

**BAŐKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**KALPTEKİ FOKAL VENTRİKÜLER ARİTMİ KAYNAĞININ
YERİNİN TESPİTİNDE
KÜMELEME VE SINIFLANDIRMA UYGULAMALARI**

AHMET SERTAÇ SUNAY

DOKTORA TEZİ
2010

**KALPTEKİ FOKAL VENTRİKÜLER ARİTMİ KAYNAĞININ
YERİNİN TESPİTİNDE
KÜMELEME VE SINIFLANDIRMA UYGULAMALARI**

**CLUSTERING AND CLASSIFICATION
APPLICATIONS FOR
VENTRICULAR FOCAL CARDIAC ARRHYTHMIA
SOURCE LOCALIZATION**

Ahmet Sertaç Sunay

Başkent Üniversitesi
Lisanüstü Eğitim Öğretim ve Sınav Yönetmeliğinin
ELEKTRİK-ELEKTRONİK Mühendisliği Anabilim Dalı İçin Öngördüğü
DOKTORA TEZİ
olarak hazırlanmıştır.

2010

Fen Bilimleri Enstitüsü Müdürlüğü'ne,

Bu çalışma, jürimiz tarafından **ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI 'nda DOKTORA TEZİ** olarak kabul edilmiştir.

Başkan : Prof. Dr. Emin AKATA

Üye (Danışman) : Doç. Dr. Bülent YILMAZ

Üye : Yrd. Doç. Dr. Yeşim SERİNAĞAOĞLU

Üye : Yrd. Doç. Dr. Hamit ERDEM

Üye : Yrd. Doç. Dr. Metin YILDIZ

ONAY

Bu tez 16/06/2010 tarihinde yukarıdaki jüri üyeleri tarafından kabul edilmiştir.

...../...../.....

Prof.Dr. Emin AKATA

FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRÜ

TEŐEKKÜR

Yazar, bu alıőmanın gerekleőmesindeki katkılarından dolayı, aőađıda adı geen kiőilere itenlikle teőekkür eder.

Sayın Yrd. Do. Dr. Bülent YILMAZ'a (tez danışmanı), alıőmanın sonuca ulaőtırılmasında ve karőtılaőtılan gülüklerin aőtılmasında her zaman yardımcı ve yol gösterici olduđu için.

Sayın Yrd. Do. Dr. Hamit ERDEM'e bu alıőmada kullanılan yapay sinir ađlarının oluőturulması ve uygulanması sırasındaki yardımları için.

Sayın Yrd. Do. Dr. Yeőtım Serinađaođlu'na bu alıőmanın her aőtamasında verdiđi destek için.

Eőtım Nagehan SUNAY'a gösterdiđi hoőtörü ve desteđi için.

ÖZ

KALPTEKİ FOKAL VENTRİKÜLER ARİTMİ KAYNAĞININ YERİNİN TESPİTİNDE KÜMELEME VE SINIFLANDIRMA UYGULAMALARI

Ahmet Sertaç Sunay

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Son dönemde kalpteki ritim bozukluklarının (aritmilerin) ortaya çıkmasında önemli rol oynayan anormal iletim bölgelerinin bulunmasında kateterlere dayalı yöntemler daha çok tercih edilir olmuşlardır. Girişimsel olmayan bir yöntem olan vücut yüzeyi potansiyel haritalama (VYPH) ise araştırma amaçlı bir uygulama olmaktan çıkıp klinikte kendine yer bulmaya çalışmaktadır.

