-nearest Neighbor and Ensemble Classifiers methods. The classification results are above the values belonging to the studies in the literature. In addition to the speed of the proposed algorithm is very suitable for telemedicine systems. The thesis study will be a part of the Decision Support System in the Telemedicine system being developed.

Key Words: Electrocardiogram (ECG), ST Segment Changes, Myocardial infarction, Time-Frequency Transforms, Pattern Recognition.

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.1. Depolarizasyon ve repolarizasyon durumunda hücre içi ve dışı yük dağılımlar ..3	
Şekil 1.2. Aktivasyon potansiyeli grafiği4	4
Şekil 1.3. Kalbin ileti sistemi5	5
Şekil 1.4. EKG dalga ve aralıkları.....6	6
Şekil 1.5. Farklı QRS kompleksleri8	8
Şekil 1.6. EKG oluşurken kalbin durumları9	9
Şekil 1.7. Ekstremitte derivasyonlar için elektrot bağlantı noktaları 10	10
Şekil 1.8. Einthoven Üçgeni 11	11
Şekil 1.9. EKG bipolar derivasyonlar için elektrot bağlantı noktaları 12	12
Şekil 1.10 EKG artırılmış derivasyonlar için elektrot bağlantı..... 13	13
Şekil 1.11. Göğüs derivasyonları için elektrot yerleşim noktaları..... 14	14
Şekil 1.12. Göğüs derivasyonları diyagramı..... 15	15
Şekil 1.13. Göğüs derivasyonlar için elektrot bağlantı noktaları..... 15	15
Şekil 1.14. 12 Farklı derivasyondaki EKG 17	17
Şekil 1.15. Miyokard İnfarktüs Sırasında EKG'nin Değişimi 18	18
Şekil 1.16. Göğüs derivasyonlarda gözüken ST segment yükselmeleri..... 20	20
Şekil 1.17. Ekstremitte ve göğüs derivasyonlarda gözüken ST segment yükselmeleri 20	20
Şekil 1.18. ST segmenti düşmesi 21	21
Şekil 1.19. Farklı göğüs derivasyonlarında gözüken ST segmenti düşmesi 21	21
Şekil 1.20. Protokollerin şematik Gösterimi..... 28	28
Şekil 1.21. Örnek Karar Ağacı..... 35	35
Şekil 1.22. Doğrusal olarak ayrılamayan 2 Sınıflı veriler için hiper düzlemin gösterimi..... 39	39
Şekil 1.23. Doğrusal olarak ayrılamayan 2 sınıflı veriler için hiper düzlemin gösterimi..... 42	42
Şekil 1.24. DVM'nin genel yapısı..... 44	44
Şekil 2.1. Sistemin temel adımları 53	53
Şekil 2.2. 109 Sol dal bloğu (Hastalıklı) V1 derivasyonu EKG Grafiği..... 56	56
Şekil 2.3. 124 Erken Karıncık Atımı(Hastalıklı) V4 derivasyonu EKG Grafiği..... 57	57
Şekil 2.4. s20571 ST segmenti düşmesi V5 derivasyonu EKG Grafiği 57	57

Şekil 2.5.	s20021 ST segmenti yükselmesi V4 derivasyonu EKG grafiği.....	57
Şekil 2.6.	e1304 ST segmenti düşmesi V1 derivasyonu EKG grafiği.	58
Şekil 2.7.	e0515 ST segmenti yükselmesi V2 derivasyonu EKG grafiği.....	58
Şekil 2.8.	Öznitelik çıkarma aşaması diyagramı.....	61
Şekil 2.9.	123 V5 derivasyonu sağlıklı EKG grafiği.....	62
Şekil 2.10.	Sağlıklı R-R aralığının YWVD spektrumu	62
Şekil 2.11.	Sağlıklı R-R aralığının CWD spektrumu	63
Şekil 2.12.	Sağlıklı R-R aralığının BJD spektrumu	63
Şekil 2.13.	Sağlıklı R-R aralığının BD spektrumu.....	64
Şekil 2.14.	Sağlıklı R-R aralığının ZAMD spektrumu.....	64
Şekil 2.15.	118 V1 derivasyonu hastalıklı EKG grafiği.....	65
Şekil 2.16.	Hastalıklı R-R aralığının YWVD spektrumu	66
Şekil 2.17.	Hastalıklı R-R aralığının CWD spektrumu	66
Şekil 2.18.	Hastalıklı R-R aralığının BJD spektrumu	66
Şekil 2.19.	Hastalıklı R-R aralığının BD spektrumu.....	67
Şekil 2.20.	Hastalıklı R-R aralığının ZAMD spektrumu.....	67
Şekil 2.21.	s20311 V3 derivasyonu ST segmenti yükselmesi EKG Grafiği.....	68
Şekil 2.22.	ST segmenti yükselmesi olan R-R aralığının YWVD spektrumu.....	68
Şekil 2.23.	ST segmenti yükselmesi olan R-R aralığının CWD spektrumu	69
Şekil 2.24.	ST segmenti yükselmesi olan R-R aralığının BJD spektrumu	69
Şekil 2.25.	ST segmenti yükselmesi olan R-R aralığının BD spektrumu	70
Şekil 2.26.	ST segmenti yükselmesi olan R-R aralığının ZAMD spektrumu.....	70
Şekil 2.27.	e0112 V4 derivasyonu ST segmenti düşmesi EKG grafiği.....	71
Şekil 2.28.	ST segmenti düşmesi olan R-R aralığının YWVD spektrumu	71
Şekil 2.29.	ST segmenti düşmesi olan R-R aralığının CWDspektrumu	72
Şekil 2.30.	ST segmenti düşmesi olan R-R aralığının BJD spektrumu.....	72
Şekil 2.31.	ST segmenti düşmesi olan R-R aralığının BD spektrumu	73
Şekil 2.32.	ST segmenti düşmesi olan R-R aralığının ZAMD spektrumu....	73
Şekil 2.33.	Birinci aşama çalışmalar için eğitim ve test seti oluşturma diyagramı.....	74
Şekil 2.34.	Birinci aşama çalışmalar için eğitim ve test seti oluşturma diyagramı.....	75

TABLULAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1.1. Ekstremitte derivasyonları ve kalbin yüzleri.....	14
Tablo 1.2. Göğüs derivasyonları ve kalbin yüzleri	15
Tablo 1.3. 2 sınıf için Konfüzyon matrisi.....	48
Tablo 1.4. Sınıf 1 için Konfüzyon matrisi.....	48
Tablo 1.5. Sınıf 3 için Konfüzyon matrisi.....	48
Tablo 2.1. MIT-BIH Aritmi veritabanından alınan kayıtlar.....	50
Tablo 2.2. European ST-T veritabanından alınan kayıtlar.....	51
Tablo 2.3. European ST-T ve Long Term ST veritabanından alınan ST segmenti yükselmesi olan kayıtlar.....	52
Tablo 2.4. European ST-T ve Long Term ST veritabanından alınan ST segmenti düşmesi olan kayıtlar.....	52
Tablo 2.5. YWVD dağılımı esaslı özniteliklerle performans analizi sonuçları.....	72
Tablo 2.6. CWD esaslı özniteliklerle performans analizi sonuçları.....	77
Tablo 2.7. BJD esaslı özniteliklerle performans analizi sonuçları.....	78
Tablo 2.8. BD esaslı özniteliklerle performans analizi sonuçları.....	79
Tablo 2.9. ZAMD esaslı özniteliklerle performans analizi sonuçları.....	80
Tablo 2.10. Dört sınıf için YWVD esaslı özniteliklerle performans analizi sonuçları.....	81
Tablo 2.11. YWD esaslı özniteliklerle en iyi sınıflandırma yönteminin konfüzyon Matrisi.....	83
Tablo 2.12. Dört sınıf için CWD esaslı özniteliklerle performans analizi sonuçları.....	84
Tablo 2.13. CWD esaslı özniteliklerle en iyi sınıflandırma yönteminin konfüzyon matrisi.....	86
Tablo 2.14. Dört sınıf için BJD esaslı özniteliklerle performans analizi Sonuçları.....	86
Tablo 2.15. BJD esaslı özniteliklerle en iyi sınıflandırma yönteminin konfüzyon matrisi.....	88
Tablo 2.16. Dört sınıf için BD esaslı özniteliklerle performans analizi sonuçları.....	89
Tablo 2.17. BD esaslı özniteliklerle en iyi sınıflandırma yönteminin konfüzyon matrisi.....	91
Tablo 2.18. Dört sınıf için ZAMD esaslı özniteliklerle performans analizi sonuçları.....	91
Tablo 2.19. ZAMD esaslı özniteliklerle en iyi sınıflandırma yönteminin konfüzyon Matrisi.....	93
Tablo 2.20. Önerilen yöntemin diğer çalışmalarla karşılaştırılması.....	94

SEMBOLLER DİZİNİ

EKG	Elektrokardiyogram
WHO	Dünya Sağlık Örgütü
SA	Sinoatriyal Düğüm
Physikalisch Technische Bundesanstalt	PTB
Destek Vektör Makineleri	DVM
K En Yakın Komşuluk	K-EYK
WaveForm DataBase	WFDB
Pozitif Prediktif Değer	PPD
Negatif Prediktif Değer	NPD
Doğru Pozitif	TP
Doğru Negatif	TN
Yanlış Pozitif	FP
Yanlış Negatif	FN
Wigner-Ville Dağılımı	WVD
Yumuşatılmış Wigner-Ville Dağılımı	YWVD
Choi-Williams Dağılımı	CWD
Born-Jordan Dağılımı	BJD
Bessel Dağılımı	BD
Zhao-Atlas-Mark Dağılımı	ZAMD
Rastgele Ormanlar	RO

1. GENEL BİLGİLER

1.1. Giriş

Elektrokardiyogram (EKG) analizi kalp krizinin tespit edilmesinde kullanılan en önemli yöntemlerden biridir. EKG kalpte oluşan elektriksel voltajları kaydeder. Kalp krizi öncesinde ve esnasında EKG ST segmenti seviyesinde değişimler oluşmaktadır. Bazı durumlarda kalp krizi hastada hiçbir belirti vermeden gerçekleşebilir. Ancak hastanın EKG kaydı incelendiğinde kalp krizi geçirdiği anlaşılabilir.

Hastanın kalp krizi geçirmeden önce alınan uzun süreli EKG kayıtlarındaki ST segment düşmeleri ve yükselmeleriyle kalp krizi geçirebileceğine dair teşhis koyulabilmektedir. Kalp krizin önceden tespit edilebilmesi ve gerekli önlemlerin alınabilmesi hastanın sağlığı için oldukça önemlidir. Aksi takdirde ani ölümler ortaya çıkmaktadır [1]. Dünya sağlık örgütü (WHO)'nün yaptığı araştırmalara göre her yıl 17,5 milyon insan kalp ve damar hastalıkları yüzünden hayatını kaybetmektedir. Bu da dünyadaki ölümlerin yaklaşık %31 ine denk gelmektedir. Ayrıca kalp hastalıklarına bağlı meydana gelen ölümlerin %80'ini kalp krizi ve felç oluşturmaktadır [2] .

Günümüzde hastanelerden uzaktaki hastalara doktorlarının ulaşım ve teşhis ve tedavilerin yapılabilmesi için Teletıp sistemlerinden yararlanılmaktadır. Teletıp sistemlerin birçok alt bileşenlerden oluşmakta olup bu alt bileşenlerden en önemlisi; hastanın yaşamı risk altına girince hastaya veya doktora alarm üretecek sistemlerdir.

Bu tez çalışmasında ilk olarak EKG sinyalindeki herhangi bir R-R aralığındaki ST segmentinde düşme veya yükselme olup olmadığını tespit edebilecek zaman frekans analizine dayalı sınıflandırma algoritmalarının gerçekleştirilmesi amaçlanmıştır. Çalışmanın ikinci aşamasında ise EKG sinyalindeki herhangi bir R-R aralığında ST segmenti düşmesi, ST segmenti yükselmesi ve herhangi bir aritminin olup olmadığını tespit edebilecek zaman frekans analizine dayalı sınıflandırma algoritmaları geliştirilmiştir. Önerilen algoritmalarda giriş olarak sadece R-R aralığı alınarak öznetelik çıkarma işlemi sağlanmıştır. Çalışmada ST segment değişimleri bulunarak miyokard iskemi veya miyokard infarktüs önceden tespiti sağlanarak kalp krizinin erken teşhisi sağlanmıştır. Birçok sınıflandırma algoritmaları kullanılarak önerilen yöntemlerin performans değerlendirmeleri yapılmıştır.


1.2. Kalp Kası ve Elektriksel İletim Sistemi

Kalp en basit şekliyle elektriksel olarak zamanlanmış bir pompa olarak düşünülebilir. Kalbin temel görevi ritmik olarak kasılarak oksijen seviyesi az olan kanı temizlemek için akciğerlere; oksijeni yüksek olan temiz kanıya vücuda pompalamaktır. Kalbin kasılması için gerekli sinyal kalp kasına elektrik akımlarıyla yayılır. Bu akımlar pacemaker hücreleri, özelleşmiş iletim sistemleriyle veya kalp kasının kendisiyle kalpte iletilir. İlerleyen bölümlerde ayrıntısı verilecek olan EKG sadece kalp kasının oluşturduğu akımları gösterir.

Kalp en genel ifadeyle sağ kulakçık (atrium), sağ karıncık (ventrikül), sol kulakçık ve sol karıncıktan oluşmaktadır. Kulakçıklar ve karıncıklar arasında tek yönlü çalışan kapakçıklar bulunur. Oksijeni az olan (kirli kan) önce sağ kulakçığa dolar daha sonra kapakçıklar yardımıyla sağ karıncığa geçiş yapar. Sağ karıncıktaki kan temizlenmek üzere akciğere damarlar aracılığıyla yönlendirilir. Akciğerde temizlenen kan damarlarla birlikte sol kulakçığa gelir daha sonra kapakçıklar yardımıyla sol karıncığa geçerek tüm vücuda yayılır. En basit haliyle kalbin çalışma mantığı yukarıda açıklanan şekildedir [3].

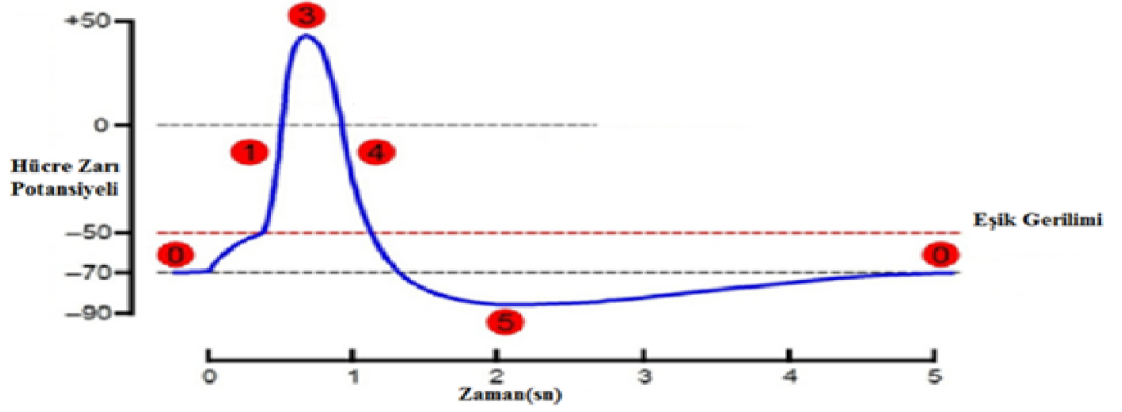
Kalbin normal ritmi sağ atriyumda yerleşmiş olan sinoatriyal (SA) düğümde veya bir başka deyişle sinüs düğümünde oluşturulur. Bu yüzden kalbin normal ritmi sinüs ritmi olarak adlandırılmaktadır. Bu düğümdeki hücreler kendinden uyarılabilen özel hücrelerdir. Aksiyon potansiyeli hücrelerin elektriksel olarak aktive olduğu noktadır. Kalp kası hücresinde oluşan iyonik değişimler sonucunda aksiyon potansiyeli oluşumu gerçekleşir. Sinir hücresi içinde ve dışında farklı yoğunluklarda iyonlar bulunur. Hücre zarı aktif ve pasif kanallar içerir. Aksiyon potansiyelinin oluşumuna en çok katkı sağlayan iyonlar Na^+ ve K^+ iyonlarıdır. Denge durumunda Na^+ iyonlarının yoğunluğu hücre dışında, K^+ iyonlarının yoğunluğu ise hücre içinde daha fazladır. Hücre zarındaki iyon kanallarının aktif olmasıyla ilk olarak hücre içerisine doğru Na^+ geçmesiyle birlikte hücre zarı potansiyelinde artışa neden olarak hücrenin uyarılmasını bir başka deyişle hücrenin depolarize olmasını sağlar. Bu uyarılma işlemine aksiyon potansiyelinde Faz 1 olarak adlandırılır. Faz 0 durumunda hücre dinlenme potansiyelindedir. Bu gerilim artışı belirli bir eşik değerinin üzerinde olursa Na^+ geçişleri hücre dışından içine doğru aktif sodyum kanallarından başlangıçta fazla sonradan azalarak devam eder. Bu sahfa hücrenin depolarizasyonu sahfası olup Faz 1 olarak adlandırılır. Sodyum iyonlarının geçişleri bitmeden, K^+ iyonlarının hücrenin içinden dışına doğru geçişleri başlamaktadır. Bu durumda aksiyon potansiyeli maksimum değere ulaşır. Bu Faz 3 olarak adlandırılır. Daha

sonra hücre zarının Na^+ geçirgenliğinin azaldığı ve K^+ geçirgenliğinin arttığı Faz 4 safhası olur. Bu safha hücrenin repolarizasyonu olarak adlandırılır. Son safhada K^+ geçirgenliği azalmaya başlar. Hücre potansiyeli denge potansiyelinin altına düştükten sonra bu potansiyele geri döner. Bu safhada hücrenin hiperpolarizasyonu söz konusu olup ve Faz 5 olarak adlandırılır. Şekil 1.1.'de depolarizasyon ve repolarizasyon durumunda hücre içi ve dışı elektriksel yük dağılımları görülmektedir. Burada S uyarıyı ifade etmektedir.



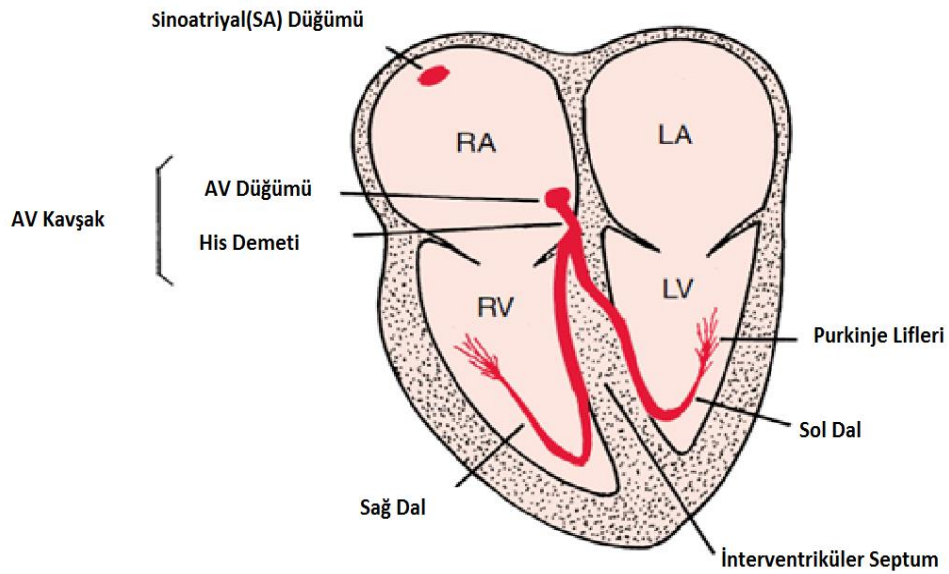
Şekil 1.1. Depolarizasyon ve repolarizasyon durumunda hücre içi ve dışı yük dağılımları [3].

Bu şekilde bir aksiyon potansiyeli gerçekleşir. Bir sonraki aksiyon potansiyelinin oluşabilmesi için hücre içi ve dışı iyon yoğunluklarının başlangıçtaki değerlere dönmesi gerekir. Bu sodyum potasyum pompası ile sağlanır. Oluşan aksiyon potansiyeli kalbin kas sistemine yayılarak atımını sağlar [4]. Aksiyon potansiyeliyle birlikte SA ateşlenir. Sinüs düğümü ortalama her saniyede bir ateşlenerek kalbin dakikada 60-70 kez atmasını sağlar. Şekil 1.2.'de aktivasyon potansiyeli aşamaların değişimi açıkça görülmektedir.



Şekil 1.2. Aktivasyon potansiyeli grafiği[5]

Kalp kası aktivasyonunun ilk aşaması sağ kulakçada yerleşen SA düğümünde başlatılır. Daha sonra elektriksel uyarı sağ kulakçından sol kulakçıya yayılır. Bir sonraki aşamada elektriksel uyarı atriyovenriküler düğümünden His demetine ulaşır. Bu elektriksel uyarı daha sonra His demetinin devamı olan sol ve sağ dallarla sol kulakçıya ve sağ kulakçıya geçer. Son olarak elektriksel uyarı Purkinje hücreleriyle kasa iletilir. Elektriksel uyarının kulakçıklarda yayılması kulakçıkların kasılmasına, karıncıklarda yayılmasıysa karıncıkların kasılarak kanın akciğerlere ve vücuda yayılmasını sağlar. Kalbin elektriksel uyarı dağılımı kulakçıklardan karıncıklara doğrudur. Şekil 1.3.'de kalbin ileti sistemi verilmiştir [3].



Şekil 1.3. Kalbin ileti sistemi [3].

Elektriksel uyarıların iletim hızı atriyoventriküler düğümde en yavaşken; Purkinje liflerinde en hızlıdır. Bu hız farkı kulakçıklar kasılmadan önce kanla dolabilmesi için yeterli zaman aralığını sağlar. Kalbin iletiminin dışında en önemli özelliklerin biri de otomatikliğidir. Yukarıda belirtildiği gibi SA doğal otomatikliği sayesinde kalbin en önemli ritim tutucusudur.

1.3. Elektrokardiyogram

Elektrokardiyogram (EKG) kalpte oluşan elektriksel voltajları kaydeder. Bu kayıt işlemi hastanın göğsüne veya hastanın kollarına ve bacaklarına takılan elektrotlar aracılığıyla yapar. EKG ile birlikte kalp kasında elektriksel uyarıların yayılması ve kalp kasının normal dinlenme durumuna dönüşü sırasında oluşan voltajlar kaydediler. Bu iki olay eş zamanlı gerçekleştiğinden EKG’de bu elektriksel akımlar dalgalar halinde kolaylıkla gözlemlenebilir. EKG cihazından gelen veriler EKG kâğıdı üzerine kaydedilir. EKG ile alakalı birçok çalışma yapan Willem Einthoven 1900 yılında galvanometreden yararlanarak ilk elektrokardiyografi cihazını geliştirmiştir [3].

1.4. EKG Ne İçin Kullanılır?

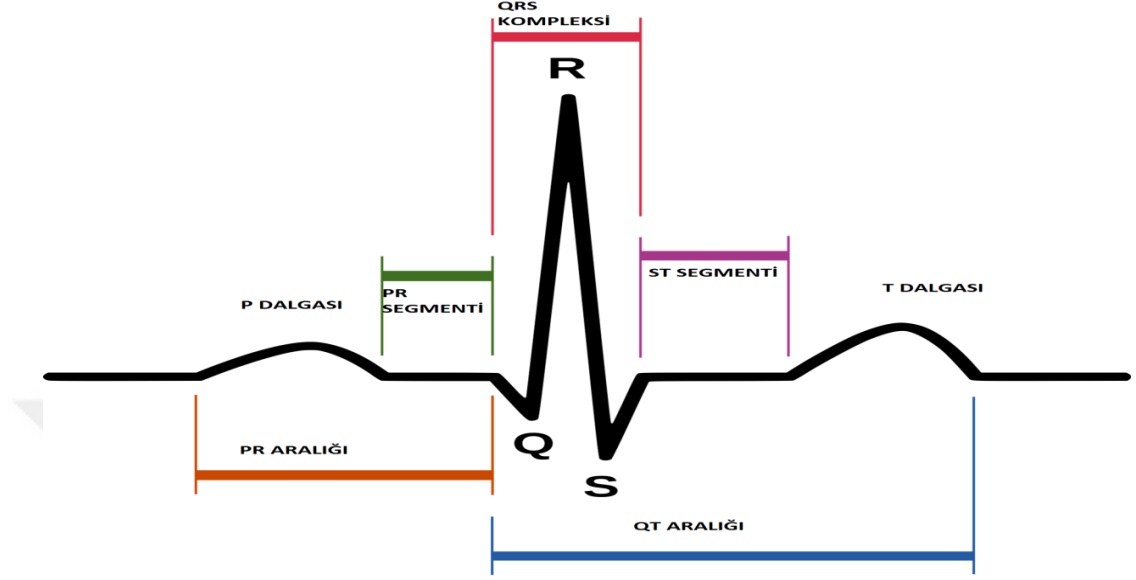
EKG’nin kullanım alanları şu şekilde sıralanabilir.

- Kalp ritm bozukluklarının tespiti ve sınıflandırılmasında
- Kalp krizi teşhisi ve diğer kalp hastalıklarının tanısında
- Kalp pillerinin en iyi şekilde değerlendirilmesinde
- Göğüs hastalıkları ve elektrolit bozuklukları tanısında
- İlaç yan etkileri ve ilaç zehirlenmelerinin teşhis edilmesinde kullanılmaktadır.

1.5. EKG Dalgaları ve Aralıkları

Kalpde elektriksel uyarımının kulakçıklar ve karıncıklar boyunca yayılması ve dinlenme durumuna dönmesi sonucunda EKG dalga ve aralıkları oluşur. Temel EKG dalgaları P,Q,R,S,T ve U dalgalarıdır. Genel olarak EKG P dalgası, PR aralığı, QRS kompleksi, ST segmenti, T dalgası, QT aralığı ve U dalgasından oluşmaktadır. Şekil 1.4.’

de Normal EKG dalga şekilleri ve aralıkları verilmiştir. Bazı durumlarda U dalgası gözükmez. Bu yüzden Şekil 1.4’de verilmemiştir.



Şekil 1.4. EKG dalga ve aralıkları [7].

Dalgalar pozitif, negatif veya bifazik olarak tanımlanabilirler. Genel olarak yukarı doğru olan dalgalar pozitif, aşağı doğru olan dalgalar ise negatif olarak adlandırılır. Bazal çizgide olan dalgalar ise izoelektrik olarak tanımlanır. Bir bölümü negatif bir bölümü pozitif olan dalgalar da bifazik olarak adlandırılır. Örneğin Şekil 4’deki QRS kompleksi bifazik, P dalgası pozitif, ST segmenti izoelektrik, T dalgası pozitifdir [8].

1.5.1. P Dalgası


P dalgası EKG kaydedilen ilk dalgadır. P dalgası, uyarının SA’dan çıkıp kulakçıklarda yayıldığını gösterir. QRS’dan önce pozitif veya negatif bir dalgadır. Normal P dalgasının genliği en fazla 3 mm ve süresi en fazla 0.12 saniyedir. P dalgası atriyal depolarizasyonu simgeler. Atriyal depolarizasyon yayılımı yavaş olduğu için P dalgaları çember şeklinde gözükmektedir [9].

1.5.2. PR Aralığı

PR aralığı P dalgasının başlangıcından QRS kompleksinin başına kadar olan kısımdır. PR aralığı atriyal depolarizasyon ile ventriküller aktivasyon arasındaki gecikmeden kaynaklı oluşur. Bu gecikmeyle birlikte karıncıkların (ventriküller) depolarize olmadan kanla dolabilmesi sağlanır. Normal PR aralığı 0.12 ile 0.20 saniye arasındadır [9].

1.5.3. QRS Kompleksi

QRS kompleksi Q dalgasının başlangıcından S dalgasının sonuna kadar olan kısımdır. EKG formları arasında genliği en fazla olanıdır. Ventriküler depolarizasyon sonucu oluşur. QRS kompleksleri derivasyonlara bağlı olarak birçok farklı şekillerde olabilir. QRS kompleksinde ilk dalga yani Q dalgası negatif; R dalgası ilk pozitif ve S dalgasıysa pozitif izleyen ilk negatif dalgadır. Bu şekilde olan QRS kompleksleri Q,R,S dalgalarını içerir. QRS kompleksinin genişliği en fazla 0.10 saniyedir [10]. Şekil 1.5.'de farklı QRS kompleksleri verilmiştir.



Şekil 1.5. Farklı QRS kompleksleri [10].

1.5.4. ST Segmenti

ST segmenti ventriküler repolarizasyonun başladığı andır. QRS kompleksinden T dalgasına kadar olan kısımdır. Normal ST segmenti pozitif veya negatif değil; bazal çizgide düz bir şekildedir. Ancak bazı durumlarda, kalp krizi gibi ST segment seviyesinde

sapmalar gözükür. ST segmentiyle alakalı tezin ilerleyen kısımlarında daha ayrıntılı bir şekilde açıklama yapılacaktır [2].

1.5.5. T Dalgası

T dalgası ventriküler repolarizasyonun bir bölümünü gösterir. T dalgası pozitif ise hızlıca yükselir ve yavaş bir şekilde bazal çizgiye döner; negatif ise yavaş bir şekilde iner ve hızlı bir şekilde bazal çizgiye döner. Bu hız farklılıkları T dalgasını simetrik olmayan bir yapıda olmasına neden olur [2].


1.5.6. QT Aralığı

QT aralığı Q dalgasının başından T dalgasının sonuna kadar olan aralıktır. QT aralığı ventriküllerin depolarize ve repolarize olması için geçen toplam süre kadardır. QT aralığının uzunluğu doğrudan kalp atım hızıyla alakalıdır. Kalp atım hızı artıka R-R aralığı ve QT aralığı kısalır. Kalp atım hızı azaldıkça R-R aralığı ve QT aralığı uzar. Bazı normal olmayan durumlarda QT aralığı uzayabilir. QT aralığının süresinin alt sınırı belli olmamakla birlikte üst sınırı maksimum 0.41 saniyedir [6].

1.5.7. U Dalgası

U dalgası T dalgasından sonra gelen küçük yuvarlak bölümdür. Her EKG'de gözükmeyebilir. Normalde U dalgasıyla T dalgasının yönü aynıdır. Kalp krizi gibi olağanüstü durumlarda pozitif T dalgalarıyla negatif U dalgaları görülebilir [6].

Şekil 1.6.'da EKG dalgalarının oluşmasında kalbin durumları adım adım gösterilmiştir. İlk kısımda kalbin yüzeyinde ölçülen gerilimlerin şekli verilmiştir. Alt kısımdaki şekildeyse vücut yüzeyine yansıyan gerilimler görülmektedir.



Şekil 1.6. EKG oluşurken kalbin durumları [11].


1.6. EKG Derivasyonları

Kalbin elektriksel aktivitesini ölçebilmek için vücudun değişik bölgelerine elektrotlar yerleştirilmektedir. Bu elektrotlar kollara, bacaklara veya göğüs duvarlarına yerleştirilebilir. Vücut iyi bir elektrik iletkenliğe sahip olduğu için kalpten uzak kısımlara yerleştirilen elektrotlar yardımıyla bile kalbin elektriksel aktivitesi değerlendirilebilir. Vücut yüzeyine yerleştirilen elektrotlar arasında oluşan voltaj farklılıklarından kaynaklı olarak EKG derivasyonları oluşmaktadır. Genelde kalbin elektriksel aktivitesini ölçmek için 12 derivasyonlu EKG kullanılır. Bu 12 derivasyon genel olarak altı kollar-bacaklar (ekstremiteler) derivasyonu ve altısı da göğüs derivasyonudur. 12 derivasyon vücudun değişik noktalarına yerleştirilen 10 adet metal elektrot sayesinde elde edilir [7]. İlerleyen bölümlerde bu 12 derivasyon ayrıntılı bir şekilde açıklanacaktır.

1.6.1. Ekstremiteler Derivasyonları

Ekstremiteler derivasyonları kollara ve bacaklara bağlanan metal elektrotlar aracılığıyla elde edilir. Ekstremiteler derivasyonları 2 ana alt gruptan oluşmaktadır. Bunlar standart

bipolar derivasyonlar ve artırılmış derivasyonlardır. Sağ bacağına bağlanan elektrotun EKG kaydında bir önemi olmamakla birlikte sadece topraklama amaçlıdır. Şekil 1.7.'de ekstremitelerde derivasyonlarındaki EKG kaydı için elektrotların bağlantı noktaları verilmiştir [2].



Şekil 1.7. Ekstremitelerde derivasyonlar için elektrot bağlantı noktaları [12].

1.6.1.1. Bipolar Derivasyonlar

Bipolar derivasyonlar sol kol ile, sağ kol; sol bacak ile sağ kol veya sol bacak ile sol kol arasında voltaj farklılıklarından kaynaklı oluşur. Bu şekilde iki ekstremitede arasındaki voltaj farklığını ölçtüğü için bu derivasyonlara bipolar (iki kutuplu) derivasyonlar denilmiştir. Bipolar derivasyonlar derivasyon I, derivasyon II, derivasyon III olmak üzere 3 alt kısmı ayrılmaktadır.

Derivasyon I sol kol ile sağ kol arasındaki; Derivasyon II sol bacak ile sağ kol arasındaki; Derivasyon III ise sol bacak ile sol kol arasındaki voltaj farkını ölçmektedir. Aşağıdaki şekilde ifade edilmektedirler [8].

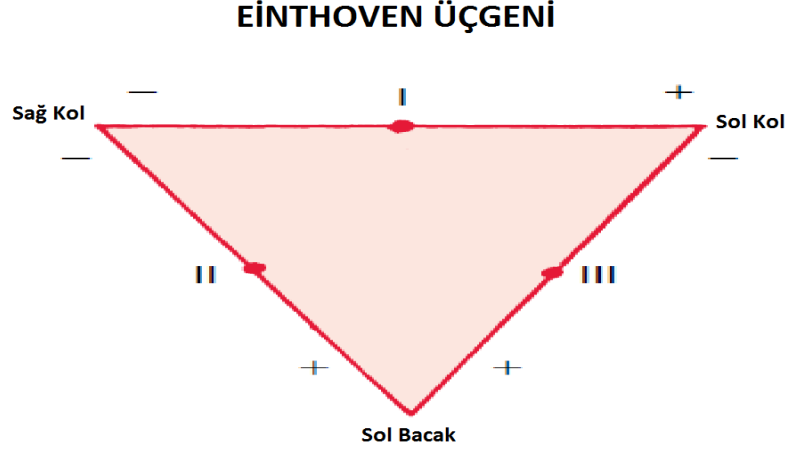
Derivasyon I=Sol kol –Sağ kol

Derivasyon II=Sol bacak –Sağ kol

Derivasyon III=Sol bacak –Sol kol

1900 yılında EKG'yi icat eden Einthoven'dan adını alan Einthoven üçgeniyle bu üç derivasyon şematik bir şekilde ifade edilebilir. Einthoven üçgenindeki temel mantık

kalbin köşeleri sol kol, sağ kol ve sol bacak olan eşkenar üçgenin merkezinde olmasıdır. Şekil 1.8.'de Einthoven üçgeni verilmiştir.




Şekil 1.8. Einthoven Üçgeni [8].

Şekil 1.8.'den anlaşılacağı üzere Derivasyon I yatay olarak çizilmiştir. Sol tarafı yani sol kol pozitif; sağ tarafı yani sağ kol negatiftir. Bundan dolayı Derivasyon I= Sol kol –Sağ kol şeklinde ifade edilmektedir. Derivasyon II ve Derivasyon III için de aynı şekilde eşitlikler yazılabilir. Derivasyon I ve Derivasyon II toplanarak aşağıdaki eşitlik bulunabilir.

$$\text{Derivasyon I} + \text{Derivasyon III} = \text{Derivasyon II}$$

Eşitlik düzenlenirse Derivasyon III'de kaydedilen potansiyel farkın derecesi Derivasyon I ve Derivasyon II arasındaki potansiyel farkı eşit olduğu görülmektedir. Bir başka deyişle Derivasyon II'deki R dalgasının tepe noktası aynı andaki Derivasyon I ve Derivasyon III'de ölçülen gerilimlerin toplamına eşittir [7]. Şekil 1.9.'da bipolar derivasyonlar için elektrot bağlantı noktaları verilmiştir. Elektrotlar kutuplu olarak seçilir.



Şekil 1.9. EKG bipolar derivasyonlar için elektrot bağlantı noktaları [12].


1.6.1.2. Artırılmış Derivasyonlar

Dr.Frank N.Wilson ve arkadaşları araştırmacı elektrot kavramını ilk defa tanımlayarak; Einthoven standart derivasyonları arasındaki ortalama potansiyelden oluşan üç tane daha derivasyon ortaya çıkarmışlardır. Bu derivasyonlar tek elektrot üzerinden ortaya çıktığı için bu derivasyonlara unipolar derivasyonlar denmiştir. Daha sonra Dr.Emanuel Goldberger 3 artırılmış unipolar derivasyon daha bulmuştur. Derivasyonlar aVR, aVL ve aVF şeklinde isimlendirmiştir. Bu kısaltmalardaki a İngilizce artırılmış kelimesinin; V voltaj kelimesinin; R İngilizce sağ kelimesinin; L İngilizce sol kelimesinin; F ise İngilizce ayak kelimesinin baş harflerdir [8].

Unipolar derivasyonlarda yukarıda anlatılan bipolar derivasyonlarda olduğu gibi iki noktanın voltaj farkını kıyaslamak yerine bir noktayı sifıra yakın bir voltajla karşılaştırılır.

Tıpkı Einthoven eşitliğindeki gibi; artırılmış derivasyonların da toplamı yani $aVR+aVL+aVF$ ifadesi 0 değerine eşittir. Örneğin 3 ayrı derivasyondaki P dalgaları, T

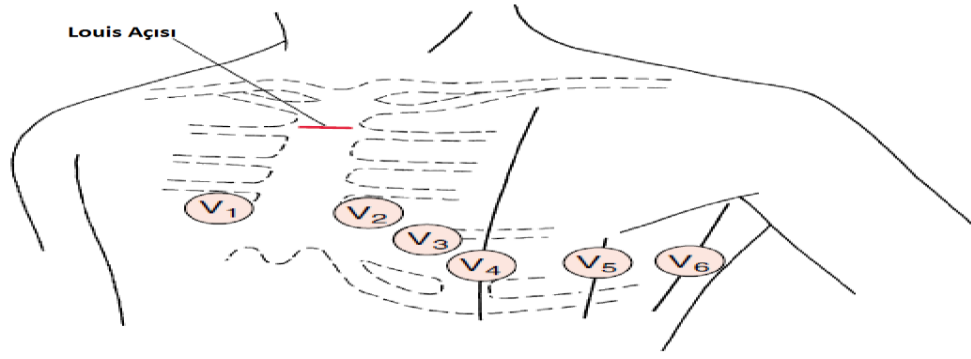
dalgaları veya QRS komplekslerinin voltajlarının toplamı 0'dır [7]. Şekil 1.10.'da artırılmış derivasyonlar için elektrot bağlantı noktaları verilmiştir.



Şekil 1.10. EKG artırılmış derivasyonlar için elektrot bağlantı noktaları [12].


1.6.2. Göğüs Derivasyonları

Göğüs üzerindeki çeşitli yerlere yerleştirilen elektrotlar yardımıyla göğüs derivasyonları elde edilir. V1, V2, V3, V4, V5 ve V6 olmak üzere altı tane göğüs derivasyonu bulunmaktadır. Bu derivasyonlar sıfıra yakın bir voltaj değeriyle kıyaslandığı için unipolar derivasyonlar olarak da düşünülebilir. Şekil 1.11 'de elektrotların göğüs üzerinde nereye yerleştirileceği görülmektedir [1].




Şekil 1.11. Göğüs derivasyonları için elektrot yerleşim noktaları [2].

Göğüs derivasyonları da ekstremité derivasyonlar gibi diyagramlar şeklinde gösterilebilir. Şekil 1.12.'de bu diyagram verilmiştir. Ekstremité derivasyonlar da olduğu gibi göğüs derivasyonların da bir negatif bir de pozitif ucu vardır. Pozitif kutuplar önde göğüse doğru; negatif kutuplar ise arkada sırtta doğru yerleştirilir [2].



Şekil 1.12.Göğüs derivasyonları diyagramı [2].

Şekil 1.13.'da göğüs derivasyonlar için elektrot bağlantı noktaları verilmiştir. Hangi derivasyonun ölçüleceğine bağlı olarak göğüs üzerindeki elektrotun yeri Şekil 1.11.'deki gibi düzenlenir. Örneğin V4 derivasyonu kaydı yapılacaksa göğüs üzerindeki yerine yerleştirilerek yapılır. Tez çalışmasında önerilen yöntemlerde göğüs derivasyonları kullanılmıştır.



Şekil 1.13. Göğüs derivasyonlar için elektrot bağlantı noktaları [12].

1.6.3. Kalbin Hangi Yüzüne Hangi Derivasyonlar Bakmaktadır?

Kalbin anterior yüzü (tepesi), posterior yüzü (arkası), inferior yüzü (tabanı) ve lateral yüzü (yanı) olmak üzere 4 adet yüzü bulunmaktadır. Belirli derivasyonlar kalbin belirli yüzüne bakmaktadır. Kalbin hangi yüzüne hangi derivasyonların baktığı aşağıdaki Tablo 1.1. ve Tablo 1.2.'de verilmiştir [13].

Tablo 1.1. Ekstremité derivasyonları ve kalbin yüzleri

Derivasyon	Kalbin Yüzü
1	Yan
2	Taban
3	Taban
aVR	Sağ atriyal bölge
aVL	Yüksek Yan
aVF	Taban


Tablo 1.2. Göğüs derivasyonları ve kalbin yüzleri

Derivasyon	Kalbin Yüzü
V1	Tepe(Anterior)
V2	Tepe
V3	Tepe
V4	Tepe
V5	Yan(Lateral)
V6	Yan

1.6.4. Neden 12 Derivasyona İhtiyaç Duyulur?

Kalp 3 boyutlu bir organdır ve ürettiği elektrik akımlar vücudun her bölümüne yayılır. Vücudun ne kadar farklı bölgesine elektrot yerleştirilirse o kadar iyi bir şekilde kalbin elektriksel aktivitesi kaydedilebilir. Farklı derivasyonlarla birlikte farklı hastalıkların teşhis ve tedavisi daha rahat bir şekilde yapılabilmektedir. Örneğin P dalgaları en etkin şekilde V1 derivasyonunda görülebilirken; ekstremitte derivasyonlarıyla birlikte kalp krizinin teşhisi sağlanır. Tüm bu 12 derivasyonla birlikte kalbin atriyal ve ventriküler depolarizasyonun ve repolarizasyonun tüm aşamaları izlenebilmektedir [8].

12 EKG derivasyonun hem yönelim hem de kutuplaşmaya sahip ve eksenlerinin ucunda pozitif ve negatif kutuplarla gösterilen polaritede olmaları en önemli 2 özelliğidir [14]. Şekil 1.14.'de 12 farklı derivasyondaki EKG verilmiştir.



Şekil 1.14. 12 farklı derivasyondaki EKG [14].

1.6.5. Hastalıklar ve Teşhisi

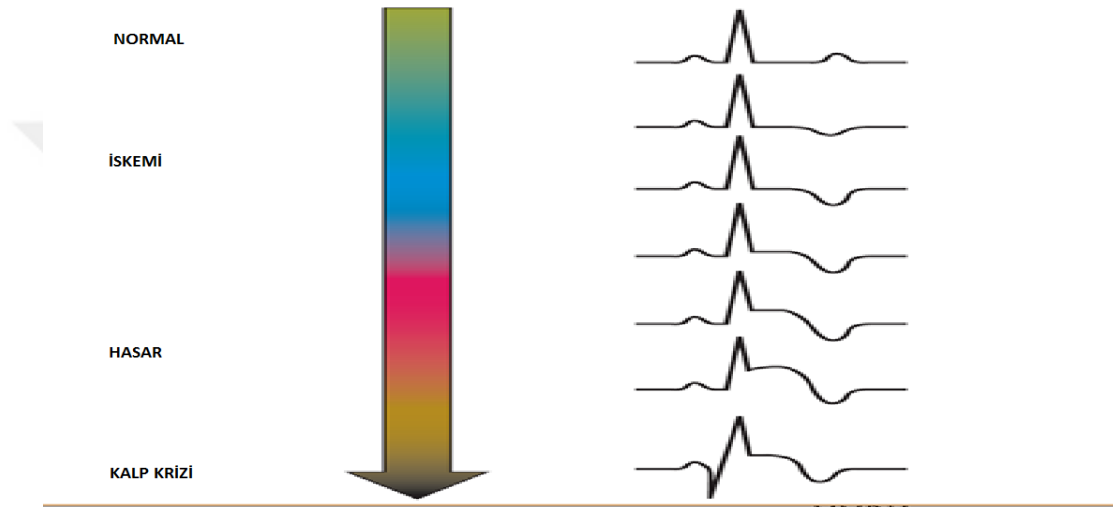
Bu bölümde tezin konusu olan ST segmentinin alçalması veya yükselmesi sonucu oluşan hastalıklardan ve teşhisi hakkında bilgilere yer verilmiştir.

1.6.5.1. Miyokardiyal İskemi ve Miyokard İnfarktüs

Kalp kası (miyokard) hücreleri oksijen ve besinle birlikte görevlerini yerine getirebilirler. Kalp kası hücreleri için gerekli olan oksijen ve besin kalbi besleyen damarlar yani koroner damarlar aracılığıyla sağlanır. Koroner damarların çeşitli sebeplerden dolayı daralması veya tamamen tıkanması sonucu kalp kası hücrelerine kan ve kanla birlikte gelen oksijen ulaşamaz. Bu durum sonucunda kalp kasının kansız kalması gerçekleşir. Bu olay tıpta miyokardiyal iskemi olarak adlandırılır. Miyokardiyal iskemi uzun sürerse kalp kasının bir kısmının işlevsiz kalması gerçekleşir ve bunun sonucunda kalp krizi oluşur. Kalp krizi miyokard infarktüs olarak adlandırılmaktadır [2].

Miyokard infarktüs genel olarak 3 safhada gerçekleşmektedir. Bunlar başlangıçta kalp kasının oksijensiz kaldığı iskemi aşaması, oksijensiz kalma sonucunda kalp kasında hasar olduğu aşama ve son olarak kalp krizinin olduğu aşamadır. İskemi aşaması, hasar

aşaması ve kalp krizi aşaması doğrudan EKG'deki ST segmentini etkilemektedir. İskemi aşamasında EKG ST segmentinde düşüş ve T dalgalarının şeklinde tersine dönme gözlemlenebilir. Kalp kasında hasar olduğu 2.aşamada ise ST segmentinde yükselmeler veya düşüşleri oluşmaktadır. Kalp krizi aşamasındaysa Q dalgalarında bozukluklar gerçekleşebilir. Şekil 1.15.'de miyokard infarktüsün gelişme aşamalarında EKG'nin nasıl değişeceği verilmiştir. ST segmenti yükselmeleri ve düşüşleri EKG'deki izoelektrik çizgiden düşme veya yükselme şeklindedir [13].



Şekil 1.15. Miyokard infarktüs sırasında EKG'nin değişimi [13].

Miyokard infarktüs daha çok kalbin sol ventrikülerinden kaynaklı sorunlardan ortaya çıkar. Bununla birlikte sağ ventrikülerden de kaynaklı oluşabilmektedir. Sol ventriküler dış tabaka (epikard) ve iç tabakadan (subendokard) oluşmaktadır. Miyokardiyal iskemi sonucunda sol ventriküllerinin iç tabakası ve ventrikül duvarlarının tamamı etkilenebilir. Ventriküler duvarlarının tamamının etkilenmesi sonucunda oluşan iskemi transmural iskemi olarak adlandırılmaktadır ve bu durum da EKG'de ST segmenti yükselmesiyle birlikte teşhis edilebilmektedir. Bazı durumlarda ise miyokard iskemisi sadece ventriküllerin iç tabakasıyla ilgilidir. Bu durumda subendokard iskemi olarak adlandırılmaktadır. Sıklıkla EKG ST segmenti düşüşüyle teşhis edilebilmektedir. Bir sonraki bölümde ST segment yükselmesi ve düşüşüyle alakalı daha geniş bilgilere yer verilecektir [13].


1.6.5.1.1. ST Segmenti Yükselmesi (Elevasyonu)

Transmural iskemiler genelde kalp kasının depolarizasyonunda oluşan QRS komplekslerinde hem de kalp kası repolarizasyonu sonucu oluşan ST-T komplekslerinde değişiklikler oluşturur. Bu aşamada tezin konusu ST segment değişimleri olduğu için QRS komplekslerini etkileyen transmural iskemilere anlatım içerisinde yer verilmemiştir. ST segmenti yükselmeli miyokard infarktüs kısaca STEMI olarak adlandırılmaktadır. Transmural iskemide ilk olarak EKG’de bazı derivasyonlarda belirgin bir şekilde ST segmenti yükselmesi gözükmektedir. Bu durumun gelişim fazı, günler içinde ortaya çıkar ST segmenti yükselmesi gözükken derivasyonlarda derin T negatiflikleri de oluşur. Transmural iskemilerin ilerlemesi sonucunda transmural miyokard infarktüsler oluşur [13].


Transmural miyokard infarktüsler genelde kalbin sol ventrikülünün anterior (ön) kısmına ya da inferior (alt) kısmına yerleşirler. Anterior infarktüs sol ventriküllerin anterior veya lateral (yanal) duvarını içerir.

Transmural miyokard infarktüsler kalbdeki anatomik yerleşim yerlerine göre farklı EKG derivasyonlarında gözükürler. Örneğin anterior miyokard infarktüsünde ST segment yükselmeleri anterior (ön) göğüs derivasyonlarında yani V1,V2,V3,V4,V5,V6 derivasyonlarında ve 1.derivasyon ile birlikte aVL derivasyonlarında daha iyi bir şekilde gözlemlenir. Inferior miyokard infarktüsünde ise ST segment yükselmeleri inferior (alt) derivasyonlar olan 2. 3. ve aVF’de gözükür [2].

STEMI’lerde gözükken ST-T değişimlerinin en önemli özelliklerinden biri de resiprokal olmalarıdır. Anterior ve inferior derivasyonlarda ters değişimler gösterirler. Örneğin anterior miyokard infarktüsünde V1’de ST segmenti yükselmesi gözükürken; tersine inferior derivasyon olan 3. derivasyonda ST segmenti düşmesi gözükür. Şekil 1.16. ve Şekil 1.17.’da örnek ST segmenti yükselmeleri verilmiştir [16].




Şekil 1.16. Göğüs derivasyonlarda gözükten ST segmenti yükselmeleri [16].



Şekil 1.17. Ekstremitte ve göğüs derivasyonlarda gözükten ST segmenti yükselmeleri [16].


1.6.5.1.2. ST Segmenti Düşmesi (Depresyonu)

Subenkord iske miyle alakalı EKG'de gözükten en sık de ğişim ST segmenti düşmesidir. Subenkord iske miye ba ğlı gö ğüs a ğrıları boyunca EKG'de ST segmenti düşmesi gözükür. Gö ğüs a ğrıları geçince ST segmenti normal haline geri dö ner. Subenkord iske mi yeterince ciddiye subenkord infarktüsü neden olanılır. Subenkord infarktüs NSTEMI olarak da adlandırılmaktadır. NSTEMI (Non ST-Elevation Myocardial Infarction) ST segmenti yükselmesi olmayan miyokardiyal infarktüs anlamına gelmektedir [11]. Şekil 1.18.'de tipik ST segmenti düşmesi ve kalbin hangi bölgesini etkiledi ği verilmiştir.



Şekil 1.18. ST segmenti düşmesi [11].

Subendokard iske miyle alakalı ST segment düşmeleri EKG'nin I, aVL, V1, V2, V3, V4, V4, V6 derivasyonları veya II, III ve aVF derivasyonlarında ya da her ikisinde gözükabilir [15]. Şekil 1.19.'de farklı göğüs derivasyonlarında gözükten ST segmenti düşmesi örnekleri verilmiştir [6].



Şekil 1.19. Farklı göğüs derivasyonlarında gözükten ST segmenti düşmesi [16].

1.6.5.2. Sessiz Miyokard İnfarktüsü

Bazı durumlarda kalp krizi hastada hiçbir belirti vermeden gerçekleşebilir. Ancak hastanın EKG kaydı incelendiğinde kalp krizi geçirdiği anlaşılabilir. Bu durumda gerçekleşen kalp krizi sessiz miyokard infarktüsü olarak adlandırılmaktadır. Hastanın kalp

krizi geçirmeden önce alınan uzun süreli EKG kayıtlarındaki ST segment düşmeleri ve yükselmeleriyle kalp krizi geçirebileceğine dair teşhis koyulabilmektedir [6].

1.7. Literatür Özeti

Birçok araştırmacı ST segment değişimlerini ve miyokard infarktüsü tespit edebilmek için farklı çalışmalar yapmışlardır. Bu bölümde yapılan çalışmalarla alakalı bilgilere yer verilecektir.

C. Papaloukas ve diğerleri çalışmalarında gürültü azaltımı, öznitelik çıkarımı, kural tabanlı sınıflandırma ve kayan pencere sınıflandırma aşamalarını gerçekleştirerek iskemik bölüm tespiti sağlamışlardır. Çalışma European ST-T veritabanında test edilerek duyarlılık ve pozitif prediktif değer sırasıyla %93.8 ve %78.5 olarak verilmiştir [17].

Bin Liu ve diğerleri çalışmalarında EKG sinyaline 20.dereceden polinom uydurarak PolyECG-S olarak tanımladıkları yeni bir yöntem geliştirmişlerdir. Çalışmada veritabanı olarak Physikalisch-Technische Bundesanstalt (PTB) seçilmiştir. Bu veritabandaki EKG sinyalleri standart 12 derivasyon olup 1000 hz örnekleme frekansına sahiptir. Veritabanından 148 ST segmenti değişimli ve 52 sağlıklı veri seçilmiştir. Rastgele Ağaçlar, Karar Ağaçları algoritmalarından biri olan J48 ve Naif Bayes sınıflandırma algoritmalarını kullanarak miyokard infarktüsü tespit etme doğruluğu en yüksek %94.4 bulunmuştur [18].

Themis P. Exarchos ve diğerleri çalışmasında European ST-T veritabanında seçilen e0104 numaralı verinin 2 saati yani tamamı ile birlikte e0103, e0105, e0108, e0113, e0114, e0147, e0159, e0162 ve e0206 numaraları verilerinin 1 saatini seçmişlerdir. Bu seçim sonucunda 86384 kalp atımı normal veya iskemi olarak etiketlenmiştir. Önerilen yöntem öznitelik çıkarımı, öznitelik ayrıştırma, kural üretimi ve sınıflandırma olmak üzere 3 ana adımda gerçekleştirilmiştir. Öznitelik çıkarma aşamasında ilk olarak EKG sinyalinin QRS kompleksi belirlenmiştir. Daha sonra bu kompleks üzerinde ST segmenti alanı, ST segmenti sapması, ST segment eğimi, T dalgası genliği olmak üzere 4 tane morfolojik öznitelik oluşturulmuştur. Bir ağaç sınıflandırma algoritması olan CT-disc ile birlikte öznitelik ayrıştırılması yapılmıştır. Kural tabanlı sınıflandırma algoritmalar kullanılarak iskemik atım tespit etme duyarlılığı %87 ve özgüllüğü %93 olarak bulunmuştur [19].

L. N. Sharma ve diğerleri çalışmalarında dalgacık dönüşümü tabanlı öznitelik çıkarımı gerçekleştirmişlerdir. EKG sinyaline; Pan Tompkins algoritması yardımıyla R

tepe noktalarını belirlendikten sonra dalgacık dönüşümü uygulanmıştır. Dalgacık dönüşümü sonucunda elde edilen değerlerden çok ölçekli enerji değerleri ve çok ölçekli kovaryans matrislerinin özdeğerleri öznitelik olarak kullanılmıştır. Çalışmada PTB veritabanı kullanılmıştır. Destek Vektör Makineleri (DVM) ve K-En Yakın Komşuluk (K-EYK) sınıflandırıcıları kullanılarak miyokard infarktüs tespit etme doğruluğu, duyarlılığı ve özgüllüğü sırasıyla %96, %93 ve %99 olarak verilmiştir [20].

Xiaoying Tang ve diğerleri çalışmalarında Long-Term ST veritabanından seçilen QRS kompleksleri üzerinde Saklı Markov Modelini kullanarak; öznitelik çıkarımı gerçekleştirmişlerdir. Miyokard iskemi tespit etme duyarlılığı ve pozitif prediktif değeri sırasıyla %89 ve %85 olarak verilmiştir [21]. Benzer şekilde A.Smrdel ve arkadaşları da öznitelik çıkarma aşamasında Saklı Markov Modeli kullanarak QRS kompleksleri üzerinden öznitelik çıkarımı yapmışlardır. Çalışmada Long Term ST veritabanındaki protokol B'ye ait 24 saatlik 86 tane EKG kaydı kullanıldığında; iskemi tespit etme duyarlılığı %78.9 pozitif prediktif değeri %80.7 olarak bulunmuştur. Çalışmada European ST-T database kullanıldığında duyarlılık ve pozitif prediktif değerler sırasıyla %81.3 ve %89.2 olarak bulunmuştur [22].

Yorgos Goletsis ve diğerleri QRS kompleksleri üzerinden birden fazla kriter kullanarak miyokard iskeminin tespit edilmesini sağlamışlardır. Bu kriterler ST segment sapmaları, ST segment eğimi, T dalgası genliği ve hastanın yaşıdır. Çalışmada European ST-T veritabanından alınan 20 iskemik ST segment bölümü ve 20 iskemik T dalgası bölümü kullanılmıştır. Bu bölümler toplamda 86.384 atım içermektedir. Daha sonra genetik algoritmaları kullanarak miyokard iskemi tespit etme duyarlılığı ve özgüllüğü %91 olarak bulunmuştur [23].

Al-Fahaum ve diğerleri rastgele 14 tane hastalıklı EKG sinyalini European ST-T veritabanından ve 24 tane rastgele normal EKG sinyalini MIT-BIH Aritmi veritabanından seçmişlerdir. EKG sinyallerine ikiz-spektrum analizi, kuadratik faz eşleme gibi yüksek frekans analiz teknikleri uygulanarak ortalama duyarlılık ve pozitif prediktif değeri sırasıyla % 100 ve %93.33 bulmuşlardır [24].

P. Ranjith ve diğerleri çalışmalarına; European ST-T veritabanından aldıkları EKG sinyallerine dalgacık dönüşümü uygulayarak başlamışlardır. Daha sonra dalgacık dönüşümü sonucunda elde edilen katsayılar kullanılarak; R tepesi, QRS kompleksinin başlama ve bitiş noktaları, T ve P dalgası gibi EKG sinyalinin karakteristik noktaları

bulunmuştur. Miyokard iskemi tespit etme duyarlılığı ve pozitif prediktif değer sırasıyla %87.5 ve %93.3 olarak bulunmuştur [25].

Amit Kumar ve diğerleri çalışmalarında; öncelikle dalgacık dönüşümünden yararlanarak R-R aralığı ve ST segmenti bulunmuştur. Bir sonraki aşamada izoelektrik referans bulunarak izoelektrik enerji hesaplanmıştır. En son aşamadaysa eşik değerleri belirlenerek miyokard iskemi tespit edilmiştir. European ST-T veritabanından seçilen e0103, e0104, e0105, e0108, e0113, e0114, e0147, e0159, e0162, e0206 numaralı verilerden toplamda 43.876 ST segmenti alınmıştır. Miyokard iskemi tespit etme ortalama duyarlılık %98.12 özgüllükse %98.16 olarak belirlenmiştir [26].

R Correa ve diğerleri çalışmasında; 2 farklı veritabanı kullanmışlardır. PTB veritabanından 52 tane sağlıklı EKG verisi seçilmiştir. Charleston Area Medical Center tarafından oluşturulan veritabanından 51 tane iskemi hastasına ait EKG verileri alınmıştır. Çalışmada ön işleme olarak Butterworth filtresi kullanılmıştır. Öznitelik çıkarmada vektörkardiyografik parametrelerden yararlanılmıştır. Doğrusal Diskriminant Analizi (LDA) ile sınıflandırma yapılarak miyokard iskemi tespit etme duyarlılık ve özgüllük değerleri sırasıyla %99.5 ve %99.4 olarak bulmuşlardır [27]. 2014 yılında yaptıkları diğer çalışmalarında ise aynı parametreleri kullanılmıştır. Bu çalışmalarında ise Charleston Area Medical Center'de 80 miyokard iskemi geçmişi olan hastanın EKG verilerinden oluşturulan bir veritabanı kullanılmıştır. Sınıflandırma aşamasında Doğrusal Diskriminant Analizi yöntemini kullanmışlardır. Miyokard iskemi tespit etme duyarlılığı %90.5 and özgüllük değeri ise %92.6'dır [28].

L Dranca ve arkadaşları ise ST genliği, ST segment eğimi, QRS kompleksi süresi, kalp hızı gibi birçok öznitelik çıkarımı yapmışlardır. Bu öznitelikleri kullanılara; Bagged Trees, Rastgele Orman, Naif Bayes ve çok katmanlı Yapay Sinir Ağları gibi birçok sınıflandırma yönteminde performans sonuçları değerlendirilmiştir. En iyi sonuçlar Bagged Trees yönteminde elde edilmiştir. Çalışmada Long Term ST veritabanı ve European ST-T veritabanı kullanılmıştır. Long Term veritabanında iskemi tespit etme duyarlılığı ve pozitif prediktif değerler sırasıyla %93.97 ve %74.91 ve European ST-T veritabanı için ise duyarlılık ve pozitif prediktif değerleri sırasıyla %83.33 ve %77.31 olarak bulunmuştur [29].

Mingfang Xu ve diğerleri morfolojik sınıflandırmayla ST segmentini tespit etmişlerdir. Çalışmalarında sırasıyla 1) 0.05–45 Hz bant geçiren filtreleme 2) R tepe noktalarının bulunması 3) Normal olmayan RR aralıklarıyla birlikte EKG atımlarının

çıkarılması 4) ST segmentinin başlangıç ve bitiş noktalarının bulunması 5) Kayan taban çizgisinin bulunması 6) Her ST segmenti için kural tabanlı morfolojik sınıflandırma adımları gerçekleştirilmiştir. Toplamda 17.314 kalp atımı European ST-T veritabanından alınmıştır. Eğitim ve test miyokard iskemi tespit etme doğrulukları %91.8 ve %90.1 olarak verilmiştir [30].

Costas Papaloukas ve diğerleri çalışmalarında başlangıçta EKG'deki izolektrik çizgi, QRS kompleksi, ST segmenti ve T dalgası çıkarılmıştır. Daha sonra kalp atımları negatif ST eğimi, pozitif ST eğimi ve T dalgası tersliği, T dalgası dalgalanması ve negatif T dalgası genliği içerip içermediği şeklinde sınıflandırılmıştır. EKG verilerini European ST-T veritabanından seçmişlerdir. Bu veritabanı 90 EKG kaydı ve bu kayıtlardan elde edilen 589 ST bölümü 393 T bölümü içermektedir. ST segmenti bulma duyarlılığı ve pozitif prediktif değerleri sırasıyla %92.0 ve %93.77 verilmiştir [31].

E. S. Jayachandran ve diğerleri çalışmalarında kalp atımlarını belirledikten sonra bu atımlara dalgacık dönüşümü uygulamışlardır. EKG verileri Hindistandaki National Institute of Technology Calicut merkezinden alınmıştır. Bu EKG kayıtları toplamda 2282 normal ve 718 tane miyokard iskemi içeren atımlardır. Önerilen yöntemde miyokard iskemi tespit etme doğruluğu %95 olarak bulunmuştur [32].

Jinho Park ve diğerleri çalışmalarında ilk olarak dalgacık dönüşümünü kullanarak taban çizgisi sapmasını kaldırmışlardır. Daha sonra QRS komplekslerini dalgacık dönüşümü yardımıyla bulmuşlardır. Her kalp atımı için 3 ayrı öznitelik tanımlamışlardır. Bunlar QRS kompleksi ve T tepe noktası arasındaki alan, QRS kompleksinden sıfır voltaj noktasına kadar olan değerlerinin normalizasyonu ve QRS kompleksi başlangıç noktasından bitiş noktasına olan eğimdir. Önerilen yönteminin performans değerlendirmesi çekirdek yoğunluk kestirimi ve DVM ile yapılmıştır. Çalışmada European ST-T veritabanından alınan 90 EKG kaydı kullanılmıştır. Bu kayıtlarsa toplamda 367 iskemik ST bölümü içermektedir. Çekirdek yoğunluk kestirimi kullanılarak iskemik ST bölümü bulma duyarlılığı ve özgüllüğü sırasıyla %93.39 ve %91.12 olarak; DVM kullanıldığında bu değerler sırasıyla %94.1 ve %92.3'dür [33].

Miha Amon ve diğerleri çalışmalarında iskemik ST segmentini bulmayı hedeflemişlerdir. Önerilen yöntemde ortogonal dönüşümlerden yararlanılmıştır. Karhunen-Loève dönüşümü ve Legendre Polinomu tabanlı dönüşümlerden yararlanarak öznitelik çıkarımı gerçekleştirmişlerdir. Çalışmanın performans değerlendirmesi Long-Term ST veritabanından seçilen 1130 iskemik ST segmenti ve 234 iskemik olmayan ST

segmenti kullanarak yapılmıştır. Sınıflandırma aşamasında, Karar ağacı, Karesel Diskriminant Analizi ve DVM algoritmaları kullanılmıştır. En iyi sınıflandırma sonuçları K-EYK algoritmasında $k=3$ seçilerek bulunmuştur. Karhunen-Loève dönüştürme sonucunda elde edilen öznitelikler kullanılarak sınıflandırma doğruluğu, duyarlılığı ve özgüllüğü sırasıyla %90, %91 ve %85 olarak bulunmuştur. Legendre Polinomu tabanlı dönüşüm kullanıldığında bu değerler %82, %85 ve %75'dir [34].

U. Rajendra Acharya ve diğerleri çalışmalarında miyokard infarktüs tespit etmeyi hedeflemişlerdir. İlk olarak kalp atımlarına Ayırık Dalgacık Dönüşümü uygulamışlardır. Daha sonra bu dönüşümün katsayılarını kullanarak 12 farklı öznitelik belirlemişlerdir. Bu öznitelikler; yaklaşık entropi, sinyal enerjisi, bulanık entropi, Kolmogrov-Sinai, permutasyon, Renyi, Shannon, Tsallis ve Dalgacık entropisi, oransal kırılma boyutu, Kolmogrov karmaşıklığı ve en büyük Lyapunov üstüdür. PTB veritabanından elde edilen 485.753 iskemik kalp atımı 125.652 normal kalp atımı seçilmiştir. Miyokard infarktüs tespit etme doğruluğu, duyarlılığı ve özgüllüğü sırasıyla %98.8, %99.45 ve %96.27 olarak bulunmuşlardır [35].

Muhammad Arif ve diğerleri çalışmasında T dalgası genişliği, Q dalgası genişliği ve ST segmenti seviye sapması özniteliklerini kullanarak miyokard infarktüs sınıflandırması yapmışlardır. PTB veritabanından elde edilen 20.160 kalp atımı kullanılmıştır. Miyokard infarktüs Anterior, Anterior-Lateral, Anterior-Septal, Inferior, Inferior-Lateral, Inferior-Posterior, Inferior-Posterior-Lateral, Lateral, Posterior, Posterior-Lateral olmak üzere 10 tane alt sınıfa ayrılmıştır. Duyarlılık, özgüllük ve doğruluk değerleri sırasıyla %90, %90 ve %98.3 olarak bulunmuştur [36].

Tez çalışmasında EKG R-R aralığındaki ST segmenti yükselmelerini veya düşmelerini önceden tespit etmek amacıyla zaman frekans dönüşümlerine dayalı yöntemler geliştirilmiştir. Önerilen yöntemlerde literatürdeki çalışmalardan farklı olarak MIT-BIH Aritmi, European ST-T ve Long Term ST veritabanları kullanılarak büyük bir veritabanı oluşturulmuştur. Ayrıca literatürdeki çalışmalardan farklı olarak performans değerlendirmesinde birden fazla sınıflandırma tekniği kullanılmıştır ve önerilen yöntemlerinin performans değerlendirme sonuçları birçok çalışmanın üstündedir.

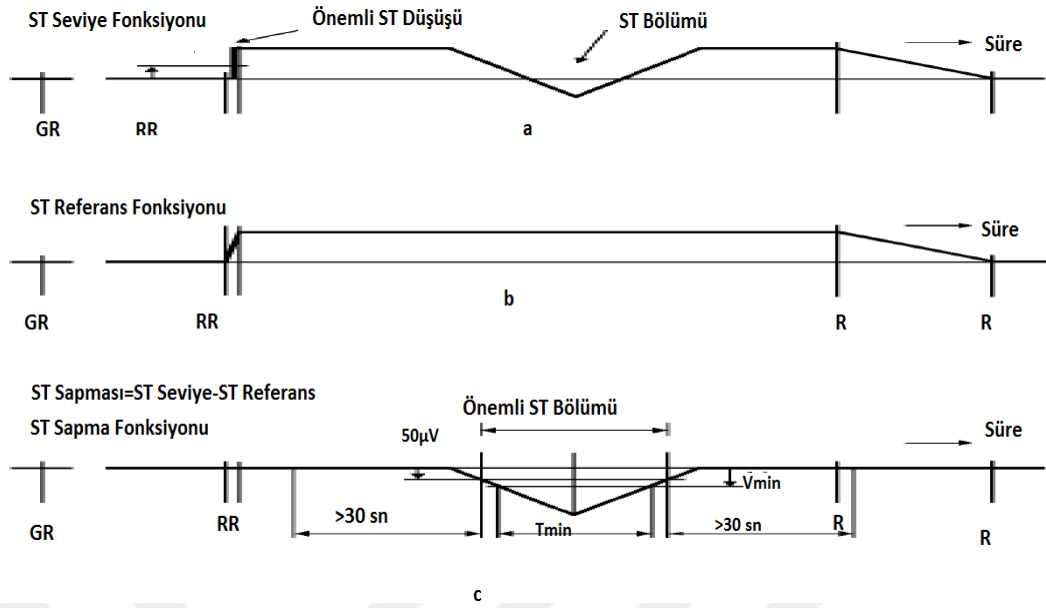
1.8. Veritabanlarının Tanıtımı

Yapılan çalışmalarda MIT-BIH Aritmi veritabanı, European ST-Tveritabanı ve Longterm ST veritabanından alınan EKG kayıtları kullanılmıştır. Bu veritabanlarına '<http://www.physionet.org/>' [40] internet adresinden ulaşılabilir.

MIT-BIH Aritmi veritabanından V1, V2, V4 ve V5 derivasyonlarına sahip her biri 30'ar dakikalık olan 46 EKG kaydı seçilmiştir. EKG sinyalleri 360 Hz örnekleme frekansına sahiptir. Bu veritabanında farklı aritmi çeşitleri ve sağlıklı EKG sinyalleri içeren kayıtlar bulunmaktadır.

European ST-T veritabanından V1, V2, V3, V4 ve V5 derivasyonlarına sahip her biri ikişer saatlik olan 70 tane EKG kaydı seçilmiştir. Kayıtlar yaşları 30 ve 84 arasında değişen 70 erkek ve 55 ve 71 arasında değişen 7 bayandan alınmıştır. Bu EKG sinyalleri 250 Hz örnekleme frekansına sahiptir. Bu veritabanında ST segment düşmesi veya yükselmesi içeren EKG kayıtları bulunmaktadır.

Diğer veritabanı olarak seçilen Long Term ST veritabanında EKG kayıtları 21- 24 saat arası kayıtlar olup 250 Hz örnekleme frekansına sahiptir. Bu kayıtlar yaş ve cinsiyetleri farklılık gösteren 17 kişiden alınmıştır. Bu veritabanından V2, V3, V4, V5 ve V6 derivasyonlarına sahip 21 tane EKG kaydı seçilmiştir. Bu veritabanında iskemik ST segmentleri, iskemik olmayan ST segmentleri ve hastanın hareketinden kaynaklı ST segmenti değişimleri uzman doktorlar tarafından etiketlenmiş bir şekilde bulunmaktadır. Yapılan tez çalışmalarında Long-Term ST veritabanından iskemik ST segmentleri seçilmiştir. Veritabanında ST segment düşmelerini veya yükselmelerini ifade edebilmek için sta, stb ve stc olmak üzere 3 farklı protokol bulunmaktadır. Bu protokollerin şematik gösterimi Şekil 1.20.'de verilmiştir. Burada R:local referans ve GR:Global referansı ST sapması ST seviyesinden ST referansı çıkartılarak bulunmaktadır..



Şekil 1.20. Protokollerin şematik gösterimi [41].

Protokol sta'da $V_{min} = 75 \mu V$ ve $T_{min} = 30$ sn; protokol stb'de $V_{min} = 100 \mu V$ ve $T_{min} = 30$ sn; protokol stc'deyse $V_{min} = 100 \mu V$ ve $T_{min} = 60$ sn olarak seçilerek uzman doktorlar tarafından gerekli etiketlenmeler yapılmıştır. Yapılan tez çalışmalarında protokol sta seçilmiştir [41].

Bu veritabanlarında EKG sinyallerinin aritmi, ST segment düşmesi veya yükselmesi içeren kısımları uzman doktorlar tarafından etiketlenmiş bir şekilde .atr dosyaları içerisinde bir başka deyişle açıklama dosyaları içerisinde bulunmaktadır. Bu dosyaları önerilen algoritmalarda kullanılabilir şekilde yeniden düzenlemesi yapılmıştır. Bu amaçla Matlab ortamından erişim olanağı sağlayan WaveForm DataBase (WFDB) toolboxdan yararlanılmıştır. WFDB toolbox kullanılarak '<http://www.physionet.org/>' sitesinde var olan 50'den fazla biyolojik sinyaller içeren veritabanına ve uzman doktorlar tarafından etiketlenmiş biyolojik sinyallere rahatlıkla erişilebilmektedir [40]. Bu WFDB toolboxda amaca yönelik kullanılabilir birçok fonksiyon bulunmaktadır. Yapılan çalışmada MIT-BIH Aritmi veritabanındaki R-R aralıklarındaki aritmi ve European ST-T ve Long Term ST veritabanındaki ST segment düşmesi veya yükselmesi etiketlenmesinin yapılabilmesi için aşağıda listelen WFDB Toolbox'ın fonksiyonları kullanılmıştır [42].

ann2rr: Açıklama dosyalarındaki R-R aralıklarını ve uzunluklarını ulaşmayı sağlar.

rdann: Açıklama dosyalarını okumayı sağlar.

sumann: Açıklama dosyalarının özetini gösterir.

1.9. Öznitelik Çıkarımı Yöntemleri

Önerilen yöntemlerde öznitelik çıkarma aşamasında geleneksel zaman frekans dağılımlarından farklı olan Yumuşatılmış Wigner-Ville (YWVD), Choi-Williams (CWD), Bessel (BJ), Born-Jordan (BJD) ve Zhao-Atlas-Marks (ZAMD) zaman frekans dağılımlardan yararlanılmıştır. İlerleyen bölümlerde bu zaman frekans dağılımlarının teorik açıklaması yapılacaktır.

1.9.1. Zaman-Frekans Dağılımları

Zaman frekans dağılımlarıyla farklı frekans değerleri barındıran işaretlerin frekans analizleri rahatlıkla yapılabilmektedir. Zaman-Frekans dağılımları değişik yazarlar tarafından değişik biçimlerde sınıflandırılmış olmasına rağmen en yaygın olarak 2 alt sınıfa ayrılmaktadır. Bunlar;

- 1) Doğrusal Zaman Frekans Dağılımları
- 2) Karesel Zaman Frekans Dağılımlarıdır.

Doğrusal zaman frekans dağılımlarında sinyallerin doğrusal gösterimi her bir sinyalin ayrı ayrı doğrusal gösterimine eşit olup sinyalin doğrusal özelliğini gösterir. Doğrusal zaman frekans dağılımlarıyla işaretteki frekans değerleri elde edilir. Fourier Dönüşümü ve Dalgacık dönüşümü doğrusal zaman frekans dağılımlarındandır. Bu dağılımlarla işaretin hangi frekans değerlerinden oluştuğu rahatlıkla tespit edilebilir.

Karesel zaman frekans dağılımları kullanılarak doğrusal zaman frekans dağılımlarından farklı olarak hangi frekansın hangi zaman aralığında mevcut olduğu bilgisine ulaşılabilir. İşlenen problemin karakteristiğine göre zamanla birçok karesel zaman frekans dağılımları geliştirilmiştir. Bu dağılımların bazıları WVD, CWD, BD, BJD, ZAMD'dır. Tüm bu dağılımların birbirlerine göre birçok avantajı ve dezavantajı bulunmaktadır [43]. Bu çalışmada karesel zaman frekans dağılımına ilişkin yöntemler kullanılmıştır.

Bu karesel zaman frekans dağılımları zamanda ve frekansta öteleme ile değiştiği için Cohen sınıfına dâhildir. Cohen sonsuz sayıda zaman-frekans dağılımı oluşturabilmek için (1.1)'deki gibi genel bir formül türetmiştir. Burada $\psi(\theta, \tau)$ dağılımdaki çekirdeği ifade eder. Çekirdek fonksiyonu değiştirilerek farklı zaman frekans dağılımları elde edilebilir. Zaman frekans dağılımları iki boyutlu çekirdekler ile karakterize edilirler ve bu çekirdekler

zaman ve frekansta iyi çözünürlük verecek aynı zamanda istenmeyen bileşenlerin oluşmasını engelleyecek şekilde düzenlenir. Farklı çekirdekler tanımlarak farklı zaman frekans dağılımları oluşturulmuştur [43].

$$C(t, w; \psi) = \left(\frac{1}{2\pi}\right)^2 \iiint e^{-j\theta t - j\theta\omega + j\theta u} \psi(\theta, \tau) s\left(t + \frac{\tau}{2}\right) s^*\left(t - \frac{\tau}{2}\right) du d\tau d\theta \quad (1.1)$$

1.9.1.1. Wigner-Ville Zaman Frekans Dağılımı

Wigner 1932 yılında kuantum mekaniği alanında yaptığı çalışmalar esnasında Wigner dağılımını tanımlamıştır [44]. Daha sonra 1948 yılında işaret teorisine Ville tarafından uygulandığı için dağılım Wigner-Ville dağılımı olarak anılmaktadır [45]. WVD aşağıdaki şekilde ifade edilmektedir.

$$WVD(t, \omega) = \int_{-\infty}^{+\infty} s\left(t + \frac{\tau}{2}\right) s^*\left(t - \frac{\tau}{2}\right) e^{-j\omega\tau} d\tau \quad (1.2)$$

Burada ; $s(t)$ sinyalin zaman serisi, $s^*(t)$ sinyalin karmaşık eşleniği, t anlık zaman, ω anlık frekans, τ zaman gecikmesini ifade eder. (1.2)'deki gösterim (1.1)'deki gösterimdeki $\psi(\theta, \tau) = 1$ alınarak bulunmaktadır.

WVD'nın en önemli avantajları şunlardır; güçlü zaman frekans rezülasyonuna sahiptir, işaretin enerjisini anlık frekans boyunca yoğunlaştırır ve her zaman reel değerler almaktadır.

(t_1, ω_1) ve (t_2, ω_2) noktaları arasında iki farklı sinyalin yerleştiğini düşünelim. Bu sinyaller neredeyse 0 değerine $\left(\frac{t_1+t_2}{2}, \frac{\omega_1+\omega_2}{2}\right)$ noktasında erişeceklerdir. Fakat bu iki sinyalin çapraz WVD'si $t = \frac{t_1+t_2}{2}$ ve $w = \frac{\omega_1+\omega_2}{2}$ noktalarında çapraz bölgelere neden olacaktır. Genel olarak bu 0 değerli WVD bileşenleri çapraz terimler olarak adlandırılmaktadır. Bu çapraz terimler işarete bulunan enerjiyi göstermediği, gerçek yoğunluk fonksiyonunda olmayan negatif değerler aldığı ve işaretin zaman frekans gösteriminin yanlış yorumlanmasına yol açtığı için bu çapraz terimlerin gerçek

uygulamalarda bulunması istenmez. Bu amaçla önerilen YWVD kullanılarak çapraz terimlerin etkisi ortadan kaldırılmıştır [46]. YWVD (1.3)'deki şekilde ifade edilmektedir.

$$YWVD(t, \omega) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} s\left(t + \frac{\tau}{2}\right) s^*\left(t + \frac{\tau}{2}\right) g(\nu) h(\tau) e^{-j\omega t} d\nu d\tau \quad (1.3)$$

(1.3) eşitliğinde ν dengeleme frekansını, $g(\nu)$ zamanı (frekans uzayındaki yumuşatılmış pencere), $h(\tau)$ frekansı (zaman uzayındaki yumuşatılmış pencere) ifade etmektedir. Pencereleme operasyonundaki h ve g YWVD'deki zaman ve frekans uzayını ifade eder. Bu pencere seçme işlemiyle zaman frekans rezülasyonu ve çapraz terim seviyeleri arasında istenilen denge sağlanmaya çalışılır [47].

1.9.1.2. Choi–Williams Zaman Frekans Dağılımı

Choi–Williams dağılımı ilk olarak 1989 yılında Hyung-Il Choi ve William J. Williams tarafından önerilmiştir [48]. WVD'deki çapraz terimlerinin yok edilebilmesi için üstel bir taban kullanılmaktadır. Bu dağılım aynı zamanda Cohen sınıfın alt sınıfı olan azaltılmış girişim dağılımları (reduced interference distributions) sınıfına aittir. Bu dağılımda çekirdek (kernel) fonksiyonu kullanılmaktadır. Çekirdek fonksiyonu (1.4)'deki eşitlikle ifade edilmektedir [45].

$$\phi(\theta, \tau) = \frac{\sqrt{\pi\sigma}}{|\tau|} e^{-\frac{\pi^2\sigma\tau^2}{\tau^2}} \quad (1.4)$$

Çekirdek fonksiyonundaki σ filtrenin kesim frekansını kontrol eden parametredir ve σ değeri küçük tutularak çapraz terimlerin en aza indirilmesi sağlanır. σ değişkenin sonsuza yaklaşması durumunda çekirdek 1'e yaklaşır. Bu durumlarda CWD, WVD benzer karakteristik gösterecektir. σ değişkenin küçük seçilmesi durumunda σ değerleri girişimi azaltıcı bir görev üstlenir. Zaman frekans dönüşümlerinde çekirdek fonksiyonları kullanılarak istenilen dağılım sınırları elde edilebilir ve çekirdek fonksiyonuyla dağılım kolay bir şekilde üretilebilir böylece hesaplama karmaşıklığının önüne geçilebilir. CWD çapraz bileşenleri azaltmasına rağmen öz bileşenleri bulanıklaştırdığı için WVD'ye göre

daha bulanık bir zaman frekans gösterimine sahiptir. $s(t)$ sinyalinin CWD değeri (1.5)'deki gibidir. Burada t anlık zamanı, ω anlık frekansı τ zamanda ötelemeyi ifade eder [45].

$$CWD(t, \omega) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \frac{\sqrt{\pi\sigma}}{|\tau|} e^{-\frac{\pi\sigma(t-u)^2}{\tau^2}} s\left(u + \frac{\tau}{2}\right) s^*\left(u - \frac{\tau}{2}\right) e^{-j\omega\tau} dud\tau \quad (1.5)$$

1.9.1.3. Born-Jordan Zaman Frekans Dağılımı

Born-Jordan zaman frekans dağılımının temeli 1966'lı yıllarda atılmış olmasına rağmen özellikleri Jeong ve Williams'ın [49] çalışmalarına kadar anlaşılammıştır. Bu çalışmalarında Jeong ve Williams BJD'nın genel özelliklerini anlatmalarının yanında bu dağılımın azaltılmış girişim dağılımları (reduced interference distributions) özelliklerini taşıdığı ortaya koymuşlardır.

BJD için çekirdek (1.6)'daki eşitlik şeklinde ifade edilir.

$$\phi(\theta, \tau) = \frac{\sin \frac{1}{2} \theta \pi}{\frac{1}{2} \theta \pi} \quad (1.6)$$

BJD (1.7.)'deki eşitlik şeklinde ifade edilir. Burada t anlık zamanı, anlık frekansı ω , τ zamanda ötelemeyi ifade eder [49].

$$BJD(t, \omega) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \frac{1}{|\tau|} e^{-j\tau\omega} \int_{t-\frac{|\tau|}{2}}^{t+\frac{|\tau|}{2}} s\left(u - \frac{1}{2}\tau\right) s^*\left(u - \frac{1}{2}\tau\right) dud\tau \quad (1.7)$$

1.9.1.4. Bessel Zaman Frekans Dağılımı

Bessel zaman frekans dağılımı; $BD_s(t, \omega)$ s sinyaline (1.8)'deki eşitlik kullanılarak uygulanır.

$$BD_s(t, \omega) = \int_{\tau} e^{-j\omega\tau} \int_{\mu} \frac{2}{\pi} |\tau| \sqrt{1 - \left(\frac{\mu-t}{\alpha\tau}\right)^2} \times \prod\left(\frac{\mu-t}{2\alpha\tau}\right) s\left(\mu + \frac{\tau}{2}\right) s^*\left(\mu - \frac{\tau}{2}\right) \cos^{-1} \theta d\mu d\tau \quad (1.8)$$

(1.8)'deki eşitlikte α pozitif ölçekleme faktörüdür ve $\alpha \leq 0.5$ olarak seçilmesi önerilmektedir. (1.9)'daki karesel fonksiyon \prod kullanılarak $\sqrt{1 - \left(\frac{\mu-t}{\alpha\tau}\right)^2}$ değerinin negatif değer olmasının önüne geçilmektedir [49].

$$\prod\left(\frac{\mu-t}{2\alpha\tau}\right) = \begin{cases} 1 & |\mu-t| \leq \alpha\tau \\ 0 & \text{değilse} \end{cases} \quad (1.9)$$

BD Cohen sınıfına dâhil olup zamanda ve frekansta ötelelemeyle değişmektedir. Aynı zamanda gerçek değerli bir zaman frekans dağılımıdır. Jeong ve William azaltılmış girişim dağılımlarını (reduced interference distributions) kullanarak Bessel fonksiyonu tabanlı azaltılmış girişim dağılımını (reduced interference distribution) (1.10)'daki eşitlik şeklinde tanımlamışlardır [50].

$$RIDB_s(t, \omega) = \int_{-\infty}^{+\infty} h(\tau) R_s(t, \tau) e^{-j2\pi\omega\tau} d\tau \quad (1.10)$$

Burada $R_s(t, \tau)$ (1.11)'daki eşitlikteki gibidir.

$$R_s(t, \tau) = \int_{t-|\tau|}^{t+|\tau|} \frac{2g(\mu)}{\pi|\tau|} \sqrt{1 - \left(\frac{\mu-t}{\alpha\tau}\right)^2} s\left(\mu + \frac{\tau}{2}\right) s^*\left(\mu - \frac{\tau}{2}\right) d\mu \quad (1.11)$$

(1.11)'daki eşitlikte $s(t)$ orijinal sinyali, $s^*(t)$ sinyalin karmaşık eşleniği, t anlık zamanı, τ zaman gecikmesini, g zamanı (Frekans uzayındaki yumuşatılmış pencere) ve h frekansı (Zaman uzayındaki yumuşatılmış pencere) ifade eder [49].

1.9.1.5. Zhao-Atlas-Marks Zaman Frekans Dağılımı

Zhao-Atlas-Marks [51] zaman frekans dağılımında çapraz terimleri ortadan kaldırmak ve frekans çözünürlüğünü artırabilmek için konik şekilli çekirdek kullanmışlardır. Çekirdek eşitlik (1.12)' de verilmiştir.

$$\phi(\theta, \tau) = g(\tau) \left| \tau \right| \frac{\sin a\theta\tau}{a\theta\tau} \quad (1.12)$$

(1.12)'deki $g(t, \tau)$ konikleşme fonksiyonunu ve a konik şeklin eğimini ifade eder. $g(t, \tau)$ değeri (1.13)'deki eşitlikteki gibidir.

$$g(t, \tau) = \left[\omega(t) \operatorname{rect} \left(\frac{\alpha(t)}{4\tau} \right) \right] ** \sin c(t) \sin c(\tau) \quad (1.13)$$

(1.13) eşitliğindeki ; $\omega(t)$ Kaiser veya Gaussian pencere fonksiyonu ; $\operatorname{rect}(x)$ standart dikdörtgen fonksiyonu ; $\sin c(x) = \frac{\sin(\pi x)}{\pi x}$ sinc fonksiyonu ve “**” çift katlamayı (konvolüsyonu) göstermektedir. ZAMD (1.14)'deki eşitlikte verilmiştir [51].

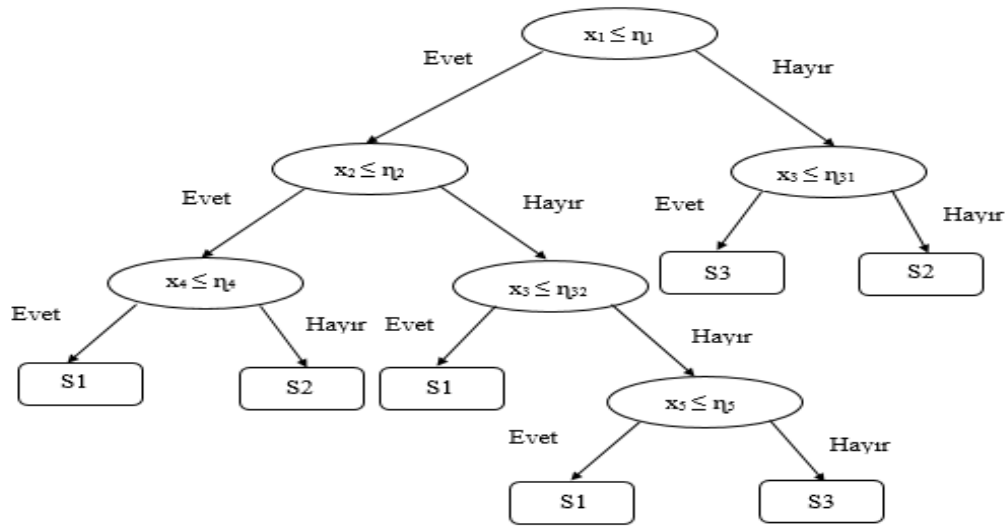
$$ZAMD(t, w) = \frac{1}{4\pi\alpha} \int_{-\infty}^{+\infty} g(\tau) e^{-j\tau\omega} \int_{t-|\tau|\alpha}^{t+|\tau|\alpha} s\left(u - \frac{1}{2}\tau\right) s^*\left(u - \frac{1}{2}\tau\right) du d\tau \quad (1.14)$$

1.10. Sınıflandırma Yöntemleri

Tez çalışmasında önerilen yöntemlerin sınıflandırma performans değerlendirmesi için Karar Ağaçları, DVM, K-EYK ve Sınıflandırıcı Toplulukları yöntemlerinden yararlanılmıştır. İlerleyen bölümlerde bu sınıflandırma yöntemlerinin teorik açıklaması yapılacaktır. Sınıflandırma yöntemlerinin adları karışıklığa sebep olmamak için İngilizce anılan adlarıyla verilecektir. Çalışmada önerilen yöntemin eğitim ve test performans analizini tespit etmek için Matlab yazılımındaki Classification Learner Toolbox kullanılmıştır.

1.10.1. Karar Ağacı Yöntemleri

Karar ağaçları düğüm, dal ve yaprak olmak üzere 3 temel kısımdan oluşmaktadır. Öznitelikler karar ağacı yöntemlerinde düğümlerde yerleşir. Yapraklara giden kollar üzerinde koşullar bir başka deyişle şartlar bulunmaktadır. Ağaçta en son kısım yaprak en üst kısım kök olarak adlandırılmaktadır. Düşük hesaplama karmaşıklığına sahip olması ve anlaşılması oldukça kolay olduğu için sıklıkla tercih edilen yöntemlerdir.



Şekil 1.21. Örnek karar ağacı [52].

Şekil 1.21.'deki iç düğümler karar düğümleri olup farklı özniteliklerle ifade edilir. η eşik değerlerine göre farklı öznitelikler sınıflandırılır. Eğer iç düğümlerdeki şart değeri sağlanıyorsa bir alt düğüme geçilir ve son olarak yaprak düğüme gelindiğinde o özneliğin hangi sınıfa ait olduğu belirlenir. Karar ağaçlarının karmaşıklığı o ağacın toplam düğüm sayısı, toplam yaprak sayısı, ağacın derinliği ve kullanılan özelliklerin sayısına bağlıdır [52].

Karar ağacı yöntemlerinde ağacın öğrenmesi aşamasında belli bir kurala göre ağaç alt kısımlara bölünür bu işlem rekürsif olarak tekrar edilir. Tekrarlama işleminin tahmin üzerinde etkisi kalmayana kadar rekürsif işlem devam ettirilir. Hangi daldan veya kökten itibaren hangi kritere göre dallanmasının yapılacağı karar ağaçlarında en önemli problemlerin başında gelmektedir [53]. Bu problemi çözümü için birçok farklı algoritmalar

bulunmaktadır ve bu algoritmalar farklı bölme kurallarına göre oluşturulmuştur. Bunlardan bazıları ID3, C4.5, C5, CART (Classification And Regression Trees), CHAID ve QUEST algoritmalarıdır. Tezde önerilen yöntemlerin sınıflandırma performansı değerlendirilirken ID3, C4.5 ve C5 ve CART algoritmalarını içeren sınıflandırma yöntemlerinden yararlanıldığı için ileryen kısımlarda bu algoritmaların genel özelliklerinden bahsedilecektir [54].

Bu algoritmalarından ID3, C4.5 ve C5 'de en ayırt edici özelliği belirlemek için bilgi kazancı ölçülür. Bilgi kazancı ölçümünde entropiden yararlanır. Entropi rastgeleliği, belirsizliği veya beklenmeyen durumunun ortaya çıkma olasılığıdır. X rastgele bir değişken olmak üzere X değeri $\{X_1, X_2, \dots, X_n\}$ şeklinde değerler alabilmektedir ve bu değerlerin gelme olasılıkları $\{p_1, p_2, \dots, p_n\}$ şeklindedir. X 'in entropisi (1.15)'deki eşitlik şeklinde ifade edebilmektedir. Bu algoritmalarda karar ağaçları yukarıdan aşağıya doğru oluşturulmaktadır [54].

$$H(x) = -\sum_{i=1}^n p(x_i) \log_2 p(x_i) \quad (1.15)$$

Quinlan'ın ID3 algoritmasının geliştirilmiş hali C4.5 algoritmasıdır ve C4.5 algoritmasının geliştirilmiş haliyse C 5.0 algoritmasıdır. Genel olarak ID3 algoritması aşağıdaki adımlardan oluşmaktadır.

- 1) Ağaca eklenmeyen özelliklerinin entropi değerlerini hesapla.
- 2) En düşük entropi değerine sahip özelliği seç.
- 3) En düşük entropi değerine sahip özelliği ayıran kararı ağaca ekle.

C4.5 algoritmasında ID3 algoritmasından farklı olarak entropi değerlerinin üzerinden normalizasyon yapılmaktadır. Yani entropi değerleri bir oran olarak tutulur. C4.5 algoritmasında budama yöntemleri kullanılmaktadır. C 5.0 algortması daha çok büyük veritabanları kullanılması önerilmektedir. C 5.0 algoritması C4.5 algoritmasına göre daha hızlı olup, bellek kullanımı daha düşüktür [55].

CART algoritması 1984 yılında Breiman ve Friedman tarafında önerilmiştir [56]. Ağacın dallanma durumunun belirlenmesi için bölme kuralı olarak Gini kuralı veya bir başka deyişle Gini indeksinden yararlanılmaktadır. Bu algortmada özellik değerleri iki alt kümeye ayrılarak bölme yapılır. Gini indeksi (1.16)'deki gibi hesaplanmaktadır.

X veri kümesi içerisinde n tane sınıf varsa ve p_j değeri C_j sınıfın olasılığıysa;

$$gini(X) = 1 - \sum_{j=1}^n p_j^2 \quad (1.16)$$

Eğer veri kümesi X_1 ve X_2 şeklinde iki alt kümeye bölünüyorsa ve her alt kümede N_1 ve N_2 örnek varsa $gini_{bölme}(X)$ değeri (1.17)'daki eşitlikten yararlanarak hesaplanır [55].

$$gini_{bölme}(X) = \frac{N_1}{N} gini(X_1) + \frac{N_2}{N} gini(X_2) \quad (1.17)$$

Her bölümlenmeden sonra $gini_{bölme}$ değeri en küçük olan seçilir. CART algoritmasında ağaç $gini_{bölme}$ değerine göre ikili olarak özyinelemeli olarak bölümlenmektedir. Bölümlenme aşaması bitince ağaçta uçtan köke doğru budama işlemi gerçekleştirilir [52].

1.10.1.1. Önerilen Yöntemlerde Kullanılan Karar Ağacı Sınıflandırma Yöntemleri

Tez çalışmasında önerilen yöntemlerin sınıflandırma performansların değerlendirilmesi için farklı maksimum bölme sayıları kullanılarak Karar Ağacı algoritmaları denenmiştir. İlerleyen kısımda bu algoritmalarından bahsedilecektir.

1.10.1.1.1 Simple Tree Yöntemi

Simple Tree Sınıflandırma yönteminde bölme kuralı olarak Gini indeksi kullanılmıştır. Maksimum bölme sayısı olarak 4 seçilmiştir.

1.10.1.1.2. Medium Tree Yöntemi

Medium Tree Sınıflandırma yönteminde bölme kuralı olarak Gini indeksi kullanılmıştır. Maksimum bölme sayısı olarak 20 seçilmiştir.

1.10.1.1.3. Kompleks Tree Yöntemi

Komples Tree Sınıflandırma yönteminde bölme kuralı olarak Gini indeksi kullanılmıştır. Maksimum bölme sayısı olarak 100 seçilmiştir.

1.10.2. Destek Vektör Makinelerine Genel Bakış

1995 yılında Cortes ve Vapnik tarafından ortaya atılan Destek Vektör Makineleri makine öğrenmesinde, örüntü sınıflandırmada ve kümelemede kullanılan bir öğrenme algoritmasıdır [57]. DVM algoritmalarında verilerin hangi sınıfa ait olduğu daha önceden bilinir bir başka deyişle danışmanlı öğrenme algoritmasıdır. Bu sınıflandırma algoritmalarının temelinde optimizasyon yöntemleri bulunduğu için büyük veritabanlarında iyi sonuçlar verir. Ayrıca hesaplama karmaşıklığı ve kullanılabilirlik açısından diğer tekniklere göre avantajlıdır.

DVM'deki esas amaç ayrılan öznelikleri birbirinden ayıracak en uygun ayırma hiperdüzlemlerin oluşturulmasıdır. Farklı verisetlerinde yüksek performans elde edebilmek için çekirdek (kernel) fonksiyonun seçimi oldukça önemlidir. Birçok farklı çekirdek fonksiyonları bulunmaktadır. DVM algoritmaları temelde ikili sınıflandırmada kullanılmaktadır. Ancak ikili sınıflandırıcılarının birleşimiyle çok sınıflı sınıflandırıcı olarak da uygulanabilmektedir [58].


1.10.2.1. Doğrusal Olarak Ayrılabilen 2 Sınıflı Veriler İçin Doğrusal DVM

Doğrusal olarak ayrılabilen 2 sınıflı verileri düzlemde ayırt edebilmek için bu 2 sınıf arasından sınır düzleminin çizilmesi gerekir. Bu sınır düzlem 2 sınıf elemanlarının da üyelerine en uzak yerden çizilmelidir.

N adet elemandan oluşan eğitim kümesi $D = \{(x_i, y_i), i = 1, \dots, N\}$ olduğu varsayalım. Burada $y_i = \pm 1$ ve sınıf etiketlerini gösterirken $x_i \in \mathcal{R}^n$ olup n boyutlu uzayda herhangi bir örnektir. Doğrusal bir sınıflandırıcı (1.18)'deki eşitlik şeklinde ifade edilebilir. Bu eşitlikte w ağırlık vektörünü b ise sabit terim olarak adlandırılmaktadır.

$$f(x) = \omega^T \cdot x + b \quad (1.18)$$

Eğer x noktalar kümesi $\omega^T x = 0$ olması durumunda tüm x noktaları ω 'ye dik ve orjinden geçer durumda olurlar. $\omega^T x = 0$ eşitliği 2 boyutlu olması durumunda bir çizgi, $\omega^T x = 0$ eşitliği 3 boyutlu olması durumunda bir düzlem ve n boyutlu olması durumunda bir hiperdüzlem oluşturulur [59].



Şekil 1.22. Doğrusal olarak ayrılabilen 2 sınıflı veriler için hiper düzlemin gösterimi

DVM'deki esas amaç en iyi yönelimdeki hiperdüzleminin belirlenmesidir. Hiper düzleminin de belirlenebilmesi için gerekli ω ve b değerlerinin bulunması gerekir. Şekil 1.22'de H_1 ve H_2 düzlemleri (1.19) ve (1.20)'deki gibi ifade edilebilir [58].

$$H_1 : x_i \cdot \omega + b = +1 \quad (1.19)$$

$$H_2 : x_i \cdot \omega + b = -1 \quad (1.20)$$

Eğitim verileri (1.21)'deki şekilde ifade edilebilir.

$$y_i (x_i \cdot \omega + b) - 1 \geq 0 \forall_i \quad (1.21)$$

Şekil 1.22.'de hiperdüzlemlere olan uzaklıklar sırasıyla d_1 ve d_2 olup bu uzaklıklar birbirine eşittir. Aynı zamanda bu uzaklıklar marjin olarak bilinir ve hiperdüzlemi destek vektörlerinden en uzak noktaya taşıyabilmek için marjin maksimum olarak ayarlanmalıdır. Marjin değerinin $\frac{1}{\|w\|}$ olduğu Şekil 1.22.'den rahatlıkla anlaşılabilir. Esas amaç marjin değerini maksimum yapmak olduğu için $\|w\|$ değeri minimum olmalıdır. $\|w\|$ değerini minimum yapabilmek $\frac{1}{2}\|w\|^2$ değerini minimum yapmaya eşittir. Bu düzenlemeyle birlikte; karesel programlama optimizasyonuna uygun bir şekilde minimum değer aranması gerçekleştirilebilir. Bu minimum değer aranması için (1.22)'deki eşitlik Lagrange çarpanları yöntemine yeniden düzenlenir [59].

$$\min \frac{1}{2}\|w\|^2, \text{ öyleki, } y_i (x_i \cdot w + b) - 1 \geq 0 \forall_i \quad (1.22)$$

(1.22)'deki eşitliğin α Lagrange çarpanlarına dağıtılmış şekli (1.23)'deki eşitlikte verilmiştir.

$$L_p = \frac{1}{2}\|w\|^2 - \sum_{i=1}^L \alpha_i y_i (x_i \cdot w + b) + \sum_{i=1}^L \alpha_i \quad (1.23)$$

(1.23)'deki eşitliği minimum w ve b değerleriyle maksimum yapacak α değerini bulmak için L_p 'nin w ve b 'ye göre türevleri alınır ve türevler sıfıra eşitlenir. Bu işlemler (1.24) ve (1.25)'de verilmiştir.

$$\frac{\partial L_p}{\partial w} = 0 \rightarrow w = \sum_{i=1}^L \alpha_i y_i x_i \quad (1.24)$$

$$\frac{\partial L_p}{\partial b} = 0 \rightarrow w = \sum_{i=1}^L \alpha_i y_i = 0 \quad (1.25)$$

(1.24) ve (1.25)'deki eşitlikler (1.23)'deki eşitlikte yerine koyulursa α 'ya bağlı (1.26)'deki eşitlik elde edilir.

$$L_d \equiv \sum_{i=1}^L \alpha_i - \frac{1}{2} \alpha^T H \alpha, \text{ öyleki, } \alpha_i \geq 0 \forall_i \sum_{i=1}^L \alpha_i y_i = 0 \quad (1.26)$$

L_d maksimum yapabilmek için (1.26)'daki konveks optimizasyon problemi çözülmelidir. (1.27)'daki hesaplanma sonucunda α değeri elde edilir. Elde edilen α değeriyle (1.24)'deki eşitlik çözülerek w değeri elde edilir.

$$\max_{\alpha} \left[\sum_{i=1}^L \alpha_i - \frac{1}{2} \alpha^T H \alpha \right], \text{ öyleki, } \alpha_i \geq 0 \forall_i \sum_{i=1}^L \alpha_i y_i = 0 \quad (1.27)$$

b değerinin hesaplanmasında (1.25)'deki ifadeyi sağlayan herhangi bir veri noktası (destek vektör) x_s (1.28)'deki şekilde olur.

$$y_s \left(\sum_{m \in S} \alpha_m y_m x_m \cdot x_s + b \right) = 1 \quad (1.28)$$

s destek vektörlerinin indeks kümesi ifade eder ve bu küme $\alpha_i > 0$ şartıyla bulunur. (1.21)'deki eşitlikten yararlanarak gerekli düzenlemeler yapılarak (1.29)'daki eşitlikten b değerine ulaşılır. Bahsedilen bu yollar sonunda elde edilen w ve b değişkenleri belirlenmiş olur [60].

$$b = y_s \sum_{m \in S} \alpha_m y_m x_m \cdot x_s \quad (1.29)$$


1.10.2.2. Doğrusal Olarak Ayrılamayan 2 Sınıflı Veriler İçin Doğrusal DVM

Gerçek hayattaki problemlerde veriler genelde doğrusal olarak ayrılamaz. Doğrusal olarak ayrılmayan veriler için sınırların gevşetilmesi gerekir. Bu gevşetilme işlemi için $(\xi_i, i = 1, \dots, n)$ sınırlamalara (1.30)'daki gibi pozitif pay değişkeni eklenerek sağlanır. Bu değişken yanlış sınıflandırılan veri örneğinin gerçekte dâhil olduğu karar sınırına olan uzaklığın ölçüsüdür.

$$\begin{aligned} \omega_T x_i + w_0 &\geq +1 - \xi_i, y_i = +1 \\ \omega_T x_i + w_0 &\leq -1 + \xi_i, y_i = -1 \end{aligned} \quad (1.30)$$

(1.30)'deki denklemlere $\xi_i \geq 0 \forall_i$ koşulunun eklenmesiyle (1.31)'deki eşitlik elde edilir.

$$y_i (x_i \cdot \omega + b) - 1 + \xi_i \geq 0 \quad (1.31)$$



Şekil 1.23. Doğrusal olarak ayrılamayan 2 sınıflı veriler için hiper düzlemin gösterimi [61].

Sınır miktarı ve test işlemindeki hata miktarı arasında dengeyi sağlayabilmek için C değişkeni (1.32)'deki gibi probleme eklenir.

$$\min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^L \xi_i, \text{ öyleki, } y_i (x_i \cdot \omega + b) - 1 + \xi_i \geq 0 \forall_i \quad (1.32)$$

(1.32)'deki ifadeyi w ve b değerlerini ξ_i değerine göre minimum; α değerine göre maksimum yapabilmek için doğrusal olarak ayrılabilen verilerde olduğu gibi Lagrange göre yeniden düzenlenip ve gerekli türevler alınırsa (1.33)'deki ifade elde edilir.

(1.33)'daki ifadenin çözümüyle α değeri bulunabilir. Bu α (1.24)'deki yerine koyularak w değeri de bulunmuş olur.

$$\max_{\alpha} \left[\sum_{i=1}^L \alpha_i - \frac{1}{2} \alpha^T H \alpha \right], \text{ öyleki, } 0 \leq \alpha_i \leq C \forall_i \text{ ve } \sum_{i=1}^L \alpha_i y_i = 0 \quad (1.33)$$

b 'yi hesaplamak için (1.29)'daki eşitlikten yararlanılır. Bu hesaplamanın yapılabilmesi için gerekli destek vektör kümesi $0 \leq \alpha_i \leq c_i$ şartını sağlayan i indis değerinin bulunması gerekmektedir [61].

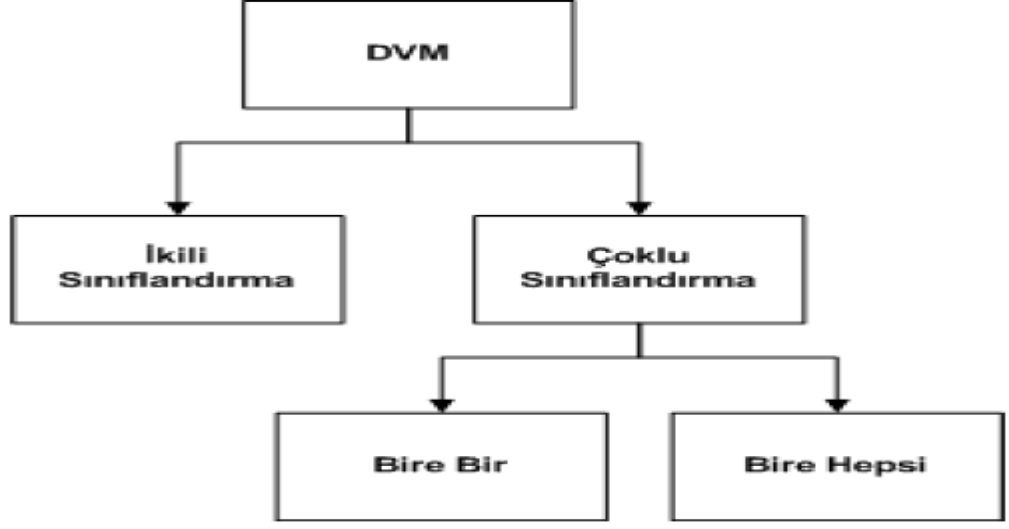
1.10.2.3. Doğrusal Olmayan Destek Vektör Makineleri

Doğrusal olmayan DVM'ler; normalde doğrusal olarak tam ayrılamayan veya belli bir hatayla birlikte de doğrusal olarak ayrılamayan verilerde kullanılır. Bu durumlarda; veriler üzerinde çekirdek (kernel) fonksiyonları kullanılarak veriler daha büyük boyutlu uzaylara taşınarak o uzaylar içerisinde sınıflandırılması gerçekleştirilir. Çekirdek fonksiyonları genel olarak (1.34)'deki şekilde ifade edilir. ϕ verileri daha yüksek boyuttaki uzaya taşımak için kullanılan fonksiyondur. K Çekirdek fonksiyonunu ifade eder. Birçok farklı çekirdek fonksiyonu tanımlanmıştır [62].

$$K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) \quad (1.34)$$

1.10.2.4. Çok Sınıflı Veriler için Destek Vektör Makineleri

DVM temel olarak 2 sınıflı veriler için sınıflandırmada kullanılmasına rağmen; bire bir stratejisi ve bire hepsi stratejisi kullanılarak çok sınıflı veriler için de uygulanabilir olmuştur. Şekil 1.24.'de DVM'nin genel yapısı verilmiştir.



Şekil 1.24. DVM'nin genel yapısı [61].

Bire bir stratejisinde her bir sınıf çifti için bir tane ikili DVM oluşturulur. N sınıflı veri kümesi için toplamda $\frac{N(N-1)}{2}$ tane DVM oluşturulur. Bire hepsi stratejisinde her bir sınıf için bir DVM üretilir. N tane sınıf için N tane DVM oluşturulur. Bire hepsi stratejisi eğitim süresinin uzun olması ve sonucun bulunmama ihtimalinin de olmasından kaynaklı tercih edilmez. Tezde önerilen yöntemlerde 4 sınıflı veriler için DVM sınıflandırma performansları değerlendirilirken bire bir stratejisi kullanılmıştır [61].

1.10.2.5. Önerilen Yöntemlerde Kullanılan Destek Vektör Makineleri

Tez çalışmasında önerilen yöntemlerin sınıflandırma performanslarını değerlendirmek için birçok farklı çekirdek fonksiyonu bağlı DVM'ler kullanılmıştır. İlerleyen bölümlerde bu DVM'lerin adları ve hangi çekirdek fonksiyonlarının kullanıldığından bahsedilecektir. Tüm DVM yöntemlerinde c değeri bir başka deyişle yumuşak-ayrım sabiti 1 olarak seçilmiştir. Bu yumuşak ayrım sabitinin artırmak destek vektörleri sayısını azaltırken eğitim süresini oldukça artırır.

1.10.2.5.1. Linear (Doğrusal) Destek Vektör Makinesi

Doğrusal DVM'de çekirdek fonksiyonu olarak (1.35)'deki formül kullanılmıştır.

$$K(x_1, x_2) = x_1^T \cdot x_2 \quad (1.35)$$

1.10.2.5.2. Fine Gaussian (Radyal Tabanlı) Destek Vektör Makinesi

Fine Gaussian DVM'de çekirdek fonksiyonu olarak (1.36)'deki formül kullanılmıştır. Burada γ çekirdek ölçekleme değeridir ve bu değer $\frac{\sqrt{a}}{4}$ 'e eşitlenmiştir. a değeri eğitim verisindeki öznitelik vektörünün sütun sayısını ifade eder. Tezde önerilen yöntemlerde $a = 20$ 'dir. Küçük γ değerleri seçilirse karar sınırı doğrusal olacaktır. γ değeri çok büyük seçilirse; yanlış kapsamalara bu da yanlış sınıflandırmalara neden olacaktır. γ değeri sınıflandırma performanslarına göre optimize edilir.

$$K(x_1, x_2) = \exp\left(-\gamma \|x_1 - x_2\|^2\right) \quad (1.36)$$

1.10.2.5.3. Medium Gaussian (Radyal Tabanlı) Destek Vektör Makinesi

Medium Gaussian DVM'de çekirdek fonksiyonu olarak (1.36)'deki formül kullanılmıştır. Çekirdek ölçekleme değeri \sqrt{a} 'e eşitlenmiştir.

1.10.2.5.4. Coarse Gaussian (Radyal Tabanlı) Destek Vektör Makinesi

Coarse Gaussian DVM'de çekirdek fonksiyonu olarak (1.36)'deki formül kullanılmıştır. Çekirdek ölçekleme değeri $4 \times \sqrt{a}$ 'e eşitlenmiştir.

1.10.2.5.5. Kubik Destek Vektör Makinesi

Kubik DVM’de çekirdek fonksiyonu olarak (1.37)’deki formül kullanılmıştır. $p = 3$ olarak seçilmiştir.

$$K(x_1, x_2) = \left(1 + x_1^T x_2\right)^p \quad (1.37)$$

1.10.2.5.6. Kuadratik Destek Vektör Makinesi

Kuadratik DVM’de çekirdek fonksiyonu olarak (1.37)’deki formül kullanılmıştır. $p = 2$ olarak seçilmiştir.

1.10.3. K En Yakın Komşu Sınıflandırma Algoritması

K-En Yakın Komşu (K-EYK) algoritması en temel sınıflandırma algoritmalarından olup anlaşılması ve uygulanması kolaydır. Bu algoritmaya göre tüm eğitim örnekleri N boyutlu uzayda bir noktaya karşılık olarak düşürülür. Bu örneklerin hangi sınıfa ait olduğunu belirleyebilmek için kaç tane en yakın komşu seçileceğini k değeri ifade eder. En yakın komşu belirlenirken seçilen örnek ile eğitim kümesindeki örnek arasındaki uzaklık hesaplaması yapılır. Uzaklık hesaplamasında genelde Öklid uzaklığı kullanılmaktadır. Öklid uzaklığının dışında Cityblok(Manhattan), Chebyshev ve Mahalanobis uzaklığı gibi birçok uzaklık kullanılan, K-EYK sınıflandırma algoritmaları bulunmaktadır. K-EYK sınıflandırma algoritması aşağıda verilen adımlarla gerçekleştirilir [63].

- 1) Test edilecek örneklerin eğitim kümesindeki örneklere olan uzaklıklarını bul.
- 2) Bu uzaklıkların en yakın k tanesini al ve ortalamalarını hesapla.
- 3) Bu ortalama uzaklık değerlerini belirlenen eşik değerine göre kıyasla ve hangi sınıfa uygunsa o sınıfa ata.

1.10.3.1. Önerilen Yöntemlerde Kullanılan K-EYK Yöntemleri

Tez çalışmasında önerilen yöntemlerin sınıflandırma performanslarının değerlendirilmesi için farklı k değerleri ve farklı uzaklık hesaplama yöntemleri

kullanılarak birçok K-EYK algoritması denenmiştir. İlerleyen kısımda bu algoritmalarından bahsedilecektir. K-EYK yönteminde komşu sayısı (k), uzaklık ölçütü ve ağırlıklandırma yöntemi önemli parametrelerdir. Sınıflandırılmakta olan örneğe daha yakın olan komşu örneklerin oylamada ağırlığının artması için; o örneklere ağırlık atanır. d komşular arası uzaklık olmak üzere $\frac{1}{d}$ veya $\frac{1}{d^2}$ en çok kullanılan ağırlık değerleridir [64].

1.10.3.1.1 Fine K-EYK Yöntemi

Fine K-EYK algoritmasında uzaklık hesaplamasında Öklid uzaklığı kullanılmıştır ve $k = 1$ olarak seçilmiştir. Komşuluk ağırlıklandırılması yapılmamıştır. Sayısal değişkenler için uzaklık; d boyutlu örüntü verileri için kullanılan Minkowski metriğinden türetilir. $X = \{x_1, x_2, \dots, x_n\}$ ve $Y = \{y_1, y_2, \dots, y_n\}$ olmak üzere X ve Y noktaları arasındaki Minkowski uzaklığı (1.38)'deki gibi ifade edilebilir. $p = 2$ seçilerek Öklid uzaklığı elde edilebilir.

$$\left(\sum_{i=1}^n |x_i - y_i|^p \right)^{1/p} \quad (1.38)$$

1.10.3.1.2. Medium K-EYK Yöntemi

Medium K-EYK algoritmasında uzaklık hesaplamasında Öklid uzaklığı kullanılmıştır ve $k = 10$ seçilmiştir. Komşuluk ağırlıklandırılması yapılmamıştır.

1.10.3.1.3. Coarse K-EYK Yöntemi

Coarse K-EYK algoritmasında uzaklık hesaplamasında Öklid uzaklığı kullanılmıştır ve $k = 100$ seçilmiştir. Komşuluk ağırlıklandırılması yapılmamıştır.

1.10.3.1.4. Kosinüs K-EYK Yöntemi

Kosinüs K-EYK algoritmasında uzaklık hesaplamasında kosinüs uzaklığı kullanılmıştır. Kosinüs uzaklığı (1.39)'deki gibi ifade edilebilir burada T transpozeyi ifade eder. $k = 10$ seçilmiştir ve komşuluk ağırlıklandırılması yapılmamıştır.

$$\left(1 - \frac{X \cdot Y^T}{\sqrt{(X \cdot X^T)(Y \cdot Y^T)}} \right) \quad (1.39)$$

1.10.3.1.5. Kubik K-EYK Yöntemi

Kubik K-EYK algoritmasında uzaklık hesaplamasında (1.38)'deki Minkowski uzaklığı $p = 3$ seçilerek kullanılmıştır. $k = 10$ seçilmiştir ve komşuluk ağırlıklandırılması yapılmamıştır.

1.10.3.1.6. Weighted K-EYK Yöntemi

Weighted K-EYK algoritmasında uzaklık hesaplamasında Öklid, Cityblok (Manhattan) ve Chebyshev uzaklığı kullanılmıştır. Cityblok (Manhattan) uzaklığı (1.37)'deki Minkowski uzaklığında $p = 1$ alınarak bulunabilir.

Chebyshev uzaklığı iki nokta arasındaki farkların mutlak değerinin maksimumu olarak ifade edilir. (1.40)'daki eşitlikten hesaplanabilir [65]. Sınıflandırma performans değerlendirmesinde Öklid uzaklığı veya Cityblok uzaklığına göre daha düşük sonuçlar çıktığı için Chebyshev uzaklığı kullanılarak bulunan sonuçlar verilmemiştir.

$$\max_{i=1}^n |x_i - y_i| \quad (1.40)$$

Tüm bu uzaklık ölçütleri için $k = 10$ seçilmiştir. Komşuluk ağırlıklandırılmasında ağırlık değeri olarak $\frac{1}{d^2}$ seçilmiştir. Önerilen yöntemlerin sınıflandırma performans değerlendirmesinde K-EYK algoritmalarında ağırlık değeri seçimi yapılırken ilk olarak $\frac{1}{d}$

denenmiştir. Ancak sonuçların $\frac{1}{d^2}$ değerinde yüksek çıktığı görüldüğü için tüm sonuçlar bu değere göre verilmiştir.

1.10.4. Topluluk Sınıflandırıcıları Yöntemleri

Topluluk Sınıflandırıcıları sınıflandırma işleminin tek bir sınıflandırma algoritmasıyla yapmak yerine; birçok sınıflandırma algoritması sonucunda elde edilen sonuçların birleştirilmesine yönelik yöntemlerdir [66]. Topluluk sınıflandırma yöntemleri en basit ve ilk yöntemi olarak Breiman ve arkadaşlarının 1994 yılında önerdikleri Torbalama (Bagging) yöntemi gösterilebilir [67]. Bu yöntemde eğitim veri setinin yer değiştirmesiyle farklı kombinasyonlar üretilir. Daha sonra bu farklı kombinasyonlar farklı modeli eğitmede kullanılır. Tek bir sonuç alabilmek için bu eğitim modellerinin ortalaması alınır veya oylama ile sonuç belirlenir. Torbalama algoritmasının dışında AdaBoost, Rastgele Ormanlar (RO) ve Rastgele alt uzaylar algoritmaları da sınıflandırıcı toplulukları yöntemlerinde yaygın olarak kullanılmaktadır. İlerleyen kısımlarda tez çalışmasında kullanılan sınıflandırıcı topluluklarından bahsedilecektir.

1.10.4.1. Boosted Trees

Boosted Trees sınıflandırma yönteminde; AdaBoost algoritması Karar Ağacı sınıflandırma yöntemiyle kullanılmıştır. AdaBoost algoritmasında eğitim veri setinden bir sınıflandırıcı oluşturulur bu sınıflandırıcının test sonucu başarısına göre, ilk iterasyonda yanlış sınıflandırılmış örnekler bir sonraki iterasyonda başarılı olsun diye ağırlıkları artırılır. Tez çalışmasında önerilen yöntemlerin Boosted Trees sınıflandırma performans değerlendirmesinde iterasyon sayısı 50 ve oluşturulacak ağaç sayısı 100 olarak alınmıştır [68].

1.10.4.2. Bagged Trees

Bagged Trees sınıflandırma yönteminde; RO algoritması Karar Ağacı sınıflandırma yöntemiyle kullanılmıştır. RO, Bagging (Torbalama) yöntemine rastgelelik özelliği

eklenerek geliştirilmiş şeklidir. Bu yöntemde ağacın her bir düğümünde rastgele olarak seçilen değişkenler arasında en iyi olanı kullanarak her bir düğümü dallara ayırır. Rastgele özellik seçimi kullanılarak ağaçlar geliştirilir. Bu ağaçların geliştirilmesinde CART algoritması kullanılır. RO algoritmasında oluşturulacak olan ağaç sayısı 100 olarak seçilmiştir [69].

1.10.4.3. Subspace K-EYK

Subspace K-EYK yönteminde Rastgele Alt Uzay algoritması K-EYK sınıflandırma yöntemiyle kullanılmıştır. Rastgele Alt Uzay algoritmasında Ho tarafından önerilmiştir. Bu yöntemde eğitim kümesindeki tüm örnekler verilmektedir ancak bu örneklerin tüm özelliklerinin verilmesi yerine rastgele seçilen özellikleri alınmaktadır. Bu şekilde her seferinde sınıflandırma yöntemlerine farklı uzaylardaki verilerin dağılımlar verilir olaya farklı açılardan bakılabilmektedir [70]. Tez çalışmasında önerilen yöntemlerin Subspace K-EYK sınıflandırma performans değerlendirmesinde; K-EYK komşu sayısı 100 ve alt uzay boyutu gerçek uzay boyutunun yarısı olan 10 olarak alınmıştır.

1.11. Önerilen Yöntemlerin Performans Değerlendirmesi

Önerilen yöntemlerin performans değerlendirmesi gerçekleştirilirken birçok farklı metriktен yararlanılmıştır. Bunlar doğruluk (accuracy), duyarlılık (sensitivity, recall), özgüllük (specificity), F1 skoru (F score), pozitif prediktif değer (positive predictive value) precision (kesinlik) ve negatif prediktif değer (negative predictive value)'dir. Bu metrikler konfüzyon matrisindeki değerlerden hesaplanır. Konfüzyon matrisindeki elemanlar Doğru Pozitif (TP), Doğru Negatif (TN), Yanlış Pozitif (FP) ve Yanlış Negatif (FN)'dir. Bu elemanların neyi ifade ettiği aşağıda açıklanmıştır [71].

TP: Gerçekte Pozitif kümenin elemanı olup test sonucunu göre de pozitif çıkan elemanlardır.

TN: Gerçekte Negatif kümenin elemanı olup test sonucunu göre de negatif çıkan elemanlardır.

FP: Gerçekte Negatif kümenin elemanı olup test sonucunu göre hatalı olarak pozitif çıkan elemanlardır.

FN: Gerçekte Pozitif kümenin elemanı olup test sonucunu göre hatalı olarak negatif çıkan elemanlardır. Bu değerlere göre iki sınıf için Konfüzyon matrisi Tablo 1.3.'deki şekilde düzenlenir.

Tablo 1.3. İki sınıf için Konfüzyon matrisi

Gerçek Sonuç	Test Sonuçları	
	Sınıf 1	Sınıf 2
Sınıf 1	A(Doğru Pozitif)	C(Yanlış Negatif)
Sınıf 2	B(Yanlış Pozitif)	D(Doğru Negatif)

Çoklu sınıflar için Konfüzyon matrisi her sınıf için yeniden düzenlenir. Tablo 1.4.'de sınıf 1 için ve Tablo 1.5.'de sınıf 3 için TP, TN, FP ve FN değerlerinin Konfüzyon matrisinde nasıl güncellendiği verilmiştir. Benzer şekilde sınıf sayısına bağlı olarak du değerler güncellenerek gerekli hesaplamalar yapılır.

Tablo 1.4. Sınıf 1 için Konfüzyon Matrisi

Gerçek Sonuç	Test Sonuçları			
	Sınıf 1	Sınıf 2	Sınıf 3	Sınıf 4
Sınıf 1	TP	FN	FN	FN
Sınıf 2	FP	TN	FN	FN
Sınıf 3	FP	FN	TN	FN
Sınıf 4	FP	FN	FN	TN

Tablo 1.5. Sınıf 3 için Konfüzyon Matrisi

Gerçek Sonuç	Test Sonuçları			
	Sınıf 1	Sınıf 2	Sınıf 3	Sınıf 4
Sınıf 1	TN	FN	FP	FN
Sınıf 2	FN	TN	FP	FN
Sınıf 3	FN	FN	TP	FN
Sınıf 4	FN	FN	FP	TN

Doğruluk: Doğru bulunan sonuçlarının tüm sonuçlara oranıdır. (1.41)'daki gibi hesaplanır.

$$\text{Doğruluk} = \frac{A+D}{A+C+B+D} = \frac{TN+TP}{TP+TN+FP+FN} \quad (1.41)$$

Duyarlılık: Gerçekte Pozitif sınıfa ait olan elamanların test sonuçlarına göre ne kadar doğrulukta bulunabildiğini gösterir. (1.42)'daki gibi hesaplanır.

$$\text{Duyarlılık} = \frac{A}{A+C} = \frac{TP}{TP+FN} \quad (1.42)$$

Özgüllük: Gerçekte Negatif sınıfa ait olan elamanların test sonuçlarına göre ne kadar doğrulukta bulunabildiğini gösterir. (1.43)'daki gibi hesaplanır.

$$\text{Özgüllük} = \frac{D}{B+D} = \frac{TN}{TN+FP} \quad (1.43)$$

Pozitif Prediktif Değer: Bu değer aynı zamanda kesinlik (precision) olarak da adlandırılmaktadır.(1.44)'daki şekilde hesaplanır.

$$\text{Pozitif Prediktif Değer} = \frac{A}{A+B} = \frac{TP}{TP+FP} \quad (1.44)$$

Negatif Prediktif Değer: Bu değer (1.45)'daki şekilde hesaplanır

$$\text{Negatif Prediktif Değer} = \frac{D}{D+C} = \frac{TN}{FN+TN} \quad (1.45)$$

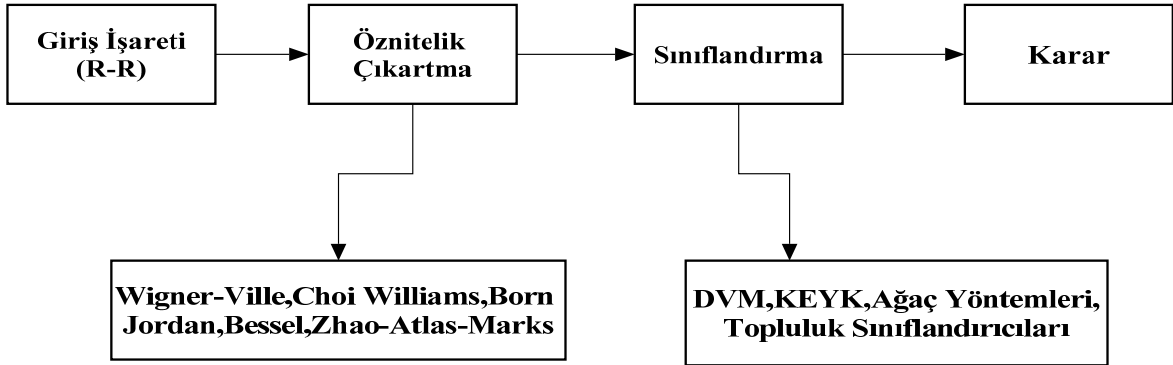
F1 skoru:F1 skoru duyarlılık ve kesinlik değerlerinin harmonik ortalamasıdır ve (1.46)'daki şekilde hesaplanır.

$$F_1 \text{Skoru} = 2 \cdot \frac{\text{Duyarlılık} \cdot \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} = \frac{2A}{2A+B+C} = \frac{2TP}{2TP+FP+FN} \quad (1.46)$$

2.YAPILAN ÇALIŞMALAR

Bu tez çalışmasında EKG işaretinin her hangi bir R-R aralığında bir ST segment seviyesi düşmesi veya yükselmesi olup olmadığını tespit edebilecek bir algoritmanın gerçekleştirilmesi amaçlanmıştır. Böylece hastada miyokard iskemi veya miyokard infarktüs varlığının önceden bulunabilmesi ve olası kalp krizinin kötü sonuçlarının en aza indirgenmesi sağlanır. Tez çalışmalarının ilk aşamasında ST segmenti seviyesi değişimlerini tespit edebilme hedeflenmiştir. Bu amaçla sağlıklı ve hastalıklı EKG işareti R-R aralığı bir sınıf; ST segment seviyesi değişimleri olan (yükselme veya düşme) bir sınıf olarak seçilmiştir. Önerilen yöntem 2 sınıflı bir probleme dönüşmektedir. Buradaki amaç ST segmenti değişimini (yükselmesi veya düşmesi) sağlıklı verilerden ve diğer hastalıklardan ayırt etmektir. Tez çalışmalarının ikinci aşamasında ise sağlıklı, hastalıklı, ST segment seviyesi düşmesi ve ST segment seviyesi düşmesi olan EKG işareti R-R aralıkları seçilmiştir. Böylece önerilen yöntemler 4 sınıflı probleme dönüştürülmüştür.

Önerilen algoritmalarda zaman-frekans analizine dayalı öznitelikler kullanılmıştır. Kullanılan bu zaman frekans dağılımları YWVD, CWD, BJD, BD ve ZAMD'dır. Önerilen yöntemlerin performans analizi DVM, KEYK, Ağaç yöntemleri ve Topluluk sınıflandırıcı gibi birçok sınıflandırma yöntemleri kullanılarak yapılmıştır. Ayrıca algoritmaların eğitim ve testi büyük veritabanlarında yapılmış olup hiçbir filtreleme yöntemi kullanılmamıştır. İlerleyen kısımlarda kullanılan Veri Tabanı, Ön-işleme, Öznitelikler ve Sınıflandırma aşamaları sırasıyla açıklanacaktır. Şekil 2.1.'de sistemin temel adımları verilmiştir.



Şekil 2.1. Sistemin temel adımları

2.1. Önerilen Yöntemlerde Kullanılan Veritabanları

Bölüm 1.8.'de tez çalışmalarında yararlanılan veritabanları ayrıntılı olarak açıklanmıştır. Tezin ilk aşamasında; MIT-BIH Aritmi veritabanındaki hastalıklı ve sağlıklı veriler bir sınıf, European ST-T veritabanındaki ST segment değişimleri (yükselmesi veya düşmesi) olan veriler farklı bir sınıf olacak şekilde toplamda 2 sınıf oluşturulmuştur. Bu sınıflar için MIT-BIH Aritmi veritabanından V1, V2, V4, V5 derivasyonlarında hastalıklı ve sağlıklı toplamda 111688 R-R aralığı seçilmiştir. Bu veri adları ve sayıları derivasyonlarla birlikte Tablo 2.1.'de verilmiştir. European ST-T veritabanında V1, V2, V3, V4, V5 derivasyonları kullanılmıştır. Bu verilerden 111688 tane ST segmenti yükselmesi veya düşmesi olan R-R aralıkları seçilmiştir. Bu veri adları ve toplam sayıları derivasyonlarla birlikte Tablo 2.2.'de verilmiştir.

Tablo 2.1. MIT-BIH Aritmi veritabanından alınan kayıtlar

Derivasyon	Veri Adı	Toplam
V1	101,105,106,107,108,109,111,112,113,115,116,118,119,121,122,200,201,202,203,205,207,208,209,210,212,213,214,215,217,219,220,221,222,223,228,230,231,232,233,234	92157
V2	102,103,104,117	7939
V4	124	1604
V5	100,102,104,114,123	9988
Toplam:		111688

Tablo 2.2. European ST-T veritabanından alınan kayıtlar

Derivasyon	Veri Adı	Toplam
V1	e0403,e0614,e0704,e0801, e0808,e1302,e1304	11496
V2	e0305,e0306,e0415,e0515, e0603,e0604	8245
V3	e0106,e0110,e0129,e0302,	6004
V4	e0104,e0105,e0107, e0108, e0111,e0112,e0113,e0114, e0116,e0118,e0119, e0121, e0122,e0124,e0125,e0126, e0127,e0139,e0147, e0148, e0154,e0159,e0161,e0162, e0163,e0166,e0170, e0501,e0607	38349
V5	e0115,e0202,e0204,e0205,e0206,e0207,e0208,e0210, e0211,e0212,e0213,e0303, e0304,e0305,e0306,e0403, e0404,e0405,e0410,e0411,e0415,e0417,e0418,e0515, e0602,e0603,e0605,e0607,e0609,e0613,e0613,e0614, e0808,e1302,e1304	47594
Toplam:		111688

Tez çalışmasının 2. aşaması olan EKG sinyalindeki herhangi bir R-R aralığında ST segmenti düşmesi, ST segmenti yükselmesi ve herhangi bir aritminin olup olmadığının tespit edilme aşamasında; Tablo 2.1., Tablo 2.3. ve Tablo 2.4'deki veritabanları, derivasyonlar ve kayıtlar kullanılmıştır. Tablo 2.3.'de; European ST-T ve Long Term ST Veritabanından alınan V1, V2, V3, V4, V5 derivasyonlarında toplamda 111688 tane ST segmenti yükselmesine ait ve Tablo 2.4.'de ise European ST-T ve Long Term ST Veritabanından alınan V1, V2, V3, V4, V5 derivasyonları toplamda 111688 ST segmenti düşmesine ait veri adları ve sayıları verilmiştir. Tablo 2.3. ve Tablo 2.4.'de "e" ile başlayan kayıtlar European ST-T; "s" ile başlayan kayıtlarsa Long Term ST veritabanlarından alınmıştır.

Tablo 2.3. European ST-T ve Long Term ST veritabanından alınan ST segmenti yükselmesi olan kayıtlar

Derivasyon	Veri Adı	Toplam
V1	e0403,e1302	4779
V2	e0515,e0604	14376
V3	e0110, s20311	221
V4	e0103,e0104,e0108,e0111,e0113,e0114,e0127,s20021, s20171,s20291,s20321,s20471	76187
V5	e0205,e0403,e0410,e0603,e0613,e0808, s30681	16125
Toplam:		111688


Tablo 2.4. European ST-T ve Long Term ST veritabanından alınan ST segmenti düşmesi olan kayıtlar

Derivasyon	Veri Adı	Toplam
V1	e0403,e0704,e0801,e0614,e0808,e1304,	29130
V2	e0306,e0415,e0603,e0604, s20581,s20591	23748
V3	e0106,e0129,e0302, s20311,s30661	24470
V4	e0105,e0107,e0112,e0116,e0118,e0119,e0121,e0122,e0124,e0125, e0126,e0139,e0147,e0148,e0154,e0159,e0161,e0162,e0163,e0166, e0170,e0501,s20151,s20301,s20171,s20331,s20481,s20491,s20511, s20551,s20601	17160
V5	e0115,e0204,e0206,e0207,e0208,e0210,e0211,e0212,e0213,e0303 ,e0304,e0305,e0306,e0404,e0405,e0411,e0415,e0417,e0418,e0515,e0 602,e0605,e0607,e0609,e0613,e0614,e1302,e1304,s20571, s30671,s30681	17160
Toplam:		111688


European ST-T, Long Term ST ve MIT-BIH Aritmi veritabanlarında her veride farklı derivasyonları bulunmaktadır. Bu yüzden tez çalışmasında kullanılan V1, V2, V3, V4, V5

derivasyonları olan veriler seçilmiştir. Benzer şekilde European ST-T ve Long Term ST veritabanındaki bazı verilerde ST segmenti düşmesi bazılarında ST segmenti yükselmesi bulunmaktadır. Bu veritabanlarından da uygun olan veriler seçilip veritabanları oluşturulmuştur.


Şekil 2.2.'de MIT-BIH Aritmi veritabanından 109 V1 derivasyonlu veriden Şekil 2.3.'deyse MIT-BIH Aritmi veritabanından 124m V4 derivasyonlu veriden hastalıklı örnek, Şekil 2.4.'de Long Term ST veritabanından s20571 V5 derivasyonlu veriden ST segmenti düşmesi, Şekil 2.5'deyse s20021 V4 derivasyonlu veriden ST segmenti yükselmesi olan, Şekil 2.6.'da European ST-T veritabanından e1304 V1 derivasyonlu veriden ST segmenti düşmesi, Şekil 2.7.'deyse e0515 V2 derivasyonlu veriden ST segmenti yükselmesi olan örnek R-R aralıkları verilmiştir. Verilen R-R aralıklarından anlaşılacağı üzere hastalıklı, ST segmenti düşmesi ve ST segmenti yükselmesi derivasyonlara ve kişilere bağlı olarak birçok farklı örüntü oluşturmaktadır. Burada genlik değerleri milivolt cinsindedir.



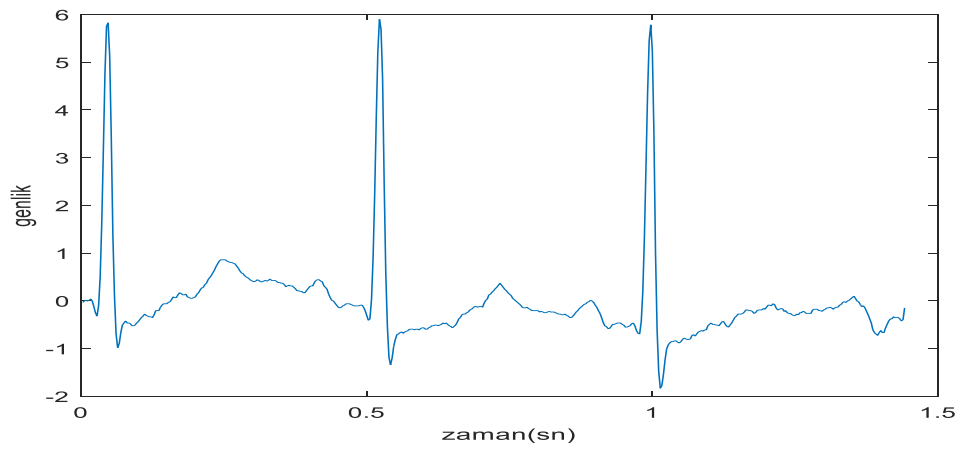
Şekil 2.2. 109 Sol dal bloğu (Hastalıklı) V1 derivasyonu EKG grafiği



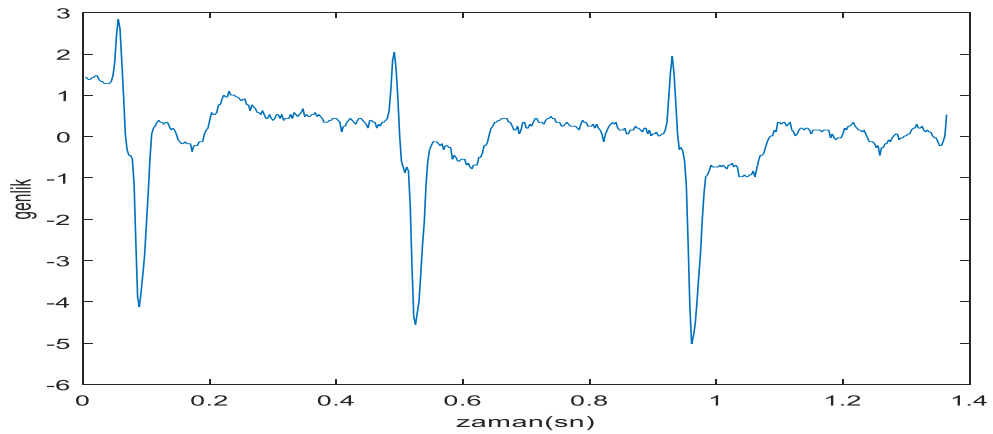
Şekil 2.3.124 Erken karıncık atımı(hastalıklı) V4 derivasyonu EKG grafiđi




Şekil 2.4. s20571 ST segmenti düşmesi V5 derivasyonu EKG grafiđi



Şekil 2.5. s20021 ST segmenti yükselmesi V4 derivasyonu EKG grafiđi



Şekil 2.6. e1304 ST segmenti düşmesi V1 derivasyonu EKG grafiği



Şekil 2.7. e0515 ST segmenti yükselmesi V2 derivasyonu EKG grafiği

2.2. Önerilen Yöntemlerde Kullanılan Ön İşleme

EKG işaretlerinin genel şekli olmasına rağmen; bu şekil birçok farklı gürültü kaynaklarından dolayı kolaylıkla değişebilmektedir. Bu gürültüler genel olarak hastadan EKG kaydı alınırken kullanılan elektrotlardan, şebekeden, hastanın hareketlerinden ve kas hareketlerinden kaynaklı gürültülerdir. Önerilen yöntemlerde bu gibi gürültü kaynaklarından sebebi oluşabilecek yanlış değerlendirmelerin önüne geçebilmek için oldukça sade ve hızlı bir işlem olan normalizasyon işlemi yapılmıştır. Bu işlemde öncelikle

EKG sinyalinin herbir R-R aralığındaki örnek değerleri için örnek değerlerin ortalama değeri ve standart sapması hesaplanmıştır. Daha sonra gerçek değerlerden bulunan ortalama değer çıkartılmıştır. Bulunan yeni değer standart sapmaya bölünmüştür. x örnek değerlerini ifade etmek üzere 2.1'deki eşitlik önişleme aşamasında kullanılmıştır.

$$X_i = \frac{X_i - \text{mean}(X_i)}{\text{std}(X_i)} \quad (2.1)$$

2.3. Önerilen Yöntemlerde Kullanılan Öznitelik Çıkartma

Öznitelik çıkartma aşamasında önişlemeden geçirilen EKG R-R aralıklarına çalışmada geleneksel zaman frekans analizi yöntemlerinden farklı bir yöntem olan ve güçlü zaman-frekans rezülasyonlarına sahip olan Yumuşatılmış Wigner-Ville, Choi-Williams, Born-Jordan, Bessel ve Zhao-Atlas-Mark dönüşümleri uygulanmıştır. Bu yöntemlerin ayrıntılı açıklaması bölüm 1.9.1'de yapılmıştır. Bu dönüşümler sonucunda EKG işareti zaman, frekans ve genlik olmak üzere 3 boyutlu olarak temsil edilebilir ve işarete hangi zaman aralığında hangi frekans değerlerinin olduğu rahatlıkla gözlemlenebilir.

Önerilen yöntemlerde EKG R-R aralıkları örnek sayısal değerleri bölüm 1.8.'de anlatıldığı şekilde uygun veritabanlarından çekilmiştir. Bu sayısal değerlere zaman frekans analizlerinin uygulanabilmesi için sayısal değerlerden analitik sinyallerin elde edilmesi gerekir. Analitik sinyal elde edilmek için Hilbert dönüşümünden yararlanılmıştır. Bu dönüşümle aynı zamanda sinyalin spektrumu üzerinde negatif ve pozitif bölgelerde oluşabilecek girişimlerin önlenmesi amaçlanmıştır. Herhangi bir $x(t)$ sinyalinin Hilbert dönüşümü bu sinyalin $\frac{1}{\pi t}$ ile konvolüsyonundan ibarettir. (2.2)'deki eşitlik şeklinde işarete uygulanır [72].

$$H\{x(t)\} = x(t) * \frac{1}{\pi t} = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t-\tau} d\tau \quad (2.2)$$

Zaman frekans dağılımı yöntemlerinin analitik sinyale uygulanabilmesi için pencere seçimi yapılmalıdır. Pencereyle birlikte EKG sinyali belli sayıda örnek içeren parçalara

ayrılır. Bölüm 1.9.1.'de ayrıntıları verilen zaman frekans dağılımları eşitliklerine bakılacak olursa sonsuz ifadeler yer almaktadır. Bu sonsuz ifadeleri sonlu ifadelere dönüştürebilmek için pencereleme işleminden yararlanır. Pencere seçimiyle sinyal parçalarının başlangıç ve bitişine çok yakın yerler elenir ve sinyal parçalarının orta noktaları vurgulanmaya çalışılır. Böylece olası yanlış değerlendirmelerin önüne geçilir. Bunların dışında bölüm 1.9.1.1.'de de pencereleme yönteminin neden yapılması gerektiği açıklanmıştır. Birçok farklı pencereleme yöntemi bulunmaktadır. Örneğin Kaiser, Hamming, Dikdörtgensel, Gauss pencereleme gibi. Tez çalışmasında önerilen yöntemlerde Hamming pencereleme yöntemi kullanılmıştır. Hamming penceresi bağımsız değişken olarak sadece pencere uzunluğuna sahiptir. N pencere uzunluğu olmak üzere Hamming penceresi 2.3'daki şekilde ifade edilebilir.

$$w(n) = \alpha - \beta \cos\left(\frac{2\pi n}{N-1}\right) \quad (2.3)$$

Zaman frekans dağılımı yöntemlerini EKG R-R aralıklarına uygularken iki farklı hamming penceresinden yararlanılmıştır. Bu pencereler g : Zaman için uygulanan Hamming pencere, h : Frekans için uygulanan Hamming pencere'dir.

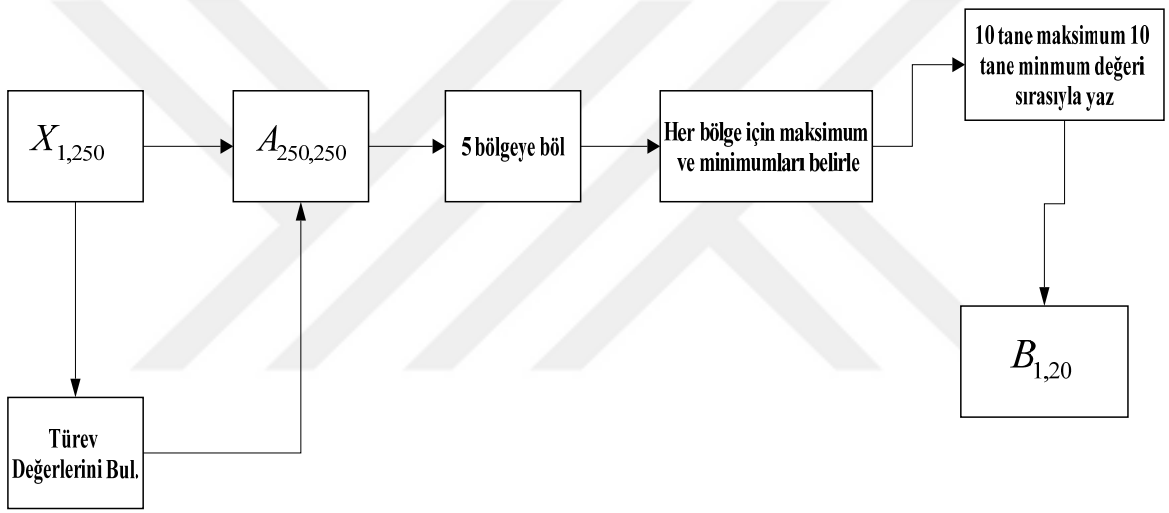
x örnek değerlerinin uzunluğu y olmak üzere; g ve h hamming pencerleri için N pencere uzunluğu 2.4'deki eşitlikteki gibidir [45].

$$N = \left(\frac{y}{4} - 1\right) - 1 - \text{mod}\left(\left(\frac{y}{4} - 1\right), 2\right) \quad (2.4)$$

Zaman frekans dönüşümleri yukarıda bahsedildiği şekilde uygulandıktan sonra; EKG işaretindeki her R-R aralığı için yatay ekseni zaman; dikey ekseni frekans olan 2 boyutlu katsayı matrisi elde edilir. EKG sinyalinin R-R aralığının baş ve son kısımları şekilsel olarak çok değişiklik göstermeyeceği için frekans ekseninde %3'lük baş ve son kısımları ihmal edilmiştir. Dikey ekseni frekans değerleri, yatay ekseni ise zaman değerleri olan 2 boyutlu katsayı matrisi 5 bölgeye bölünür. Bu bölgeler içerisindeki maksimum ve minimum katsayıları bulunur.


Daha sonra x örnek değerlerinin türev değerleri alınır. Bu türev değerleri üzerinden yukarıdaki işlemler tekrarlanarak zaman frekans dönüşümleri uygulanır ve aynı şekilde 2 boyutlu katsayı matrisi elde edilir. Bu katsayı matrisi 5 bölgeye bölünür. Benzer şekilde

bu bölgeler içerisindeki maksimum ve minimum katsayıları bulunur. En son adımdaysa 10 tane maksimum 10 tane minimum değerler sırasıyla yazılarak her bir R-R aralığı için boyutu 20 olan öznitelik vektörü oluşturulmuştur. Katsayı matrisinde maksimum ve minimum noktalar seçilerek frekans değişimlerinin olduğu bir başka deyişle ST segmenti düşmesi veya yükselmesi olan noktaların bulunması hedeflenmiştir. Şekil 2.8.'de örnek $X_{1,250}$ değerli giriş R-R aralığı için öznitelik çıkarma aşamasının blok diyagramı verilmiştir. Şekil 2.8.'deki $A_{250,250}$ zaman frekans dönüşümlerinden sonra elde edilen 2 boyutlu katsayı matrisini; $B_{1,20}$ öznitelik çıkarma aşamasının sonunda elde edilen öznitelik vektörünün ifade eder.




Şekil 2.8. Öznitelik çıkarma aşaması diyagramı


Şekil 2.9.'da MIT-BIH Aritmi veritabanından; 123 V5 derivasyonuna ait sağlıklı R-R aralıkları içeren işaret verilmiştir. Şekil 2.10., Şekil 2.11., Şekil 2.12., Şekil 2.13. ve Şekil 2.14'de ise sırasıyla tek R-R aralığında YWVD, CWD, BJD, BD ve ZAMD dönüşümleri sonucunda oluşan spektrumlar verilmiştir.




Şekil 2.9. 123 V5 derivasyonu sağlıklı EKG grafiği




Şekil 2.10. Sağlıklı R-R aralığının YWVD spektrumu




Şekil 2.11. Sağlıklı R-R aralığının CWD spektrumu



Şekil 2.12. Sağlıklı R-R aralığının BJD spektrumu




Şekil 2.13. Sağlıklı R-R aralığının BD spektrumu




Şekil 2.14. Sağlıklı R-R aralığının ZAMD spektrumu


Şekil 2.15’de MIT-BIH Aritmi veritabanından; 118 V1 derivasyonuna ait hastalıklı R-R aralıkları içeren işaret verilmiştir. Şekil 2.16., Şekil 2.17., Şekil 2.18., Şekil 2.19. ve Şekil 2.20.’deyse sırasıyla tek R-R aralığında YWVD, CWD, BJD, BD ve ZAMD dönüşümleri sonucunda oluşan spektrumlar verilmiştir.




Şekil 2.15. 118 V1 derivasyonu hastalıklı EKG grafiği




Şekil 2.16 Hastalıklı R-R aralığının YVWD spektrumu




Şekil 2.17. 16 Hastalıklı R-R Aralığının CWD Spektrumu



Şekil 2.18. Hastalıklı R-R aralığının BJD spektrumu




Şekil 2.19. Hastalıklı R-R aralığının BD spektrumu




Şekil 2.20. Hastalıklı R-R aralığının ZAMD spektrumu


Şekil 2.21.'de Long Term ST veritabanından; s20311 V3 derivasyonuna ait ST segmenti yükselmesi içeren R-R aralıkları işaret verilmiştir. Şekil 2.22., Şekil 2.23., Şekil 2.24., Şekil 2.25. ve Şekil 2.26.'daysa sırasıyla tek R-R aralığında YWVD, CWD, BJD, BD ve ZAMD sonucunda oluşan spektrumlar verilmiştir.




Şekil 2.21. s20311 V3 derivasyonu ST segmenti yükselmesi EKG grafiği




Şekil 2.22. ST Segmenti yükselmesi olan R-R aralığının YWVD spektrumu




Şekil 2.23. ST segmenti yükselmesi olan R-R aralığının CWD spektrumu



Şekil 2.24. ST segmenti yükselmesi olan R-R aralığının BJD spektrumu




Şekil 2.25. ST segmenti yükselmesi olan R-R aralığının BD spektrumu




Şekil 2.26. ST Segmenti yükselmesi olan R-R aralığının ZAMD spektrumu


Şekil 2.27.'de Long Term ST veritabanından; e0112 V4 derivasyonuna ait ST segmenti düşmesi içeren R-R aralıkları işaret verilmiştir. Şekil 2.28., Şekil 2.29., Şekil 2.30., Şekil 2.31. ve Şekil 2.32.'deyse sırasıyla tek R-R aralığında YWVD, CWD, BJD, BD ve ZAMD sonucunda oluşan spektrumlar verilmiştir.




Şekil 2.27. e0112 V4 derivasyonu ST segmenti düşmesi EKG grafiği




Şekil 2.28. ST segmenti düşmesi olan R-R aralığının YWVD spektrumu




Şekil 2.29. ST segmenti düşmesi olan R-R aralığının CWD spektrumu



Şekil 2.30. ST segmenti düşmesi olan R-R aralığının BJD spektrumu



Şekil 2.31 ST segmenti düşmesi Olan R-R aralığının BD spektrumu



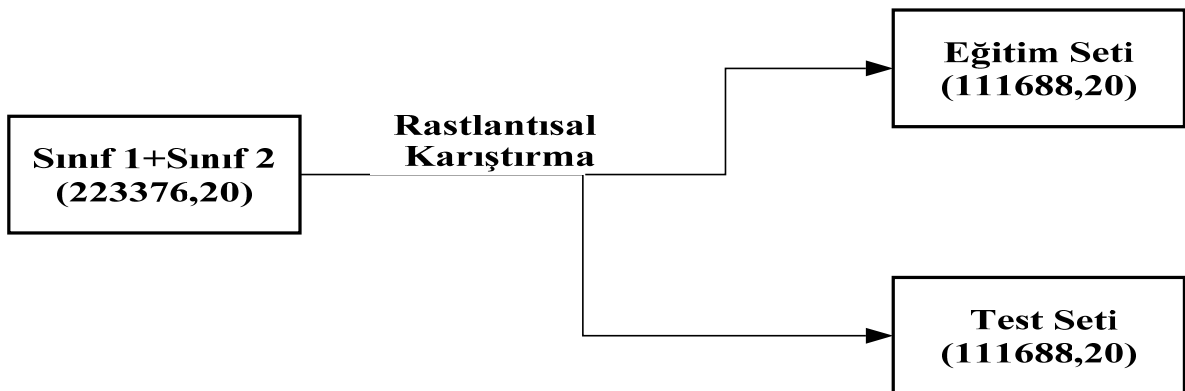
Şekil 2.32. ST segmenti düşmesi olan R-R aralığının ZAMD spektrumu

Verilen spektrumlardan da anlaşılacağı üzere; sağlıklı, hastalıklı (aritmî içeren), ST segmenti düşmesi ve ST segmenti yükselmelerinin; her bir zaman frekans dağılımlarının katsayılarına bağlı olarak farklı şekillerle karşımıza çıkmaktadır.

2.4. Önerilen Yöntemlerde Kullanılan Sınıflandırma Yöntemleri

ST segment düşmeleri veya yükselmeleri V1, V2, V3, V4, V5 derivasyonlarında daha etkin gözükür. European ST-T ve Long Term ST veritabanında var olan V1, V2, V3, V4, V5 derivasyonları seçilmiştir. MIT-BIH Aritmi veritabanında V3 derivasyonu bulunmadığı için seçilememiştir. Tez çalışmasında önerilen yöntemlerin sınıflandırma performans değerlendirmesi için Karar Ağaçları, DVM, K-EYK ve Sınıflandırıcı Toplulukları yöntemlerinden yararlanılmıştır. Bu yöntemlerin parametre seçimleri ve ayrıntıları bölüm 1.10.'da verilmiştir. Tez çalışmasındaki esas amaç geliştirilmekte olan Teletıp sistemi için kalp krizi gibi önemli durumlarda oluşabilecek alarm sisteminin oluşturulmasıdır. Bu amaç doğrultusunda tez çalışmasında sınıflar oluşturulmuştur.

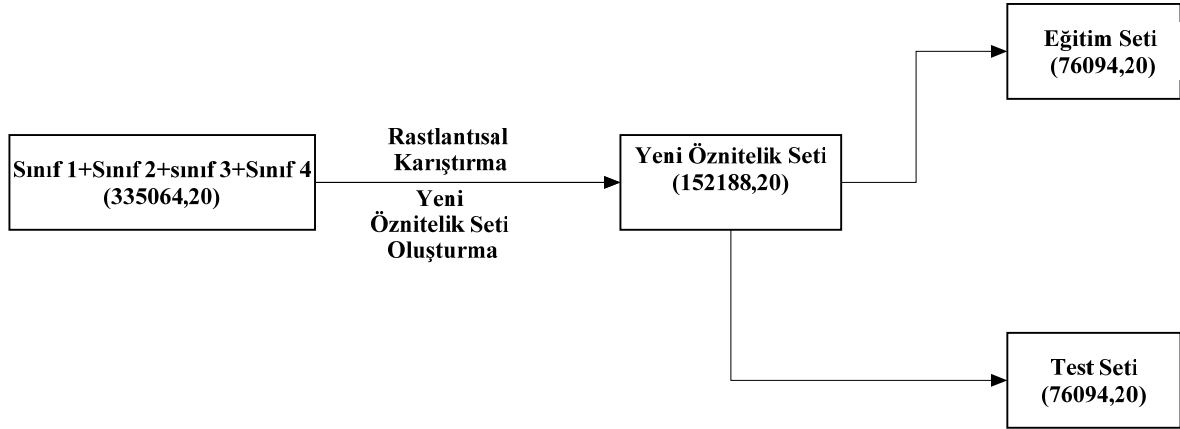
Tez çalışmalarının ilk aşamasındaki amaç ST segmenti değişimlerini (yükselmesi veya düşmesi) sağlıklı verilerden ve diğer hastalıklardan ayırt etmektir. Bu nedenle Tablo 2.1. ve Tablo 2.2 'deki veriler kullanılmıştır. Tablo 2.1.'deki veriler bir sınıf Tablo 2.2 'deki veriler diğer sınıf olarak seçilmiştir ve toplamda 2 sınıf oluşturulmuştur. Oluşturulan sınıf 1 ve sınıf 2 verileri birleştirilerek 223376 satır 20 sütuna sahip öznitelik vektör seti hazırlanmıştır. Daha sonra öznitelik vektör seti rastlantısal olarak karıştırılmıştır. Eğitim seti ve test seti eşit sayıda olabilmesi için rastlantısal olarak karıştırılan öznitelik vektör setinin yarısı eğitimde yarısı testte kullanılmıştır. Bu bahsedilen karıştırma işlemi 3 defa tekrarlanarak sınıflandırma performans değerleri hesaplanmıştır. Şekil 2.33.'de bahsedilen işlemin blok diyagramı verilmiştir.



Şekil 2.33 Birinci aşama çalışmalar için eğitim ve test seti oluşturma diyagramı

Tez çalışmalarının ikinci aşamasında Tablo 2.1., Tablo 2.3. ve Tablo 2.4.'deki veriler kullanılmıştır. Bu aşamadaki amaç EKG R-R aralığındaki hastalıklı, sağlıklı, ST segmenti yükselmesi ve ST segmenti düşmesini birbirinden ayırt etmektir. Bu nedenle Tablo

2.1.'deki 73641 tane sağlıklı R-R aralığı sınıf 1, Tablo 2.1'deki 38047 tane hastalıklı R-R aralığı sınıf 2, Tablo 2.3'deki 111688 tane ST segmenti düşmesi olan R-R aralığı sınıf 3 ve Tablo 2.4.'deki 111688 tane ST segmenti yükselmesi olan R-R aralığı sınıf 4 olarak atanmıştır. Oluşturulan sınıf 1, sınıf 2, sınıf 3, sınıf 4 verileri birleştirilerek 335064 satır 20 sütuna sahip öznitelik vektör seti oluşturulmuştur. Daha sonra öznitelik vektör seti rastlantısal olarak karıştırılmıştır. Öznitelik vektör setinden her seferinde en az sayıda R-R aralığına sahip sınıf sayısı kadar; yani 38047 tane öznitelik her sınıftan rastlantısal olarak seçilmiştir. $38047 * 4 = 152188$ tane R-R aralığına yeni öznitelik vektörü oluşturulmuştur. Bu yeni oluşturulan öznitelik vektörünün yarısı eğitim $\left(\frac{152188}{2} = 76094\right)$ yarısı da test $\left(\frac{152188}{2} = 76094\right)$ için kullanılmıştır. Bu bahsedilen karıştırma işlemi 3 defa tekrarlanarak sınıflandırma performans değerleri hesaplanmıştır. Eğitim aşamalarında 10-kat katlamalı çapraz doğrulama(10-fold cross validation) yaklaşımı kullanılmıştır. Bu yöntemde eğitim kümesi 10 eşit alt parçaya bölünür. Daha sonra her 9 küme eğitim için kullanılır geri kalan 1 küme ise eğitim doğruluğunu hesaplamak için kullanılır. Bu işlem 10 defa tekrarlanır tüm eğitim doğruluklarının ortalaması alınarak eğitim doğruluğu hesaplanır. Şekil 2.34'de bahsedilen işlemin blok diyagramı verilmiştir.



Şekil 2.34. İkinci aşama çalışmalar için eğitim ve test seti oluşturma diyagramı

2.5. Deneysel Sonuçlar ve Karşılaştırma

Tez çalışmalarının birinci aşaması olan 2 sınıflı problem için eğitim doğruluğu ve test doğruluğu, duyarlılığı, özgülüğü ve pozitif prediktif değer bölüm 1.11.'de verilen formüllerden yararlanılarak hesaplanmıştır. Bölüm 2.4.'de bahsedilen rastlantısal karışıma işlem 3 defa tekrarlanarak değerlerin ortalama ve standart sapmalar hesaplanmıştır. Bölüm 1.10.'da verilen önerilen yöntemlerde kullanılan sınıflandırma yöntemleri; kullanılarak performans analizleri tablolar şeklinde verilecektir. Talo 2.5.'de YWVD esaslı öznelikler kullanıldığında önerilen yöntemin performans analizi sonuçları verilmiştir.

Tablo 2.5. YWVD esaslı özneliklerle performans analizi sonuçları

Sınıflandırma Yöntemi	Eğitim	Test			PPD (%)
	Doğruluk (%)	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	
Destek Vektör Makineleri Yöntemleri					
Kuadratik	98.10 ±0.6	97.69± 0.02	97.92±0.05	97.43 ±0.04	97.44
Kubik	98.73± 0.06	98.76 ±0.04	98.77±0.02	98.83 ±0.07	98.83
Fine Gaussian	98.76± 0.06	97.78± 0.04	95.98±0.07	99.58 ±0.01	99.56
MediumGaussian	98.70 ±0.00	98.72 ±0.02	98.62±0.05	98.82 ±0.02	98.82
Coarse Gaussian	96.13±0.04	96.03±0.09	97.53±0.10	94.55±0.01	94.71
Doğrusal	93.73 ±0.06	93.80 ±0.02	93.46±0.08	94.15 ±0.13	94.40
K-En Yakın Komşuluk Yöntemleri					
Fine	98.6 ±0.00	98.65 ±0.00	98.84 ±0.00	98.47 ±0.00	98.48
Medium	98.63 ±0.06	98.56± 0.03	98.65± 0.02	98.6 ±0.03	98.67
Coarse	97.97± 0.21	98.05 ±0.17	98.24 ±0.16	97.85±0.17	97.86
Kosinüs	98.50 ±0.00	98.52± 0.04	98.53± 0.05	98.51 ±0.04	98.51
Kubik	98.46 ±0.06	98.48±0.04	98.40 ±0.08	98.51±0.01	98.51
Weighted-öklid	98.70 ±0.00	98.69± 0.02	98.73 ±0.01	98.56 ±0.02	98.56
Weighted-cityblok	98.60±0.02	98.30±0.13	98.52±0.14	98.43±0.05	98.43
Topluluk Sınıflandırıcıları Yöntemleri					
Bagged Trees	98.73±0.06	98.78± 0.02	98.55± 0.06	99.01 ±0.02	99.01
Subspace KEYK	98.63 ±0.06	98.71±0.04	98.58 ±0.04	98.83±0.04	98.83
Boosted Trees	95.1 ±0.00	95.18±0.00	94.01 ±0.00	96.35 ±0.00	96.43
Karar Ağacı Yöntemleri					
Simple Tree	89.52±0.08	89.50±0.02	90.60±0.10	88.29±0.06	88.55
Medium Tree	94.18±0.02	94.25±0.04	92.01±0.16	96.38±0.03	96.21
Complex Tree	96.15±0.05	96.02±0.08	95.32±0.11	96.75±0.07	96.70

Tablo 2.5.'den de görüldüğü gibi test doğruluğu, duyarlılığı, özgülüğü ve pozitif prediktif değeri sırasıyla %89.50 ve %98.78, %90.60 ve %98.84, %88.29 ve %99.58, %88.55 ve %99.56 arasında değişmektedir. En iyi sınıflandırma sonuçlarının, DVM algoritmalarındaki Kubik DVM yönteminde; K-EYK algoritmalarındaki Weighted

(Öklid) K-EYK yönteminde; Topluluk sınıflandırıcıları algoritmalarındaki Bagged Trees yönteminde olduğu görülmüştür. Bu sınıflandırma algoritmaların doğruluk, duyarlılık, özgüllük değerlerinin standart sapmaları sırasıyla maksimum 0.04, 0.06, 0.07 değerlerinde olduğu gözlemlenmiştir. Talo 2.6.'da CWD esaslı öznitelikler kullanıldığında önerilen yöntemin performans analizi sonuçları verilmiştir.

Tablo 2.6. CWD esaslı özniteliklerle performans analizi sonuçları

Sınıflandırma Yöntemi	Eğitim	Test			PPD (%)
	Doğruluk (%)	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	
Destek Vektör Makineleri Yöntemleri					
Kuadratik	97.77±0.15	97.62±0.51	98.31±0.07	97.53±0.05	97.55
Kubik	98.80±0.00	98.82±0.05	98.97±0.02	98.67±0.03	98.67
Fine Gaussian	98.24±0.06	98.31±0.04	97.25±0.05	99.37±0.04	99.36
MediumGaussian	98.5±0.00	98.53±0.02	98.65±0.32	98.24±0.02	98.25
Coarse Gaussian	96.26±0.06	96.38±0.03	97.86±0.04	94.91±0.04	95.06
Doğrusal	93.43±0.06	93.42±0.08	95.62±0.09	91.23±0.10	91.60
K-En Yakın Komşuluk Yöntemleri					
Fine	98.83±0.06	99.16±0.72	99.44±0.48	98.88±0.96	98.89
Medium	98.63±0.06	98.69±0.02	99.12±0.05	98.28±0.05	98.29
Coarse	97.77±0.46	97.81±0.36	98.90±0.12	96.73±0.61	96.80
Kosinüs	98.57±0.29	98.01±0.85	99.12±0.06	97.58±0.45	97.62
Cubic	98.7±0.20	98.14±0.49	99.04±0.01	98.17±0.08	98.19
Weighted-öklid	98.93±0.4	98.94±0.39	99.39±0.19	98.47±0.60	98.48
Weighted-cityblok	98.8±0.03	98.75±0.05	99.27±0.09	98.18±0.20	98.20
Topluluk Sınıflandırıcıları Yöntemleri					
Bagged Tree	99.00±0.34	99.06±0.38	99.08±0.34	99.02±0.45	99.02
Subspace K-EYK	98.78±0.12	98.82±0.11	99.02±0.12	98.52±0.22	98.53
Boosted Tree	91.48±0.02	91.60±0.06	91.50±0.03	91.74±0.05	91.72
Karar Ağaçları Yöntemleri					
SimpleTree	89.78±0.01	90.00±0.09	90.90±0.11	89.21±0.07	89.39
MediumTree	92.2±0.07	92.30±0.04	94.13±0.14	90.39±0.05	90.74
Complextree	95.46±0.06	95.46±0.15	96.44±0.37	94.77±0.35	94.86

Tablo 2.6.'dan da görüldüğü gibi test doğruluk, duyarlılık, özgüllük ve pozitif prediktif değerler sırasıyla %90.00 ve %99.06, %90.90 ve %99.44, %89.21 ve %99.02, %89.39 ve %99.36 değerleri arasında değiştiği görülmektedir. En iyi sınıflandırma sonuçlarının DVM algoritmalarındaki Kubik DVM yönteminde; K-EYK algoritmalarındaki Weighted (Öklid) K-EYK yönteminde; Topluluk sınıflandırıcıları algoritmalarındaki Bagged Trees yönteminde olduğu görülmüştür. Bu sınıflandırma

yöntemlerinin doğruluk, duyarlılık, özgüllük değerlerinin en yüksek standart sapma değerleriyse sırasıyla 0.39, 0.34, 0.60'dir.

Talo 2.7.'de BJD esaslı öznitelikler kullanıldığında önerilen yöntemin performans analizi sonuçları verilmiştir.

Tablo 2.7. BJD esaslı özniteliklerle performans analizi sonuçları

Sınıflandırma Yöntemi	Eğitim	Test			PPD (%)
	Doğruluk (%)	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	
Destek Vektör Makineleri Yöntemleri					
Kuadratik	97.70±0.87	97.71±0.84	97.59±0.79	97.82±0.89	97.81
Kubik	98.63±0.06	98.68±0.03	98.53±0.02	98.83±0.06	98.83
Fine Gaussian	96.7±0.00	96.91±0.05	94.03±0.15	99.65±0.03	99.63
Medium Gaussian	98.7±0.10	98.76±0.04	98.48±0.03	99.04±0.07	99.03
Coarse Gaussian	95.3±0.0	95.37±0.03	95.16±0.22	95.8±0.14	95.77
Doğrusal	91.33±0.06	91.32±0.04	91.98±0.02	90.65±0.08	90.77
K-En Yakın Komşuluk Yöntemleri					
Fine	98.7±0.0	98.71±0.01	98.75±0.08	98.67±0.09	98.67
Medium	98.66±0.06	98.67±0.03	98.40±0.03	98.62±0.09	98.62
Coarse	97.93±0.23	97.99±0.19	97.92±0.15	98.07±0.22	98.07
Kosinüs	98.5±0.17	98.54±0.15	98.72±0.09	98.37±0.20	98.38
Cubic	98.46±0.06	98.57±0.02	98.30±0.05	98.82±0.02	98.81
Weighted	98.73±0.06	98.74±0.04	98.71±0.07	98.78±0.14	98.78
Weighted (cityblok)	98.9±0.11	98.93±0.01	98.83±0.03	98.89±0.10	98.89
Topluluk Sınıflandırıcıları Yöntemleri					
Bagged Trees	98.86±0.38	98.93±0.42	98.49±0.59	99.37±0.25	99.36
Subspace K-EYK	98.81±0.20	98.28±0.35	98.03±0.09	99.15±0.13	99.14
Boosted Trees	90.4±0.2	90.44±0.10	83.67±0.29	97.22±0.26	96.78
Karar Ağaçları Yöntemleri					
Simple Tree	89.10±0.01	89.14±0.02	93.29±0.04	84.95±0.11	86.11
Medium tree	93.36±0.05	93.30±0.21	91.55±0.33	95.7±0.15	95.51
Complex tree	95.36±0.06	95.37±0.10	94.57±0.30	96.16±0.12	96.10

Tablo 2.7'den görüldüğü gibi test doğruluk, duyarlılık, özgüllük ve pozitif prediktif değerler sırasıyla %89.14 ve %98.93, %83.67 ve %98.75, %84.95 ve %99.65, %86.11 ve %99.63 değerleri arasında değiştiği görülmektedir. En iyi sınıflandırma sonuçlarının DVM algoritmalarındaki Medium Gaussian DVM yönteminde; K-EYK algoritmalarındaki Weighted (cityblok) K-EYK yönteminde; Topluluk sınıflandırıcıları algoritmalarındaki Bagged Trees yönteminde olduğu görülmüştür. Bu sınıflandırma yöntemlerinin doğruluk, duyarlılık, özgüllük değerlerinin en yüksek standart sapma değerleriyse sırasıyla 0.42, 0.59, 0.25'dir. Tablo 2.8.'de BD esaslı öznitelikler kullanıldığında önerilen yöntemin performans analizi sonuçları verilmiştir.

Tablo 2.8. BD esaslı özniteliklerle performans analizi sonuçları

Sınıflandırma Yöntemi	Eğitim	Test			PPD (%)
	Doğruluk (%)	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	
Destek Vektör Makineleri Yöntemleri					
Kuadratik	97.23±0.06	97.23±0.02	97.01±0.02	97.45±0.05	97.44
Kubik	98.43±0.05	98.53±0.02	98.33±0.02	98.74±0.03	98.73
Fine Gaussian	96.63±0.06	96.56±0.28	98.88±0.44	94.22±0.19	94.48
Medium Gaussian	98.6±0.00	98.62±0.07	98.36±0.01	98.89±0.11	98.88
Coarse Gaussian	95.73±0.05	95.81±0.04	94.93±0.12	96.69±0.06	96.63
Doğrusal	92.63±0.06	92.64±0.02	91.47±0.02	93.82±0.05	93.67
K-En Yakın Komşuluk Yöntemleri					
Fine	98.33±0.05	98.44±0.03	98.40±0.01	98.45±0.08	98.45
Medium	98.36±0.05	98.42±0.03	97.99±0.02	98.86±0.04	98.85
Coarse	97.46±0.05	97.56±0.02	97.01±0.05	98.11±0.01	98.09
Kosinüs	98.16±0.05	98.23±0.09	98.24±0.03	98.44±0.33	98.44
Kubik	98.23±0.05	98.29±0.09	97.79±0.05	98.68±0.07	98.67
Weighted-öklid	98.43±0.05	98.49±0.07	98.28±0.01	98.69±0.01	98.68
Weighted-cityblok	98.55±0.04	98.55±0.03	98.31±0.06	98.78±0.02	98.77
Topluluk Sınıflandırıcıları Yöntemleri					
Bagged Trees	98.16±0.05	98.30±0.02	97.86±0.04	98.74±0.01	98.73
Subspace K-EYK	98.32±0.08	98.25±0.07	97.78±0.10	98.67±0.11	98.66
Boosted Trees	91.76±0.05	91.81±0.03	89.20±0.09	94.35±0.21	94.04
Karar Ağaçları Yöntemleri					
Simple Tree	87.63±0.07	87.30±0.09	87.01±0.03	87.71±0.05	87.62
Medium Tree	91.7±0.43	91.71±0.39	89.56±0.18	93.48±0.43	93.21
Complex tree	94.3±0.1	94.30±0.13	93.52±0.02	94.60±0.27	94.54

Tablo 2.8.'den görüldüğü gibi test doğruluk, duyarlılık, özgüllük ve pozitif prediktif değerler sırasıyla %87.30 ve %98.62, %87.01 ve %98.88, %87.71 ve %98.89, %87.62 ve %98.88 değerleri arasında değiştiği görülmektedir. En iyi sınıflandırma sonuçlarının DVM algoritmalarındaki Medium Gaussian DVM yönteminde; K-EYK algoritmalarındaki Weighted (cityblok) K-EYK yönteminde; Topluluk sınıflandırıcıları algoritmalarındaki Bagged Trees yönteminde olduğu görülmüştür. Bu sınıflandırma yöntemlerinin doğruluk, duyarlılık, özgüllük değerlerinin en yüksek standart sapma değerleriyse sırasıyla 0.07, 0.06, 0.11'dir. Tablo 2.9. ZAMD esaslı öznitelikler kullanıldığında önerilen yöntemin performans analizi sonuçları verilmiştir.

Tablo 2.9. ZAMD dağılımı esaslı özniteliklerle performans analizi sonuçları

Sınıflandırma Yöntemi	Eğitim	Test			PPD (%)
	Doğruluk (%)	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	
Destek Vektör Makineleri Yöntemleri					
Kuadratik	97.28±0.02	97.32±0.01	97.35±0.04	97.24±0.09	97.24
Kubik	98.67±0.03	96.22±0.02	92.65±0.13	99.52±0.20	99.28
Fine Gaussian	96.03±0.07	96.25±0.04	92.79±0.04	99.62±0.12	99.59
Medium Gaussian	98.75±0.08	98.74±0.07	98.57±0.06	98.91±0.04	98.91
Coarse Gaussian	95.55±0.08	95.71±0.03	95.09±0.05	96.34±0.02	96.29
Doğrusal	92.55±0.10	92.57±0.05	92.31±0.13	92.84±0.05	92.80
K-En Yakın Komşuluk Yöntemleri					
Fine	98.76±0.04	98.74±0.16	98.86±0.07	98.79±0.09	98.79
Medium	98.65±0.05	98.79±0.03	98.53±0.03	99.05±0.04	99.05
Coarse	97.76±0.04	97.83±0.09	97.55±0.10	98.01±0.07	98.00
Kosinüs	98.61±0.08	98.76±0.07	98.55±0.01	98.78±0.10	98.78
Kubik	98.57±0.03	98.42±0.10	98.11±0.06	98.80±0.07	98.19
Weighted-öklid	98.78±0.02	99.15±0.41	99.07±0.45	99.24±0.39	99.24
Weighted -cityblok	98.88±0.02	98.97±0.03	98.89±0.02	99.06±0.06	99.06
Topluluk Sınıflandırıcıları Yöntemleri					
Bagged Trees	98.47±0.03	98.51±0.07	98.07±0.13	98.93±0.03	98.92
Subspace K-EYK	98.75±0.07	98.78±0.04	98.44±0.07	99.13±0.02	99.12
Boosted Trees	90.52±0.09	90.62±0.10	88.11±0.13	93.12±0.07	92.76
Karar Ağaçları Yöntemleri					
Simple Tree	89.9±0.01	89.94±0.12	86.77±0.15	93.10±0.38	92.63
Medium tree	92.0±0.15	92.01±0.22	89.04±0.47	94.98±0.03	94.66
Complex tree	94.38±0.02	94.19±0.03	91.90±0.06	96.40±0.09	96.23

Tablo 2.9.'dan görüldüğü gibi test doğruluk, duyarlılık, özgüllük ve pozitif prediktif değerler sırasıyla %89.94 ve %99.15, %86.77 ve %99.07, %92.84 ve %99.06, %92.63 ve %99.06 değerleri arasında değiştiği görülmektedir. En iyi sınıflandırma sonuçlarının DVM algoritmalarındaki Medium Gaussian DVM yönteminde K-EYK algoritmalarındaki Weighted (cityblok) K-EYK yönteminde; Topluluk sınıflandırıcıları algoritmalarındaki Subspace K-EYK yönteminde olduğu görülmüştür. Bu sınıflandırma yöntemlerinin doğruluk, duyarlılık, özgüllük değerlerinin en yüksek standart sapma değerleri ise sırasıyla 0.07, 0.07, 0.06'dir.

Tez çalışmalarının ikinci aşaması olan 4 sınıflı problem için eğitim doğruluğu ve test doğruluğu, duyarlılığı, özgüllüğü, F skoru ve negatif prediktif değerleri bölüm 1.11. verilen formüllerden yararlanılarak hesaplanmıştır. Eğitim doğruluğu 4 sınıfın ortalama değeri olarak verilmiştir. Diğer bahsedilen değerler her sınıf için tek tek hesaplanmıştır. Birinci aşamayla benzer şekilde; bölüm 2.4.'de bahsedilen rastlantısal karışıma işlem 3 defa

tekrarlanarak değerlerin ortalama ve standart sapmalar hesaplanmıştır. Daha sonra her sınıfın ortalama değerlerinin ve standart sapmalarının ortalama değerleri alınarak her sınıflandırma yöntemi için test doğruluğu, duyarlılığı, özgüllüğü, F skoru ve negatif prediktif değerler hesaplanmıştır. Bu ortalama değerler koyu renkle birlikte gösterilmiştir. Bölüm 1.10.'da önerilen yöntemlerde kullanılan sınıflandırma yöntemleri kullanılarak performans analizleri tablolar şeklinde verilecektir. Ancak Simple Tree, Medium Tree, Complex Tree, Doğrusal DVM, Coarse Gaussian ve Boosted Tree sınıflandırma yöntemlerinin sonuçları %80 altında çıktığı için tablolara eklenmemiştir.

Tablo 2.10. Dört sınıf için YWVD esaslı özniteliklerle performans analizi sonuçları

Sınıflandırma Yöntemi	Eğitim	Test				
	Doğruluk (%)	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	NPD (%)	F skoru (%)
Destek Vektör Makineleri Yöntemleri						
Kuadratik	87.93±0.12	88.13±0.08	88.09±0.04	95.70±0.09	95.69±0.14	88.09±0.11
ST Düşmesi		88.01±0.19	90.03±0.18	95.53±0.07	96.34±0.33	89.01±0.17
ST Yükselmesi		92.58±0.13	91.07±0.25	97.28±0.04	96.67±0.09	91.82±0.19
Sağlıklı		84.18±0.24	86.69±0.22	94.21±0.12	95.23±0.07	85.42±0.02
Hastalıklı		87.75±0.30	84.54±0.27	95.77±0.13	94.54±0.08	86.12±0.07
Kubik	93.2±0.1	93.24±0.20	93.22±0.18	97.65±0.08	97.62±0.10	93.23±0.06
ST Düşmesi		94.75±0.29	94.81±0.33	98.14±0.11	98.04±0.27	94.78±0.10
ST Yükselmesi		96.36±0.30	96.23±0.28	98.71±0.13	98.65±0.09	96.29±0.05
Sağlıklı		89.77±0.09	91.68±0.07	96.41±0.04	97.13±0.03	90.72±0.03
Hastalıklı		92.07±0.13	90.17±0.02	97.33±0.04	96.64±0.01	91.11±0.05
Fine Gaussian	88.5±0.0	91.27±0.13	88.94±0.15	96.21±0.06	96.15±0.12	89.21±0.09
ST Düşmesi		96.11±0.32	89.84±0.11	98.65±0.12	96.28±0.32	92.87±0.15
ST Yükselmesi		98.69±0.06	90.69±0.19	99.55±0.02	96.61±0.07	94.52±0.09
Sağlıklı		72.14±0.09	98.25±0.11	87.16±0.07	99.34±0.04	83.19±0.02
Hastalıklı		98.14±0.04	76.98±0.20	99.48±0.02	92.37±0.06	86.27±0.11
Medium Gaussain	92.9±0.0	92.88±0.24	94.21±0.20	94.55±0.09	97.55±0.12	92.97±0.13
ST Düşmesi		92.96±0.01	94.05±0.09	97.72±0.11	97.92±0.23	93.79±0.18
ST Yükselmesi		96.21±0.35	95.08±0.16	98.66±0.01	98.25±0.06	95.65±0.09
Sağlıklı		88.87±0.34	98.26±0.14	95.98±0.15	97.64±0.04	91.02±0.12
Hastalıklı		93.48±0.26	89.46±0.39	97.83±0.09	96.40±0.13	91.42±0.11
K-En Yakın Komşuluk Yöntemleri						
Fine	92.43±0.16	92.60±0.18	92.63±0.21	97.25±0.25	97.47±0.07	92.60±0.15
ST Düşmesi		93.99±0.17	93.48±0.1	97.42±0.79	97.86±0.04	93.73±0.11
ST Yükselmesi		94.46±0.1	96.45±0.13	97.96±0.04	98.72±0.04	95.44±0.10
Sağlıklı		90.68±0.36	89.69±0.24	96.82±0.13	96.44±0.07	90.16±0.23
Hastalıklı		91.25±0.09	90.88±0.35	96.78±0.04	96.84±0.12	91.07±0.17
Medium	92.57±0.05	92.84±0.22	92.57±0.23	97.40±0.09	97.37±0.08	92.56±0.14
ST Düşmesi		93.16±0.2	93.73±0.19	97.57±0.07	97.62±0.08	93.44±0.16

Tablo 2.10.'un devamı

ST Yükselmesi		94.33±0.09	96.08±0.12	97.94±0.03	98.59±0.04	95.21±0.09
Sağlıklı		89.44±0.44	91.59±0.21	96.26±0.18	97.07±0.07	90.51±0.13
Hastalıklı		94.42±0.14	88.87±0.38	97.82±0.06	96.20±0.12	91.09±0.17
Coarse	89.00±0.1	89.21±0.19	89.17±0.28	96.13±0.09	96.16±0.12	89.18±0.15
ST Düşmesi		89.74±0.02	89.81±0.13	96.30±0.02	96.34±0.07	89.71±0.04
ST Yükselmesi		90.53±0.18	94.10±0.19	96.39±0.08	97.81±0.06	92.28±0.09
Sağlıklı		86.87±0.45	86.60±0.24	95.36±0.18	95.34±0.05	86.83±0.21
Hastalıklı		89.71±0.1	86.16±0.55	96.48±0.06	95.14±0.18	87.91±0.24
Kosinüs	92.27±0.05	92.27±0.21	92.25±0.25	97.29±0.08	97.28±0.08	92.24±0.15
ST Düşmesi		92.65±0.24	93.07±0.17	97.40±0.09	97.52±0.09	92.86±0.15
ST Yükselmesi		93.47±0.08	95.83±0.16	97.61±0.03	98.49±0.06	94.64±0.11
Sağlıklı		89.57±0.39	91.28±0.16	96.32±0.15	96.95±0.06	90.42±0.17
Hastalıklı		93.39±0.12	88.82±0.33	97.81±0.05	96.16±0.10	91.05±0.18
Kubik	91.73±0.06	91.95±0.17	91.92±0.15	97.16±0.07	97.18±0.05	91.91±0.11
ST Düşmesi		92.52±0.12	92.96±0.08	97.34±0.05	97.52±0.03	92.74±0.06
ST Yükselmesi		93.67±0.16	95.75±0.17	97.68±0.06	98.46±0.06	94.70±0.01
Sağlıklı		88.58±0.38	90.97±0.04	95.93±0.15	96.84±0.01	89.76±0.19
Hastalıklı		93.03±0.04	88.01±0.31	97.70±0.01	95.89±0.10	90.45±0.18
Weighted-öklid	92.9±0.1	92.99±0.21	92.98±0.22	97.55±0.08	97.35±0.10	92.97±0.16
ST Düşmesi		94.27±0.12	93.33±0.11	98.01±0.04	96.80±0.15	93.79±0.12
ST Yükselmesi		94.19±0.02	96.85±0.19	97.87±0.01	98.87±0.06	95.51±0.09
Sağlıklı		90.42±0.47	91.51±0.21	96.66±0.18	97.06±0.07	90.96±0.22
Hastalıklı		93.07±0.23	90.24±0.38	97.67±0.09	96.65±0.12	91.63±0.20
Weighted-cityblok	93.8±0.1	93.81±0.19	93.62±0.20	97.85±0.07	97.86±0.06	93.78±0.12
ST Düşmesi		95.14±0.13	94.61±0.34	98.31±0.05	98.00±0.09	94.69±0.12
ST Yükselmesi		94.93±0.09	97.58±0.04	98.16±0.03	99.13±0.01	96.23±0.03
Sağlıklı		91.39±0.37	91.18±0.18	97.02±0.14	97.31±0.06	91.78±0.22
Hastalıklı		93.77±0.17	91.12±0.23	97.92±0.06	96.97±0.08	92.42±0.12
Topluluk Sınıflandırıcıları Yöntemleri						
Bagged Trees	94.26±0.06	94.30±0.13	94.13±0.10	97.98±0.08	97.99±0.10	94.15±0.09
ST Düşmesi		94.62±0.07	95.54±0.18	98.10±0.03	98.48±0.22	95.07±0.05
ST Yükselmesi		97.79±0.01	95.69±0.03	99.23±0.1	98.49±0.1	96.73±0.02
Sağlıklı		88.75±0.31	95.99±0.05	95.84±0.13	98.59±0.02	92.23±0.19
Hastalıklı		96.03±0.11	89.31±0.14	98.73±0.04	96.41±0.05	92.55±0.12
Subspace KEYK	92.8±0.02	91.01±0.34	92.83±0.27	97.51±0.09	97.02±0.07	93.62±0.14
ST Düşmesi		93.87±0.24	94.25±0.12	97.83±0.09	97.96±0.05	94.07±0.06
ST Yükselmesi		95.58±0.36	95.62±0.34	98.33±0.02	98.51±0.01	98.59±0.01
Sağlıklı		92.50±0.66	93.11±0.13	95.79±0.21	95.57±0.05	90.72±0.26
Hastalıklı		94.09±0.11	88.33±0.49	98.08±0.05	96.04±0.16	91.11±0.21

Tablo 2.10.'dan anlaşılacağı üzere test doğruluğu, duyarlılığı, özgüllüğü ve negatif prediktif değeri, F skoru değerleri sırasıyla %88.13 ve %94.30, %88.09 ve % 94.21, %94.55 ve %97.98, %95.69 ve %97.99, %88.09 ve %94.15 değerleri arasında değiştiği görülmektedir. En iyi sınıflandırma sonuçlarının DVM algoritmalarındaki Kubik DVM

yönteminde; K-EYK algoritmalarındaki Weighted (cityblok) K-EYK yönteminde; Topluluk sınıflandırıcıları algoritmalarındaki; Bagged Trees yönteminde olduğu alındığı açıkça gözükmektedir. Bu sınıflandırma yöntemlerinin doğruluk, duyarlılık, özgüllük, F skoru değerlerinin en yüksek standart sapma degerleriye sırasıyla 0.20, 0.20, 0.08, 0.10 ve 0.12'dir. Bahsedilen 3 yöntem arasında en iyi sonuca Weighted (cityblok) K-EYK yönteminde ulaşılmıştır. Bu yöntemin konfüzyon matrisi Tablo 2.11'da verilmiştir.

Tablo 2.11. YWVD dağılımı esaslı özniteliklerle en iyi sınıflandırma yönteminin konfüzyon matrisi

Gerçek Sonuçlar	Test Sonuçları				Yanlış Negatif	Doğru Negatif
	ST Düşmesi	ST Yükselmesi	Sağlıklı	Hastalıklı		
ST Düşmesi	17780	890	203	150	1243	52942
ST Yükselmesi	534	18388	80	21	635	52334
Sağlıklı	344	159	17362	1158	1661	53360
Hastalıklı	230	83	1518	17192	1831	53530
Yanlış Pozitif	1108	1132	1801	1329		
Doğru Pozitif	17780	18388	17362	17192		

Talo 2.12.'de CWD esaslı öznitelikler kullanıldığında önerilen yöntemin performans analizi sonuçları verilmiştir.

Tablo 2.12. Dört sınıf için CWD esaslı özneliklerle performans analizi sonuçları

Sınıflandırma Yöntemi	Eğitim	Test				
	Doğruluk (%)	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	NPD (%)	F skoru (%)
Destek Vektör Makineleri Yöntemleri						
Kuadratik	89.48±0.08	89.51±0.30	89.48±0.39	96.25±0.13	96.24±0.12	89.49±0.22
ST Düşmesi		93.37±0.46	91.77±0.17	97.61±0.18	96.99±0.03	92.56±0.28
ST Yükselmesi		88.95±0.11	91.13±0.55	95.93±0.03	96.78±0.19	90.03±0.31
Sağlıklı		86.90±0.21	88.34±0.51	95.29±0.11	95.86±0.16	87.62±0.19
Hastalıklı		88.81±0.43	86.68±0.34	96.17±0.18	95.32±0.1	87.73±0.11
Kubik	93.6±0.1	93.76±0.13	93.75±0.16	97.83±0.05	97.83±0.03	93.75±0.10
ST Düşmesi		96.69±0.03	96.31±0.4	98.83±0.01	98.67±0.03	96.50±0.18
ST Yükselmesi		94.77±0.31	95.17±0.01	98.15±0.12	98.30±0.01	94.97±0.15
Sağlıklı		90.96±0.1	92.35±0.06	96.86±0.03	97.37±0.02	91.65±0.02
Hastalıklı		92.61±0.07	91.17±0.17	97.50±0.03	96.98±0.05	91.89±0.05
Fine Gaussian	92.7±0.1	92.93±0.01	92.77±0.19	97.57±0.05	97.59±0.07	92.99±0.08
ST Düşmesi		98.06±0.03	94.81±0.1	99.32±0.01	98.44±0.04	96.74±0.1
ST Yükselmesi		96.59±0.12	93.89±0.15	98.82±0.04	97.85±0.05	95.22±0.06
Sağlıklı		82.83±0.15	96.90±0.14	93.19±0.08	98.88±0.05	89.31±0.04
Hastalıklı		96.61±0.19	85.47±0.36	98.96±0.06	95.17±0.11	90.70±0.12
Medium Gaussain	92.33±0.12	94.46±0.12	92.40±0.16	97.34±0.07	97.35±0.09	92.41±0.03
ST Düşmesi		95.58±0.02	93.49±0.1	98.46±0.1	97.66±0.12	94.52±0.04
ST Yükselmesi		91.06±0.04	93.68±0.08	96.77±0.02	97.76±0.02	92.35±0.05
Sağlıklı		89.70±0.17	92.87±0.18	96.29±0.07	97.59±0.12	91.26±0.01
Hastalıklı		93.52±0.25	89.56±0.28	97.83±0.09	96.40±0.09	91.50±0.03
K-En Yakın Komşuluk Yöntemleri						
Fine	93.73±0.06	93.92±0.03	93.96±0.17	97.89±0.04	97.97±0.13	93.95±0.07
ST Düşmesi		95.96±0.07	96.85±0.09	98.59±0.03	98.85±0.04	96.47±0.09
ST Yükselmesi		94.7±0.04	94.56±0.41	98.19±0.04	98.20±0.08	94.72±0.08
Sağlıklı		92.19±0.27	91.75±0.15	97.36±0.05	97.26±0.21	91.97±0.03
Hastalıklı		92.59±0.08	92.69±0.02	97.42±0.01	97.58±0.19	92.64±0.05
Medium	93.47±0.6	93.74±0.12	93.26±0.27	97.51±0.01	97.84±0.09	93.73±0.17
ST Düşmesi		93.74±0.12	95.02±0.05	96.94±0.02	98.92±0.03	95.97±0.01
ST Yükselmesi		94.02±0.13	94.25±0.01	97.91±0.04	97.99±0.01	94.14±0.14
Sağlıklı		91.05±0.66	93.41±0.24	96.84±0.26	97.71±0.07	92.22±0.21
Hastalıklı		94.95±0.16	90.35±0.75	98.34±0.07	96.72±0.24	92.59±0.31
Coarse	89.83±0.06	90.11±0.19	90.09±0.11	96.51±0.13	96.47±0.20	89.09±0.11
ST Düşmesi		91.43±0.25	93.83±0.07	96.81±0.09	97.71±0.17	92.62±0.1
ST Yükselmesi		89.43±0.08	90.77±0.16	96.36±0.29	96.69±0.05	90.09±0.12
Sağlıklı		88.08±0.13	88.83±0.02	95.76±0.05	96.05±0.06	88.46±0.14
Hastalıklı		91.52±0.28	86.95±0.16	97.13±0.1	95.44±0.52	85.18±0.06
Kosinüs	92.93±0.05	93.21±0.19	92.16±0.24	97.51±0.19	97.63±0.08	93.63±0.21
ST Düşmesi		93.89±0.09	93.03±0.06	97.36±0.52	98.94±0.01	97.76±0.04
ST Yükselmesi		93.12±0.04	93.65±0.07	97.58±0.01	97.77±0.02	93.38±0.06
Sağlıklı		90.52±0.6	93.07±0.01	96.63±0.23	97.58±0.01	91.78±0.31
Hastalıklı		95.32±0.02	88.9±0.82	98.48±0.02	96.23±0.26	91.99±0.43
Kubik	93.12±0.06	92.90±0.18	92.64±0.22	97.29±0.08	97.63±0.08	93.18±0.06
ST Düşmesi		93.19±0.01	94.44±0.02	96.63±0.06	98.78±0.01	95.52±0.03

Tablo 2.12.'nin devamı

ST Yükselmesi		93.69±0.07	93.64±0.12	97.79±0.02	97.77±0.04	93.66±0.08
Sağlıklı		90.31±0.3	92.82±0.27	96.56±0.12	97.50±0.1	91.55±0.03
Hastalıklı		94.42±0.33	89.65±0.45	98.16±0.12	96.47±0.14	91.97±0.09
Weighted-öklid	93.9±0.0	94.97±0.20	94.08±0.21	97.94±0.07	97.95±0.09	94.07±0.11
ST Düşmesi		95.86±0.1	96.85±0.08	98.52±0.03	98.88±0.14	96.35±0.07
ST Yükselmesi		94.41±0.08	94.91±0.03	98.04±0.02	98.22±0.01	94.66±0.03
Sağlıklı		91.62±0.49	93.20±0.2	97.07±0.17	97.65±0.06	92.40±0.13
Hastalıklı		94.45±0.14	91.37±0.53	98.15±0.06	97.05±0.17	92.86±0.21
Weighted-cityblok	94.27±0.06	94.23±0.22	95.72±0.09	98.15±0.12	98.34±0.22	95.30±0.19
ST Düşmesi		96.20±0.03	96.93±0.19	98.60±0.05	98.80±0.25	96.65±0.05
ST Yükselmesi		94.60±0.09	95.30±0.08	97.99±0.12	98.01±0.38	94.95±0.27
Sağlıklı		91.50±0.44	95.35±0.03	98.01±0.11	98.25±0.14	94.80±0.21
Hastalıklı		94.64±0.3	95.30±0.08	97.99±0.18	98.29±0.10	94.80±0.21
Topluluk Sınıflandırıcıları Yöntemleri						
Bagged Trees	94.33±0.05	94.43±0.11	94.43±0.18	98.09±0.09	98.58±0.06	95.17±0.03
ST Düşmesi		97.52±0.09	96.51±0.01	99.15±0.04	98.77±0.01	97.01±0.04
ST Yükselmesi		94.85±0.07	95.58±0.01	98.20±0.02	98.45±0.01	98.21±0.03
Sağlıklı		90.40±0.26	95.01±0.33	96.56±0.11	98.27±0.10	92.65±0.02
Hastalıklı		95.19±0.43	90.59±0.38	98.43±0.16	98.83±0.12	92.83±0.01
Subspace K-EYK	94.39±0.01	94.83±0.29	98.81±0.41	98.14±0.33	98.63±0.27	94.68±0.16
ST Düşmesi		97.66±0.42	97.24±0.31	99.18±0.17	99.04±0.13	97.45±0.37
ST Yükselmesi		96.53±0.32	96.13±0.58	98.45±0.41	98.66±0.21	96.33±0.13
Sağlıklı		90.74±0.08	94.37±0.51	96.47±0.41	98.22±0.44	92.29±0.13
Hastalıklı		94.37±0.36	95.48±0.21	98.46±0.32	98.63±0.30	92.65±0.01

Tablo 2.12.'den anlaşılacağı üzere test doğruluğu, duyarlılığı, özgülüğü ve negatif prediktif değeri, F skoru değerleri sırasıyla %89.51 ve %94.97, %89.48 ve % 98.81, %96.25 ve %98.63, %96.24 ve %98.63, %89.09 ve %95.30 değerleri arasında değiştiği görülmektedir. En iyi sınıflandırma sonuçlarının DVM algoritmalarındaki Kubik DVM; K-EYK algoritmalarındaki Weighted (cityblok) K-EYK yönteminde; Topluluk sınıflandırıcıları algoritmalarındaki Subspace K-EYK yönteminde alındığı görülmüştür. Bu sınıflandırma yöntemlerinin doğruluk, duyarlılık, özgülük, negatif prediktif değer ve F skoru değerlerinin en yüksek standart sapma değerleri ise sırasıyla 0.29, 0.41, 0.33, 0.27 ve 0.16'dir. Bahsedilen 3 yöntem arasında en iyi sonuca Subspace K-EYK yönteminde ulaşılmıştır. Bu yöntemin konfüzyon matrisi Tablo 2.13.'de verilmiştir.

Tablo 2.13.CWD esaslı özniteliklerle en iyi sınıflandırma yönteminin konfüzyon matrisi

Gerçek Sonuçlar	Test Sonuçları				Yanlış Negatif	Doğru Negatif
	ST Düşmesi	ST Yükselmesi	Sağlıklı	Hastalıklı		
ST Düşmesi	18539	369	70	45	484	54706
ST Yükselmesi	325	18364	208	126	659	54881
Sağlıklı	37	215	18209	562	814	55036
Hastalıklı	25	121	744	18133	890	55112
Yanlış Pozitif	387	705	1022	733		
Doğru Pozitif	18539	18364	18209	18133		

Tablo 2.14.'de BJD esaslı öznitelikler kullanıldığında önerilen yöntemin performans analizi sonuçları verilmiştir.

Tablo 2.14. Dört sınıf için BJD esaslı özniteliklerle performans analizi sonuçları

Sınıflandırma Yöntemi	Eğitim	Test				
	Doğruluk (%)	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	NPD (%)	F skoru (%)
Destek Vektör Makineleri Yöntemleri						
Kuadratik	85.13±0.12	85.49±0.32	85.22±0.34	94.61±0.10	94.60±0.16	85.33±0.16
ST Düşmesi		86.24±0.45	88.26±0.08	94.74±0.21	95.54±0.31	87.24±0.27
ST Yükselmesi		89.44±0.41	86.24±0.28	96.18±0.02	94.89±0.11	87.84±0.16
Sağlıklı		83.14±0.11	83.19±0.51	93.88±0.02	93.89±0.19	82.94±0.05
Hastalıklı		83.17±0.31	83.19±0.51	93.66±0.15	94.09±0.04	83.30±0.19
Kubik	91.13±0.11	91.25±0.03	91.20±0.13	96.97±0.13	96.91±0.15	91.03±0.15
ST Düşmesi		93.20±0.25	93.30±0.28	97.51±0.28	97.72±0.30	93.14±0.16
ST Yükselmesi		94.50±0.11	93.60±0.06	97.99±0.07	97.62±0.15	94.02±0.11
Sağlıklı		88.39±0.12	89.13±0.03	95.94±0.08	96.17±0.04	88.73±0.10
Hastalıklı		88.70±0.03	88.87±0.15	96.03±0.09	96.15±0.12	88.23±0.22
Fine Gaussian	90.1±0.2	90.20±0.04	90.20±0.21	96.52±0.11	95.90±0.08	90.10±0.05
ST Düşmesi		94.72±0.35	93.73±0.12	98.09±0.14	97.73±0.05	94.22±0.12
ST Yükselmesi		89.09±0.33	96.06±0.45	95.75±0.16	95.53±0.16	92.44±0.04
Sağlıklı		82.81±0.17	94.42±0.21	93.15±0.10	97.95±0.08	88.25±0.01
Hastalıklı		96.70±0.03	76.61±0.06	99.09±0.02	92.39±0.03	85.49±0.03
Medium Gaussain	91.03±0.05	91.43±0.16	91.87±0.15	97.21±0.08	96.97±0.13	91.41±0.18
ST Düşmesi		92.25±0.18	92.83±0.02	97.22±0.08	97.45±0.27	92.54±0.09

Tablo 2.14.'ün devamı

ST Yükselmesi		94.60±0.06	93.02±0.14	98.09±0.02	97.50±0.05	93.80±0.04
Sağlıklı		88.31±0.03	90.96±0.24	95.79±0.08	96.82±0.09	89.62±0.24
Hastalıklı		90.57±0.35	90.69±0.19	97.77±0.12	96.11±0.12	89.67±0.33
K-En Yakın Komşuluk Yöntemleri						
Fine	91.33±0.05	91.20±0.19	91.45±0.16	96.98±0.07	96.99±0.05	91.44±0.14
ST Düşmesi		92.24±0.18	91.99±0.14	97.63±0.07	97.19±0.09	92.61±0.06
ST Yükselmesi		93.21±0.12	94.11±0.07	97.54±0.05	97.88±0.03	93.66±0.09
Sağlıklı		89.93±0.12	89.04±0.27	96.52±0.01	96.19±0.01	89.48±0.19
Hastalıklı		89.41±0.35	90.65±0.15	96.25±0.13	96.71±0.06	90.03±0.21
Medium	91.87±0.11	92.19±0.13	92.09±0.21	97.22±0.07	97.23±0.09	92.09±0.19
ST Düşmesi		93.16±0.13	93.12±0.04	97.58±0.04	97.55±0.06	93.14±0.08
ST Yükselmesi		94.29±0.06	93.85±0.12	97.96±0.02	97.81±0.04	94.07±0.04
Sağlıklı		89.16±0.03	91.99±0.33	96.11±0.09	97.19±0.12	90.56±0.29
Hastalıklı		91.84±0.33	89.39±0.34	97.23±0.11	96.37±0.12	90.60±0.34
Coarse	88.1±0.10	88.53±0.08	88.54±0.18	95.87±0.08	95.86±0.14	85.54±0.10
ST Düşmesi		90.51±0.14	88.73±0.11	96.61±0.06	95.89±0.26	89.61±0.07
ST Yükselmesi		90.37±0.21	90.84±0.22	96.46±0.09	96.64±0.08	90.60±0.05
Sağlıklı		84.47±0.24	87.22±0.08	95.13±0.11	95.43±0.09	86.84±0.14
Hastalıklı		86.84±0.12	87.35±0.32	95.28±0.06	95.47±0.11	87.09±0.15
Kosinüs	91.17±0.06	91.42±0.18	91.41±0.21	96.96±0.10	97.47±0.07	91.41±0.19
ST Düşmesi		91.57±0.09	92.79±0.23	96.97±0.04	97.37±0.05	92.18±0.17
ST Yükselmesi		92.72±0.25	94.07±0.05	97.35±0.11	97.86±0.01	93.39±0.11
Sağlıklı		88.59±0.01	91.59±0.37	95.87±0.12	97.02±0.13	90.07±0.18
Hastalıklı		92.95±0.39	87.21±0.17	97.68±0.14	97.61±0.07	89.99±0.28
Kubik	91.2±0.10	91.30±0.05	91.27±0.13	96.63±0.13	93.83±0.19	92.14±0.12
ST Düşmesi		92.22±0.09	92.01±0.23	97.24±0.13	97.46±0.09	92.14±0.11
ST Yükselmesi		93.50±0.14	92.01±0.21	97.05±0.22	92.03±0.31	97.40±0.06
Sağlıklı		88.35±0.03	92.25±0.04	95.22±0.03	89.79±0.21	89.03±0.26
Hastalıklı		91.25±0.07	88.81±0.03	97.02±0.14	96.03±0.13	90.00±0.02
Weighted-öklid	92.±0.00	92.33±0.09	92.33±0.21	97.31±0.07	97.28±0.11	92.33±0.19
ST Düşmesi		94.21±0.14	92.49±0.09	97.99±0.05	97.23±0.19	93.35±0.11
ST Yükselmesi		93.97±0.11	94.73±0.21	97.84±0.04	98.12±0.07	94.35±0.16
Sağlıklı		89.96±0.24	91.57±0.21	96.45±0.09	97.06±0.07	90.76±0.21
Hastalıklı		91.22±0.23	90.52±31	96.97±0.08	96.71±0.11	90.86±0.27
Weighted-cityblok	92.74±0.06	92.91±0.13	92.89±0.18	97.52±0.04	97.51±0.13	92.91±0.16
ST Düşmesi		95.14±0.13	93.37±0.08	98.31±0.05	97.63±0.27	94.25±0.11
ST Yükselmesi		94.81±0.14	95.49±0.31	98.14±0.04	98.40±0.11	95.15±0.23
Sağlıklı		90.31±0.06	91.88±0.19	96.59±0.02	97.18±0.07	91.09±0.13
Hastalıklı		91.37±0.17	90.82±0.14	97.04±0.06	96.83±0.05	91.15±0.16
Topluluk Sınıflandırıcıları Yöntemleri						
Bagged Trees	92.27±0.06	92.13±0.37	92.47±0.32	97.48±0.27	97.54±0.21	92.64±0.50
ST Düşmesi		93.47±0.44	94.77±0.09	97.78±0.39	98.53±0.04	94.45±0.79
ST Yükselmesi		96.42±0.61	94.30±0.62	98.76±0.23	97.99±0.25	95.34±0.62
Sağlıklı		87.52±0.32	93.34±0.15	95.38±0.14	97.89±0.40	90.53±0.36
Hastalıklı		95.09±0.08	87.47±0.43	97.98±0.31	95.76±0.15	90.24±0.23
Subspace K-EYK	92.47±0.06	92.58±0.06	93.61±0.11	96.32±0.06	97.34±0.12	92.53±0.16
ST Düşmesi		94.07±0.02	94.15±0.19	97.89±0.02	97.88±0.05	94.11±0.09
ST Yükselmesi		95.30±0.13	98.21±0.17	94.21±0.06	97.86±0.13	94.75±0.07
Sağlıklı		88.29±0.02	93.02±0.01	95.70±0.04	97.49±0.17	90.48±0.37
Hastalıklı		92.65±0.07	89.05±0.07	97.47±0.12	96.14±0.12	90.78±0.10

Tablo 2.14.'den anlaşılacağı üzere test doğruluğu, duyarlılığı, özgüllüğü ve negatif prediktif değeri, F skoru değerleri sırasıyla %85.49 ve %92.91, %85.22 ve % 93.61, %94.61 ve %97.52, %93.83 ve %97.54, %85.33 ve %92.91 değerleri arasında değiştiği görülmektedir. En iyi sınıflandırma sonuçlarının DVM algoritmalarındaki Medium Gaussain DVM, K-EYK algoritmalarındaki Weighted (cityblok) K-EYK yönteminde; Topluluk sınıflandırıcıları algoritmalarındaki Subspace K-EYK yönteminde alındığı görülmüştür. Bu sınıflandırma yöntemlerinin doğruluk, duyarlılık, özgüllük, negatif prediktif değer ve F skoru değerlerinin en yüksek standart sapma değerleri ise sırasıyla 0.16, 0.18, 0.08, 0.13 ve 0.18'dir. Bahsedilen 3 yöntem arasında en iyi sonuca Weighted (cityblok) K-EYK yönteminde ulaşılmıştır. Bu yöntemin konfüzyon matrisi Tablo 2.15.'de verilmiştir.

Tablo 2.15. BJD esaslı özniteliklerle en iyi sınıflandırma yönteminin konfüzyon matrisi

Gerçek Sonuçlar	Test Sonuçları				Yanlış Negatif	Doğru Negatif
	ST Düşmesi	ST Yükselmesi	Sağlıklı	Hastalıklı		
ST Düşmesi	17751	798	260	214	1272	52926
ST Yükselmesi	612	18126	136	149	897	52551
Sağlıklı	176	97	17505	1245	1518	53172
Hastalıklı	137	117	1474	17295	1728	53382
Yanlış Pozitif	925	1012	1870	1608		
Doğru Pozitif	17751	18126	17505	17295		

Talo 2.16.'da BD esaslı öznitelikler kullanıldığında önerilen yöntemin performans analizi sonuçları verilmiştir.

Tablo 2.16. Dört sınıf için BD esaslı özneliklerle performans analizi sonuçları

Sınıflandırma Yöntemi	Eğitim	Test			NPD (%)	F skoru (%)
	Doğruluk (%)	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)		
Destek Vektör Makineleri Yöntemleri						
Kuadratik	84.35±0.08	84.51±0.12	84.41±0.30	94.22±0.07	94.21±0.14	84.42±0.22
ST Düşmesi		83.85±0.27	88.94±0.07	93.56±0.12	95.76±0.16	86.32±0.18
ST Yükselmesi		89.65±0.01	83.60±0.59	96.34±0.04	93.93±0.20	86.52±0.32
Sağlıklı		81.93±0.06	82.65±0.52	93.33±0.03	93.63±0.17	82.29±0.29
Hastalıklı		82.61±0.14	82.45±0.01	93.63±0.06	93.56±0.01	82.53±0.07
Kubik	89.90±0.03	89.85±0.23	89.79±0.11	96.36±0.08	96.31±0.14	89.85±0.09
ST Düşmesi		91.30±0.03	92.14±0.16	96.87±0.05	97.20±0.19	91.75±0.06
ST Yükselmesi		93.32±0.09	91.20±0.10	97.54±0.11	96.75±0.10	92.29±0.15
Sağlıklı		86.74±0.19	88.30±0.08	95.21±0.13	95.75±0.21	87.59±0.02
Hastalıklı		88.02±0.07	87.53±0.10	95.80±0.03	95.55±0.05	87.78±0.10
Fine Gaussian	85.70±0.15	87.96±0.28	86.04±0.36	94.49±0.12	95.00±0.12	86.21±0.32
ST Düşmesi		72.30±0.39	96.71±0.05	86.97±0.21	98.70±0.03	82.74±0.28
ST Yükselmesi		95.23±0.15	86.09±0.66	98.35±0.07	94.89±0.21	90.43±0.29
Sağlıklı		88.17±0.45	84.89±0.19	95.79±0.17	94.49±0.07	86.49±0.32
Hastalıklı		96.14±0.13	76.48±0.54	96.87±0.03	91.92±0.16	85.19±0.39
Medium Gaussain	89.80±0.01	89.90±0.09	89.84±0.09	96.31±0.11	96.29±0.14	89.80±0.13
ST Düşmesi		89.07±0.10	92.99±0.05	95.82±0.11	97.46±0.09	91.01±0.12
ST Yükselmesi		94.25±0.03	89.15±0.02	98.01±0.08	96.02±0.17	91.54±0.15
Sağlıklı		86.53±0.13	90.21±0.16	94.89±0.22	96.23±0.14	88.24±0.20
Hastalıklı		89.74±0.16	87.03±0.12	96.52±0.02	95.43±0.16	88.42±0.04
K-En Yakın Komşuluk Yöntemleri						
Fine	89.74±0.12	89.77±0.03	89.75±0.23	96.34±0.04	96.26±0.13	89.77±0.13
ST Düşmesi		90.86±0.04	90.06±0.06	96.74±0.02	96.45±0.36	90.46±0.02
ST Yükselmesi		91.40±0.07	91.23±0.39	96.89±0.01	96.83±0.14	91.32±0.2
Sağlıklı		88.83±0.26	87.76±0.06	96.09±0.09	95.68±0.02	88.29±0.16
Hastalıklı		87.98±0.01	89.98±0.41	95.63±0.03	96.09±0.01	89.03±0.12
Medium	90.54±0.06	90.58±0.13	90.59±0.22	96.66±0.05	95.42±0.07	89.85±0.14
ST Düşmesi		90.11±0.14	92.67±0.19	96.37±0.01	97.40±0.06	91.37±0.11
ST Yükselmesi		93.85±0.19	89.85±0.17	97.89±0.08	96.41±0.04	91.81±0.01
Sağlıklı		88.26±0.24	90.87±0.13	95.74±0.09	96.75±0.05	89.54±0.19
Hastalıklı		90.35±0.08	88.96±0.38	96.65±0.02	91.12±0.13	86.65±0.23
Coarse	86.70±0.04	86.60±0.08	85.62±0.08	95.06±0.10	95.05±0.18	86.61±0.1
ST Düşmesi		87.05±0.03	88.43±0.13	95.11±0.02	95.76±0.21	87.72±0.06
ST Yükselmesi		90.51±0.09	85.49±0.04	96.52±0.20	94.65±0.16	87.90±0.09
Sağlıklı		85.27±0.19	85.49±0.10	94.54±0.14	94.63±0.21	85.39±0.11
Hastalıklı		84.01±0.01	87.05±0.03	94.05±0.03	95.19±0.13	85.44±0.05
Kosinüs	89.67±0.58	89.57±0.12	89.97±0.17	96.43±0.07	95.26±0.08	89.98±0.06
ST Düşmesi		88.65±0.11	92.59±0.09	95.76±0.04	92.65±0.04	90.58±0.09
ST Yükselmesi		90.58±0.01	90.06±0.19	97.37±0.06	96.43±0.05	91.26±0.04
Sağlıklı		87.70±0.13	90.36±0.12	95.51±0.06	96.55±0.11	89.01±0.05
Hastalıklı		91.32±0.23	86.89±0.27	97.07±0.12	95.42±0.09	89.06±0.03

Tablo 2.16.'nın devamı

Cubic	89.8±0.01	89.65±0.06	89.61±0.13	96.26±0.09	96.29±0.08	89.65±0.09
ST Düşmesi		89.00±0.03	91.63±0.09	95.84±0.10	96.99±0.18	90.21±0.14
ST Yükselmesi		92.50±0.05	88.75±0.10	97.45±0.13	96.01±0.02	90.79±0.04
Sağlıklı		87.50±0.08	90.03±0.19	95.39±0.09	96.38±0.10	88.72±0.13
Hastalıklı		89.60±0.06	88.01±0.12	96.34±0.04	95.77±0.03	88.87±0.02
Weighted-öklid	90.94±0.06	90.76±0.10	90.75±0.13	96.67±0.09	96.73±0.04	90.80±0.07
ST Düşmesi		91.68±0.05	91.53±0.21	97.02±0.07	97.00±0.01	91.62±0.09
ST Yükselmesi		93.13±0.13	91.48±0.14	97.52±0.11	96.98±0.05	92.39±0.04
Sağlıklı		88.85±0.17	90.01±0.12	96.01±0.04	96.49±0.02	89.47±0.05
Hastalıklı		89.50±0.05	89.99±0.04	96.13±0.13	96.43±0.09	89.71±0.08
Weighted-cityblok	91.70±0.02	91.74±0.03	91.61±0.13	97.04±0.09	95.43±0.09	91.58±0.13
ST Düşmesi		93.20±0.09	92.75±0.15	97.60±0.02	97.48±0.17	93.02±0.07
ST Yükselmesi		94.40±0.04	93.01±0.08	98.01±0.12	97.48±0.06	93.60±0.15
Sağlıklı		89.09±0.12	90.43±0.14	96.13±0.04	96.62±0.08	89.65±0.10
Hastalıklı		90.03±0.07	90.24±0.12	96.42±0.16	90.13±0.05	90.05±0.19
Topluluk Sınıflandırıcıları Yöntemleri						
Bagged Trees	90.9±0.01	91.07±0.04	91.08±0.29	96.60±0.10	96.87±0.13	91.09±0.06
ST Düşmesi		91.06±0.07	94.27±0.28	96.69±0.04	97.96±0.33	92.65±0.05
ST Yükselmesi		95.29±0.24	91.82±0.29	98.36±0.09	97.08±0.01	93.53±0.04
Sağlıklı		85.91±0.24	92.49±0.16	94.71±0.12	97.31±0.06	89.07±0.06
Hastalıklı		92.73±0.31	85.73±0.42	96.64±0.12	95.13±0.12	89.09±0.08
Subspace K-EYK	91.37±0.06	91.52±0.09	91.44±0.21	96.98±0.04	95.90±0.07	91.47±0.12
ST Düşmesi		91.80±0.01	93.59±0.19	97.03±0.01	93.41±0.09	92.69±0.11
ST Yükselmesi		94.63±0.08	91.72±0.29	98.14±0.04	97.07±0.10	93.16±0.09
Sağlıklı		87.66±0.18	92.29±0.11	95.47±0.07	97.26±0.04	89.92±0.12
Hastalıklı		91.98±0.09	88.15±0.26	97.31±0.03	95.86±0.02	90.13±0.14

Tablo 2.16.'dan anlaşılacağı üzere test doğruluğu, duyarlılığı, özgüllüğü ve negatif prediktif değeri, F skoru değerleri sırasıyla %84.51 ve %91.52, %84.41 ve % 91.61, %94.22 ve %96.98, %94.21 ve %96.87, %84.42 ve %91.58 değerleri arasında değiştiği görülmektedir. En iyi sınıflandırma sonuçlarının DVM algoritmalarındaki Medium Gaussain DVM; K-EYK algoritmalarındaki Weighted (cityblok) K-EYK yönteminde; Topluluk sınıflandırıcıları algoritmalarındaki Subspace K-EYK yönteminde alındığı görülmüştür. Bu sınıflandırma yöntemlerinin doğruluk, duyarlılık, özgüllük, negatif prediktif değer ve F skoru değerlerinin en yüksek standart sapma degerleriye sırasıyla 0.09, 0.21, 0.11, 0.14 ve 0.13'dür. Bahsedilen 3 yöntem arasında en iyi sonuca Weighted (cityblok) K-EYK yönteminde ulaşılmıştır. Bu yöntemin konfüzyon matrisi Tablo 2.17.'de verilmiştir.

Tablo 2.17. BD esaslı özniteliklerle en iyi sınıflandırma yönteminin konfüzyon matrisi

Gerçek Sonuçlar	Test Sonuçları				Yanlış Negatif	Doğru Negatif
	ST Düşmesi	ST Yükselmesi	Sağlıklı	Hastalıklı		
ST Düşmesi	17673	811	308	231	1350	52132
ST Yükselmesi	943	17709	180	191	1314	52096
Sağlıklı	196	136	17230	1461	1793	52575
Hastalıklı	132	95	1603	17193	1830	52612
Yanlış Pozitif	1271	1042	2091	1883		
Doğru Pozitif	17673	17709	17230	17193		

Talo 2.18.'de ZAMD esaslı öznitelikler kullanıldığında önerilen yöntemin performans analizi sonuçları verilmiştir.

Tablo 2.18. Dört sınıf için ZAMD esaslı özniteliklerle performans analizi sonuçları

Sınıflandırma Yöntemi	Eğitim	Test			NPD (%)	F skoru (%)
	Doğruluk (%)	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)		
Destek Vektör Makineleri Yöntemleri						
Kuadratik	88.80±0.15	89.17±0.17	89.06±0.18	96.07±0.08	96.09±0.09	89.05±0.14
ST Düşmesi		86.79±0.15	92.64±0.12	94.92±0.07	97.31±0.04	89.62±0.14
ST Yükselmesi		93.09±0.07	86.13±0.31	97.69±0.03	95.12±0.12	89.48±0.15
Sağlıklı		88.36±0.04	88.63±0.03	95.82±0.03	95.92±0.13	88.49±0.15
Hastalıklı		88.42±0.43	88.81±0.23	95.84±0.19	95.98±0.07	88.62±0.11
Kubik	93.25±0.22	93.59±0.16	93.72±0.16	97.76±0.06	97.80±0.06	93.65±0.15
ST Düşmesi		93.44±0.13	93.44±0.14	97.72±0.05	97.71±0.05	93.43±0.13
ST Yükselmesi		93.57±0.20	94.84±0.15	97.72±0.08	98.18±0.05	94.20±0.17
Sağlıklı		95.21±0.18	93.50±0.25	98.35±0.06	97.73±0.09	94.35±0.21
Hastalıklı		92.14±0.10	93.11±0.11	97.25±0.03	97.60±0.04	92.62±0.10
Fine Gaussian	90.20±0.15	92.27±0.17	90.70±0.16	96.80±0.08	96.77±0.07	90.87±0.16
ST Düşmesi		97.70±0.09	89.64±0.14	99.23±0.04	96.24±0.05	93.49±0.12
ST Yükselmesi		96.44±0.11	93.77±0.20	98.73±0.04	97.74±0.08	95.09±0.05
Sağlıklı		76.43±0.39	98.65±0.1	89.67±0.2	99.49±0.05	86.13±0.29
Hastalıklı		98.52±0.08	80.74±0.21	99.57±0.03	93.61±0.07	88.75±0.16
Medium Gaussain	92.70±0.28	93.10±0.21	93.03±0.25	97.56±0.09	97.56±0.09	93.03±0.11
ST Düşmesi		91.17±0.40	95.12±0.23	96.78±0.17	98.27±0.08	93.09±0.11
ST Yükselmesi		95.74±0.27	90.95±0.51	98.58±0.11	96.88±0.17	93.28±0.15

Tablo 2.18.'in devamı

Sağlıklı		91.54±0.14	94.47±0.02	96.95±0.05	98.05±0.01	92.98±0.08
Hastalıklı		93.96±0.02	91.58±0.21	97.94±0.02	97.09±0.07	92.76±0.10
K-En Yakın Komşuluk Yöntemleri						
Fine	94.20±0.14	94.25±0.23	94.24±0.13	98.00±0.09	97.97±0.09	94.25±0.14
ST Düşmesi		95.23±0.22	95.39±0.08	98.33±0.09	98.39±0.03	95.31±0.06
ST Yükselmesi		95.72±0.13	95.10±0.09	98.51±0.05	98.29±0.03	95.41±0.10
Sağlıklı		92.98±0.39	93.25±0.01	97.58±0.15	97.67±0.01	93.12±0.19
Hastalıklı		93.07±0.18	93.24±0.33	97.61±0.05	97.53±0.28	93.16±0.20
Medium	94.15±0.07	94.08±0.16	93.79±0.12	98.03±0.07	97.97±0.11	94.19±0.26
ST Düşmesi		94.11±0.05	95.87±0.06	97.91±0.02	98.35±0.29	94.53±0.65
ST Yükselmesi		93.31±0.04	92.20±0.14	98.74±0.01	97.99±0.05	95.24±0.09
Sağlıklı		93.94±0.40	95.17±0.02	97.13±0.16	98.31±0.01	93.53±0.22
Hastalıklı		94.99±0.15	91.94±0.27	98.33±0.06	97.25±0.09	93.44±0.07
Coarse	90.45±0.21	91.01±0.29	90.98±0.28	96.81±0.12	96.81±0.10	90.99±0.13
ST Düşmesi		90.73±0.21	91.85±0.07	96.67±0.08	97.09±0.03	91.29±0.14
ST Yükselmesi		93.01±0.09	90.99±0.36	97.56±0.03	96.81±0.13	91.99±0.23
Sağlıklı		88.97±0.45	91.69±0.25	95.99±0.19	97.04±0.09	90.31±0.11
Hastalıklı		91.34±0.41	89.39±0.44	97.01±0.17	96.28±0.14	90.36±0.03
Kosinüs	93.65±0.22	94.01±0.14	93.95±0.10	97.47±0.06	97.91±0.04	93.95±0.03
ST Düşmesi		93.38±0.03	95.94±0.01	95.94±0.01	98.57±0.01	94.64±0.02
ST Yükselmesi		95.73±0.06	94.13±0.04	98.53±0.03	97.96±0.02	94.92±0.01
Sağlıklı		91.25±0.28	95.31±0.12	96.84±0.11	98.36±0.04	93.24±0.03
Hastalıklı		95.69±0.16	90.40±0.22	98.59±0.06	96.75±0.07	92.97±0.05
Kubik	93.75±0.08	93.85±0.18	93.81±0.15	97.85±0.08	97.86±0.07	93.82±0.13
ST Düşmesi		93.60±0.08	95.32±0.03	97.73±0.03	98.36±0.09	94.45±0.06
ST Yükselmesi		95.76±0.1	93.71±0.20	98.55±0.04	97.82±0.07	94.73±0.13
Sağlıklı		91.42±0.40	94.67±0.04	96.93±0.16	98.14±0.02	93.02±0.23
Hastalıklı		94.64±0.14	91.55±0.31	98.20±0.06	97.11±0.10	93.07±0.10
Weighted-öklid	94.45±0.22	94.73±0.14	94.71±0.12	98.16±0.06	98.22±0.09	94.70±0.10
ST Düşmesi		95.40±0.05	95.65±0.03	98.38±0.02	98.49±0.01	95.51±0.04
ST Yükselmesi		96.24±0.16	95.35±0.05	98.71±0.06	98.56±0.26	95.79±0.10
Sağlıklı		92.61±0.32	94.97±0.2	97.40±0.12	98.26±0.01	93.76±0.16
Hastalıklı		94.67±0.02	92.85±0.20	98.21±0.02	97.56±0.07	93.75±0.09
Weighted-cityblok	94.85±0.21	95.09±0.17	95.08±0.15	98.31±0.07	98.31±0.04	95.08±0.15
ST Düşmesi		95.85±0.19	96.02±0.14	98.56±0.07	98.62±0.05	95.93±0.16
ST Yükselmesi		96.54±0.05	95.91±0.09	98.81±0.02	98.58±0.04	96.23±0.03
Sağlıklı		92.92±0.38	95.30±0.11	97.52±0.15	98.38±0.04	94.10±0.25
Hastalıklı		95.05±0.04	93.07±0.27	98.35±0.02	97.65±0.01	94.06±0.16
Topluluk Sınıflandırıcıları Yöntemleri						
Bagged Trees	93.55±0.08	93.98±0.21	93.91±0.09	96.14±0.08	97.89±0.04	93.90±0.13
ST Düşmesi		94.57±0.06	95.32±0.04	95.09±0.03	98.36±0.02	94.94±0.01
ST Yükselmesi		95.66±0.28	94.57±0.05	94.50±0.10	98.10±0.02	95.11±0.12
Sağlıklı		90.34±0.20	95.56±0.07	96.48±0.08	98.44±0.03	92.88±0.14
Hastalıklı		95.34±0.30	90.18±0.19	98.48±0.10	96.67±0.07	92.69±0.25
Subspace K-EYK	94.25±0.22	94.47±0.19	94.43±0.15	98.07±0.07	98.08±0.05	94.43±0.15
ST Düşmesi		95.30±0.12	95.48±0.19	98.36±0.04	98.43±0.06	95.39±0.15
ST Yükselmesi		95.79±0.32	95.33±0.11	98.54±0.11	98.37±0.04	95.56±0.21
Sağlıklı		91.50±0.29	95.50±0.05	96.95±0.12	98.43±0.02	93.46±0.13
Hastalıklı		95.28±0.02	91.39±0.22	98.44±0.01	97.08±0.07	93.30±0.11

Tablo 2.18.'den anlaşılacağı üzere test doğruluğu, duyarlılığı, özgüllüğü ve negatif prediktif değeri, F skoru değerleri sırasıyla %89.17 ve %95.09, %89.06 ve % 95.08, %96.07 ve %98.31, %96.09 ve %98.31, %89.05 ve %95.08 değerleri arasında değiştiği görülmektedir. En iyi sınıflandırma sonuçlarının DVM algoritmalarındaki Kubik DVM; K-EYK algoritmalarındaki Weighted (cityblok) K-EYK yönteminde; Topluluk sınıflandırıcıları algoritmalarındaki Subspace K-EYK yönteminde alındığı görülmüştür. Bu sınıflandırma yöntemlerinin doğruluk, duyarlılık, özgüllük, negatif prediktif değer ve F skoru değerlerinin en yüksek standart sapma degerleriye sırasıyla 0.19, 0.16, 0.07, 0.06 ve 0.15'dür. Bahsedilen 3 yöntem arasında en iyi sonuca Weighted (cityblok) K-EYK yönteminde ulaşılmıştır. Bu yöntemin konfüzyon matrisi Tablo 2.19.'da verilmiştir.

Tablo 2.19. ZAMD esaslı özniteliklerle en iyi sınıflandırma yönteminin konfüzyon matrisi

Gerçek Sonuçlar	Test Sonuçları				Yanlış Negatif	Doğru Negatif
	ST Düşmesi	ST Yükselmesi	Sağlıklı	Hastalıklı		
ST Düşmesi	18248	492	152	131	775	54019
ST Yükselmesi	536	18234	176	77	789	54033
Sağlıklı	114	75	18116	718	907	54151
Hastalıklı	165	80	1109	17669	1354	54598
Yanlış Pozitif	815	647	1437	926		
Doğru Pozitif	18248	18234	18116	17669		

Tez çalışmasının ilk aşaması olan 2 sınıflı problem için en iyi performans sonuçları Choi-Williams zaman frekans dağılımında Bagged Tree sınıflandırma yönteminde alınmıştır. Sırasıyla doğruluk, duyarlılık, özgüllük ve pozitif prediktif değer %99.06, %99.08, %99.02 ve %99.02 olarak bulunmuştur. 4 sınıflı problem için en iyi performans sonuçları ZAMD dağılımında Weighted (cityblok) K-EYK sınıflandırma yönteminde alınmıştır. Sırasıyla doğruluk, duyarlılık, özgüllük ve negatif prediktif değer, F skoru %95.09, %95.08, %98.31, %98.31 ve %95.08 olarak bulunmuştur. Önerilen algoritmalar geliştirilmekte olan Teletıp sisteminin bir parçası olacağı için hesaplama süresi de önemli bir faktördür. Algoritmanın hesaplama süresi öznitelik çıkarma için geçen süre ve test süresi toplanarak bulanabilmektedir. Bir R-R aralığı için öznitelik çıkarma süresi 2 sınıflı

problem için CWD kullanıldığında; MIT-BIH Aritmi veritabanında 2.41 saniye iken European ST-T veritabanı için 0.61 saniyedir. 4 sınıflı problem için ZAMD dağılımı kullanıldığında; MIT-BIH Aritmi veritabanında 1.3 saniye, European ST-T veritabanında 0.66 saniye ve Long Term ST veritabanındaysa 1.65 saniyedir. Test süresi oldukça düşük olduğu için ihmal edilebilir. Çalışmada öz nitelik çıkarma süreleri hesaplanırken kullanılan bilgisayarın işlemcisi 64 bit Intel® Core, 998 MHz RAM'i ise 4,00 GB'dır. Bu hesaplama sürelerinin toplamı göz önüne alındığında; en yüksek değer yaklaşık 2 kalp atımı için gerekli süre kadardır. Her iki yöntemde de hesaplama sürelerinin oldukça düşük olması önerilen algoritmanın Teletıp sistemleri için oldukça uygun olduğunu göstermektedir. Tablo 2.20.'de önerilen yöntemlerin diğer çalışmalarla karşılaştırılması verilmiştir. Tablo 2.20.'de olan [36, 37, 38, 39] çoklu sınıflı çalışmalardır.

Tablo 2.20.Önerilen yöntemlerin diğer çalışmalarla karşılaştırılması

Yazar	Veritabanı	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	PPD(%)
[18]	PTB 148 aritmi ve 52 sağlıklı veri	94.4	-	-	-
[19]	European ST-T aritmi veya sağlıklı 86.384 kalp atımı	-	87	93	-
[20]	PTB	96	93	99	-
[21]	Long Term ST-T	-	89	-	85
[22]	Long Term ST 86 veri	-	78.9	-	80.7
	European ST-T	-	81.3	-	89.2
[23]	European ST-T 86.384 sağlıklı ve iskemik atım	-	91	91	-
[24]	European ST-T 14 veri aritmi MIT-BIH Aritmi 24 veri normal	-	100	-	93.33
[25]	European ST-T	-	87.5	-	93.3
[26]	European ST-T veritabanı 10 veri 43.876 ST segmenti	-	98.12	98.16	-

Tablo 2.20.'nin devamı

[27]	PTB 52 sağlıklı veri Charleston Area Medical Center veritabanı 51 tane iskemik veri	-	99.5	99.4	-
[28]	Charleston Area Medical Center veritabanı 80 tane iskemik veri	-	90.5	92.6	-
[29]	Long Term ST 86 veri European ST-T	- -	93.7 83.3	- -	74.91 77.31
[30]	European ST-T 17.314 normal ve iskemik atım	90.1	-	-	-
[31]	589 ST ve 393 T bölümü	-	92.02	-	93.77
[32]	National Institute of Technology Calicut 2282 normal ve 718 iskemik atım	95	-	-	-
[33]	European ST-T 367 iskemik ST bölümü	-	94.1	92.3	-
[34]	Long-Term ST 1130 iskemik ST segmenti ve 234 iskemik olmayan ST segmenti	90	91	85	-
[35]	PTB 485.753 iskemik atım 125.652 normal atım	98.8	99.45	96.27	-
[36]	PTB 20.160 atım	%98.3	%90	%90	-
[37]	124 tane veri	-	84.6	90	-
[38]	290 tane veri	-	81.3	-	-
[39]	Catholic Üniversitesi 539 atım	-	78.25	-	-
Önerilen Yöntem(2 sınıflı)	European ST-T ve MIT-BIH Aritmi	99.06	99.08	99.02	99.02
Önerilen Yöntem(4 sınıflı)	European ST-T, MIT-BIH Aritmi ve LongTerm ST	95.09	95.08	98.31	-

Tablo 2.20.'den anlaşılacağı üzere tez çalışmasının ilk aşaması olan 2 sınıflı problem için sadece bir çalışmanın [24] duyarlılık değeri önerilen yöntemden daha yüksektir. Aynı zamanda bu çalışmanın pozitif prediktif değeri önerilen yöntemle göre oldukça düşüktür. Tez çalışmalarının 2. aşaması olan 4 sınıflı problem için Tablo 2.20.'de çoklu sınıf içeren çalışmalarla kıyaslanma yapıldığında sadece bir çalışmanın [36] doğruluk değeri önerilen yöntemle göre yüksektir. Diğer çoklu sınıf çalışmaların performans analizi sonuçları önerilen yöntemle göre oldukça düşüktür. Aynı zamanda her iki çalışmada hesaplama süreleri hakkında bilgiye yer verilmemiştir.



3.SONUÇLAR VE TARTIŞMA

EKG işaretinde ST segmentinin yükselmesinin veya düşmesinin erken tespit edilmesi kalp krizinin önlenmesi açısından oldukça önemlidir. Bu amaçla bu tez çalışmasında kalp krizinin önceden tespit edebilmek amacıyla zaman frekans dağılımlarına dayalı algoritmalar geliştirilmiştir. Bu zaman frekans dağılımları geleneksel zaman frekans dağılımlarından farklı ve azaltılmış girişim dağılımları olarak seçilmiştir. Bu dağılımlar kuadratik zaman frekans dağılımları olan; Yumuşatılmış Wigner Ville, Choi-Williams, Born-Jordan, Bessel ve Zhao-Atlas-Mark dağılımlarıdır.

Tez çalışmasının ilk aşaması olan; EKG ST segmenti değişimleri içeren R-R aralıklarının (yükselme veya düşme) normal veya hastalıklı R-R aralıklarından ayırt etme, aşamasında yapılan deneyler sonucunda en iyi sınıflandırma sonuçlarına Choi-Williams dağılımı tabanlı öznelikler kullanıldığında ulaşılmıştır. Tez çalışmasının ikinci aşaması olan ST segmenti yükselmesi, ST segmenti düşmesi, hastalıklı ve sağlıklı EKG R-R aralıklarını sınıflandırma aşamasındaysa en iyi sonuçlara Zhao-Atlas Mark dağılımı tabanlı öznelikler kullanıldığında ulaşılmıştır. Bu dağılımlar sonucunda elde edilen öznelikler Ağaç Yöntemleri, DVM, K-EYK ve Topluluk sınıflandırıcı yöntemleri kullanılarak önerilen algoritmaların performans analizleri yapılmıştır. Tez çalışmalarının birinci ve ikinci aşamaları için de en iyi sınıflandırma sonuçları Weighted K-EYK (cityblok) yönteminde elde edilmiştir. Tez çalışmasının ilk aşaması olan 2 sınıflı veriler için DVM iyi sonuçlar vermekteyken 4 sınıf olan ikinci aşamadaysa KEYK sınıflandırma yöntemleri daha iyi sonuçlar vermiştir. Genel olarak sağlıklı EKG R-R aralıklarının tespit edilme sonuçlara daha düşük çıkmıştır. Sınıflandırma performans sonuçlarının standart sapma değerleri oldukça düşük çıkmıştır. Bu da önerilen yöntemlerin kararlı bir şekilde çalıştığını göstermektedir.

Literatürdeki diğer çalışmalarla kıyaslandığında önerilen algoritmaların performans sonuçları oldukça yüksektir. Ayrıca literatürdeki birçok çalışmaya göre daha büyük veritabanı kullanılmıştır. Seçilen veritabanlarındaki veriler farklı hastalara ait olup birden fazla derivasyon içermektedir. Böylece önerilen algoritmanın derivasyona ve kişiye bağımlılığı da azaltılmıştır. Önerilen yöntemler güncel yaklaşımlar olup geliştirilmekte olan Teletıp Sistemin bir parçası olabilecek düzeydedir. Aynı zamanda önerilen algoritmalarının hızı da Teletıp sistemleri için uygundur.

4.ÖNERİLER

Çalışmada çıkarılan öznitelik sayısı Temel Bileşenlerin Analizi gibi yöntemler kullanılarak aza indirgenebilir. Bu şekilde hesaplama süresi ve performans sonuçları değişebilir.

Öznitelik çıkarma aşamasında kullanılan zaman frekans dağılımları için farklı pencereler seçilip performans değerlendirmesi yapılabilir.

Sınıflandırma yöntemleri için farklı parametreler seçilerek performans sonuçları artırılabilir.

Yöntemde kullanılan algoritma matlab ortamında optimize edilmeyen kodlarla geliştirilmiştir. C programlama dili kullanılarak hesaplama süresi daha da kısaltılabilir.

Önerilen algoritmaların performans değerlendirmesi V1, V2, V3, V4 ve V5 derivasyonlarında EKG işaretlerinde yapılmıştır. Ekstremiter derivasyonlar içeren EKG verileri ve hastanın yaşı özelliği de çalışmaya eklenebilir.

Çalışma sırasında geliştirilen yaklaşımın bir bölümüne dayanan 3 adet bildiri, CMBEBIH 2017 [73], SIU 2017, BIYOMUT 2016 konferanslarında sunulmuştur. SIU 2017 ve BIYOMUT 2016'da sunulan bildiriler henüz yayınlanmadığı için referanslara eklenmemiştir.

5.KAYNAKLAR

1. Dupre, A., Vieau, S., ve Iaizzo, P. A., Basic ECG theory, recordings, and interpretation, Handbook of cardiac anatomy, physiology, and devices, (2005) 191-201.
2. http://www.who.int/cardiovascular_diseases/en, 10 Mayıs 2017.
3. Goldberger, Ary L., Clinical electrocardiography: a simplified approach, Eighth Edition, Elsevier Health Sciences, 2012.
4. Khan, M. G., İlerigelen, B. ve Avcı, B. K., Hızlı EKG yorumu, İstanbul Medikal Yayıncılık, 2007.
5. http://www.physiologyweb.com/lecture_notes/neuronal_action_potential/neuronal_action_potential_important_features.html, 25 Nisan 2017.
6. Thaler, M. S., The only EKG book you'll ever need, Lippincott Williams & Wilkins 2010.
7. <http://a-fib.com/treatments-for-atrial-fibrillation/diagnostic-tests/the-ekg-signal/>, 15 Mart 2017.
8. de Luna, A. B., Electrocardiografía clínica, 15, Univ. Autònoma de Barcelona, 1994.
9. Bowbrick, S., ve Borg, A. N., ECG complete, Elsevier Health Sciences, 2006.
10. http://www.dcbiomed.com/proimages/materials/EKG_Introduction/portableEKG_weritere_Informationen.pdf, 29 Nisan 2017
11. Sajjan, M., Learn ECG in a Day: A Systematic Approach, JP Medical Ltd, 2012.
12. Chan, A. Y., Biomedical device technology: principles and design, Charles C Thomas Publisher, 2016.
13. <http://yorkcardiology.co.uk/electrocardiogram-ecg/>, 11 Nisan 2017
14. Jones, S. A., ECG notes: Interpretation and management guide, FA Davis, 2009.
15. Foster, D. B., Twelve-lead electrocardiography: Theory and interpretation, Springer Science and Business Media, 2007.
16. Edhouse, J., Brady, W. J. ve Morris, F., Acute myocardial infarction, British Medical Journal, 324,7343 (2002), 963.

17. Papaloukas, C., Fotiadis, D. I., Liavas, A. P., Likas, A., ve Michalis L.K., A knowledge-based technique for automated detection of ischaemic episodes in long duration electrocardiograms, Medical and Biological Engineering and Computing, 39,1 (2001) 105-112.
18. Liu, B., Liu, J., Wang, G., Huang, K., Li, F., Zheng, Y., ve Zhou, F., A novel electrocardiogram parameterization algorithm and its application in myocardial infarction detection, Computers in Biology and Medicine, 61 (2015) 178-184.
19. Exarchos, T. P., Papaloukas, C., Fotiadis, D. I., ve Michalis, L. K., An association rule mining-based methodology for automated detection of ischemic ECG beats, IEEE Transactions on Biomedical Engineering, 53,8 (2006) 1531-1540.
20. Sharma, L. N., Tripathy, R. K., ve Dandapat, S., Multiscale energy and eigenspace approach to detection and localization of myocardial infarction, IEEE Transactions on Biomedical Engineering, 62,7 (2015) 1827-1837.
21. Tang, X., Xia, L., Liu, W., Peng, Y., Gao, T., ve Zeng, Y., An approach to determine myocardial ischemia by hidden Markov models, Computer Methods in Biomechanics and Biomedical engineering, 15,10 (2012) 1065-1070.
22. Smrdel, A., ve Jager, F., Automated detection of transient ST-segment episodes in 24h electrocardiograms, Medical and Biological Engineering and Computing, 42,3 (2004) 303-311.
23. Goletsis, Y., Papaloukas, C., Fotiadis, D. I., Likas, A., ve Michalis, L. K., Automated ischemic beat classification using genetic algorithms and multicriteria decision analysis, IEEE transactions on Biomedical Engineering, 51,10 (2004) 1717-1725.
24. Al-Fahoum, A., Al-Fraihat, A., ve Al-Araida, A., Detection of cardiac ischaemia using bispectral analysis approach, Journal of Medical Engineering and Technology, 38,6 (2014) 311-316.
25. Ranjith, P., Baby, P. C., ve Joseph, P., ECG analysis using wavelet transform: application to myocardial ischemia detection, ITBM-RBM, 24,1 (2003) 44-47.
26. Kumar, A., ve Singh, M., Ischemia detection using isoelectric energy function, Computers in Biology and Medicine, 68 (2016) 76-83.
27. Correa, R., Arini, P., Correa, L., Valentinuzzi, M., ve Laciari, E., Analysis of vectorcardiographic dynamic changes in patients with acute myocardial ischemia, Journal of Physics, 447,1 (2013) 012032-12040.
28. Correa, R., Arini, P. D., Correa, L. S., Valentinuzzi, M., ve Laciari, E., Novel technique for ST-T interval characterization in patients with acute myocardial ischemia, Computers in Biology and Medicine, 50 (2014) 49-55.

29. Dranca, L., Goni, A., ve Illarramendi, A., Real-time detection of transient cardiac ischemic episodes from ECG signals, Physiological Measurement, 30,9 (2009) 983.
30. Xu, M., Wei, S., Qin, X., Zhang, Y., ve Liu, C., Rule-based method for morphological classification of ST segment in ECG signals, Journal of Medical and Biological Engineering, 35,6 (2015) 816-823.
31. Papaloukas, C., Fotiadis, D. I., Likas, A., Stroumbis, C. S., ve Michalis, L. K., Use of a novel rule-based expert system in the detection of changes in the ST segment and the T wave in long duration ECGs, Journal of Electrocardiology, 35,1 (2002) 27-34.
32. Jayachandran, E. S., Analysis of myocardial infarction using discrete wavelet transform, Journal of Medical Systems, 34,6 (2010) 985-992.
33. Park, J., Pedrycz, W., ve Jeon, M., Ischemia episode detection in ECG using kernel density estimation, support vector machine and feature selection, Biomedical Engineering Online, 11,1 (2012) 30.
34. Amon, M., ve Jager, F., Electrocardiogram ST-Segment Morphology Delineation Method Using Orthogonal Transformations, PloS One, 11,2 (2016) e0148814.
35. Acharya, U. R., Fujita, H., Sudarshan, V. K., Oh, S. L., Adam, M., Koh, J. E., ve Poo, C. K., Automated detection and localization of myocardial infarction using electrocardiogram: a comparative study of different leads, Knowledge-Based Systems, 99 (2016) 146-156.
36. Arif, M., Malagore, I. A., ve Afsar, F. A., Detection and localization of myocardial infarction using k-nearest neighbor classifier, Journal of Medical Systems, 36,1 (2012) 279-289.
37. Lu, H. L., Ong, K., ve Chia, P., An automated ECG classification system based on a neuro-fuzzy system, Computers in Cardiology, 27 (2000) 387-390.
38. Nugent, C. D., Webb, J. A. C., ve Black, N. D., Feature and classifier fusion for 12-lead ECG classification, Medical Informatics and the Internet in Medicine, 25,3 (2000) 225-235.
39. Bozzola, P., Bortolan, G., Combi, C., Pinciroli, F., ve Brohet, C., A hybrid neuro-fuzzy system for ECG classification of myocardial infarction, Computers in Cardiology, (1996) 241-244.
40. <http://physionet.org/physiobank/database/#ecg>, 12 Mart 2017
41. Jager, F., Taddei, A., Moody, G. B., Emdin, M., ve Antolič, G., Long-term ST database: a reference for the development and evaluation of automated ischaemia detectors and for the study of the dynamics of myocardial ischaemia, Medical and Biological Engineering and Computing, 41,2 (2003) 172-182.

42. Silva, I., ve Moody, G. B., An open-source toolbox for analysing and processing physionet databases in matlab and octave, Journal of open research software, 2,1 (2014).
43. Wigner, E., On the quantum correction for thermodynamic equilibrium, Physical review, 40,5 (1932) 749.
44. Ville, J. D., Théorie et applications de la notion de signal analytique, Cables et transmission, 2,1 (1948) 61-74.
45. Cohen, L., Time-frequency analysis, 778, Englewood Cliffs, NJ Prentice Hall PTR, 1995.
46. Pachori, R. B., ve Sircar, P., A new technique to reduce cross terms in the Wigner distribution, Digital Signal Processing, 17,2 (2007) 466-474.
47. Stankovic, L. J., ve Katkovnik, V., The Wigner distribution of noisy signals with adaptive time-frequency varying window, IEEE Transactions on Signal Processing 47,4 (1999) 1099-1108.
48. Choi, H. I., ve Williams, W. J., Improved time-frequency representation of multicomponent signals using exponential kernels, IEEE Transactions on Acoustics, Speech, and Signal Processing, 37,6 (1989) 862-871.
49. Guo, Z. Durand, L. G. ve Lee, H. C., The time-frequency distributions of nonstationary signals based on a Bessel kernel, IEEE Transactions on Signal Processing, 42,7 (1994) 1700-1707.
50. Jeong, J. ve Williams, W. J., Kernel design for reduced interference distributions, IEEE Transactions on Signal Processing, 40,2 (1992) 402-412.
51. Zhao, Y. Atlas, L. E. ve Marks, R. J., The use of cone-shaped kernels for generalized time-frequency representations of nonstationary signals, IEEE Transactions on Acoustics, Speech, and Signal Processing, 38,7 (1990) 1084-1091.
52. Loh, W. Y. ve Shih, Y. S., Split selection methods for classification trees, Statistica sinica, (1997) 815-840.
53. Safavin, S. R. ve Landgrebe, D. A., Survey of Decision Tree Classifier Methodology, IEEE Transaction on Systems, Man and Cybernetics, 21, 3 (1991) 660-674.
54. Rokach, L. Pattern classification using ensemble methods, 75, World Scientific, 2010.
55. Quinlan, J. R., C4.5: Programs for Machine Learning, Morgan Kaufmann Publishers Inc, San Francisco, CA, USA, 1993.
56. Breiman, L. ve Friedman, J. H., Estimating optimal transformations for multiple regression and correlation, Journal of the American statistical Association, 80,391 (1985) 580-598.

57. Vapnik, V. N., *The Nature of Statistical Learning Theory*, Springer-Verlag, New York, USA, 1995.
58. Vapnik, V., *The nature of statistical learning theory*. Springer science and Business Media, 2013.
59. Theodoridis, S. ve Koutroumbas, K., *Pattern Recognition*, Second Edition, Academic Press, London, 2003.
60. Fan, R. E, Chen, P. H. ve Lin C. J., Working set selection using second order information for training support vector machines, *Journal of machine Learning Research*, (2005) 1889-1918.
61. Ayhan, S. ve Erdoğan, Ş., DVM ile Sınıflandırma Problemlerinin Çözümü, *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 9,1 (2014) 175-198.
62. Jakkula, V., *Tutorial on Support Vector Machine (SVM)*, School of EECS, Washington State University, Pullman 99164, 2006.
63. Bhatia, N., Survey of nearest neighbor techniques, *International Journal of Computer Science and Information Security*, 8,2 (2010) 302-305.
64. Duda, R. O., Hart, P. E., ve Stork, D. G., *Pattern classification*. John Wiley & Sons, 2012.
65. Xu, G., Zong, Y., ve Yang, Z., *Applied data mining*, CRC Press, 2013.
66. Brown, G., Ensemble learning, *Encyclopedia of Machine Learning*, Springer US, (2011) 312-320.
67. Breiman, L., Bagging predictors, *Machine learning*, 24,2 (1996) 123-140.
68. Rokach, L., Ensemble-based classifiers, *Artificial Intelligence Review*, 33,1 (2010) 1-39.
69. Breiman, L., Random forests, *Machine learning*, 45,1 (2001) 5-32.
70. Ho, T. K., The random subspace method for constructing decision forests, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20,8 (1998) 832-844.
71. Arbel, R., ve Rokach, L., Classifier evaluation under limited resources, *Pattern Recognition Letters*, 27,14 (2006) 1619-1631.
72. Benitez, D., Gaydecki, P. A., Zaidi, A., ve Fitzpatrick, A. P., The use of the Hilbert transform in ECG signal analysis, *Computers in Biology and Medicine*, 31,5 (2001) 399-406.

73. Kayıkçıođlu, İ., Akdeniz, F., Kayıkçıođlu, T., ve Kaya, İ., Real-Time Monitoring of ST Change for Telemedicine, CMBEBIH 2017 Springer, Singapore, 2017, 671-677.



ÖZGEÇMİŞ

İlknur KAYIKÇIOĞLU, 1991 Lubbock-TEXAS ABD doğumludur. İlkokulu ve ortaokulu Mimar Sinan İlköğretim Okulu'nda ve liseyi Kanuni Anadolu Lisesinde tamamlamıştır. Karadeniz Teknik Üniversitesi Bilgisayar Mühendisliği Bölümü'nden 2014 yılında mezun olmuştur. 2015 yılında Karadeniz Teknik Üniversitesi Bilgisayar Mühendisliği Bölümü'nde yüksek lisans öğrenimine başlamıştır. 2015 yılından itibaren Bülent Ecevit Üniversitesi Bilgisayar Mühendisliği bölümünde araştırma görevlisi olarak çalışmıştır. Daha sonra yüksek lisans görevlendirmesi nedeniyle Karadeniz Teknik Üniversitesinde araştırma görevlisi olarak çalışmaya başlamıştır. Halen Bilgisayar Mühendisliği Bölümü'nde araştırma görevlisi olarak çalışmaktadır. İyi derecede İngilizce bilmektedir.