Bu tez çalışmasında, fokal (odaksal) ventriküler aritmi kaynaklarının yerinin kateterlere dayalı yöntemlerle veya VYPH ile tespitinde yeni bir yaklaşım ile değişik kümeleme ve sınıflandırma yöntemleri kullanılmıştır. Kalbin yüzeyi, Kohonen özörgütlemeli haritalar ve bulanık C ortalamalı kümeleme kullanılarak, belirli sayıda bölgeye (küme) ayrılmıştır. Daha sonra geri yayılım (GYA), olasılıksal sinir ağı (OSA), diskriminant analiz (DA), k en yakın komşu (kNN), destek vektör makineleri (DVM) olarak sıralayabileceğimiz sınıflandırma yaklaşımları kullanılarak aritmi kaynağının kalbin üzerindeki hangi bölge içinde olduğu belirlenmiştir. Çalışmanın birinci kısmında, 13 adet köpek kalbi deneyinden elde edilen aktivasyon zamanı verilerini kullanarak toplardamar içindeki kateterlerden kalbin dış yüzeyindeki (epikart) aritmi kaynağı tespit edilmiştir. İkinci aşamada, Aliev-Panfilov matematiksel modelleme yöntemine dayanan benzetim veri seti üzerinde hem dış hem de iç yüzeydeki (endokart) fokal kaynakların hangi kalp yüzeyinde bulunduğu ve o yüzeyin hangi bölgesinde yer aldığı belirlenmiştir. Üçüncü aşamada, vücut yüzeyi potansiyel haritalarından Karhunen-Loeve dönüşümü, QRS ve QRST integralleri yaklaşımlarıyla elde özellik vektörleri yardımıyla epikardiyal kaynakların yerinin belirlenmesi gerçekleştirilmiştir.

Çalışma sonucunda, ventriküler aritmilerin kaynaklarının tespiti için yeni yöntemler geliştirilmiştir ve bu yöntemlerin performans analizleri yapılmıştır.

ANAHTAR SÖZCÜKLER: Aritmi, Kohonen SOM, Bulanık C-Ortalama, Olasılıksal Sinir Ağları, Geri Yayılım Ağları, Diskriminant Analiz, Destek Vektör Makineleri, k en yakın komşu.

Danışman: Yrd.Doç.Dr. BÜLENT YILMAZ, Zirve Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü.

ABSTRACT

CLUSTERING AND CLASSIFICATION APPLICATIONS FOR VENTRICULAR FOCAL CARDIAC ARRHYTHMIA SOURCE LOCALIZATION

Ahmet Sertaç SUNAY

Baskent University Institute of Science

Department of Electrical Electronics Engineering

Catheter-based approaches used in determining the regions of abnormal conduction causing rhythm disturbances on the heart have recently become popular due to their minimal invasive nature. Another noninvasive method, body surface potential mapping (BSPM), strives for staying not only as a research tool but becoming a clinically applicable approach.

In this thesis, feasibility and performance of clustering and classification approaches in the localization of the source of focal ventricular arrhythmias using catheter-based or BSMP-based techniques have been investigated. For this purpose, the measurement points on the heart surface have been clustered by Kohonen self organizing maps (SOM) and fuzzy C-means (FCM). Finally, back-propagation, probabilistic neural networks (PNN), discriminant analysis (DA), k nearest neighbor (kNN), support vector machines classification approaches have been studied in determination of the cluster (region of the heart) from which the arrhythmic beat originates. In the first phase of study, outer surface (epicardial) mapping have been performed using a subset of activation times that coming from catheters inside coronary veins. In the second stage, the simulation data set based on Aliev-Panfilov model that was developed for the mathematical modelling of the electrical activity of the heart was used for the determining the source of the arrhythmias on both inner and outer surfaces of the heart. the third stage, the feature vectors have been selected using the Karhunen-Loeve Transform (KLT) and QRS, QRST integral calculations on the body surface potential maps. Then these vectors have been used for determining epicardial sources.

As a result of this study, new methods that detect the source of the ventricular arrhythmias have been developed.

KEYWORDS: Arrhythmias, Kohonen SOM, Fuzzy C-Means, Probabilistic Neural Networks, Back Propagation Networks, Discriminant Analysis, Support Vector Machines, k Nearest Neighbor.

Supervisor: Assist. Prof. Dr. Bülent YILMAZ, Zirve University, Department of Electrical Electronics Engineering.

İÇİNDEKİLER LİSTESİ

| | <u>Sayfa</u> |
|--|--------------|
| ÖZ | i |
| ABSTRACT | iii |
| İÇİNDEKİLER LİSTESİ..... | iv |
| ŞEKİLLER LİSTESİ..... | viii |
| ÇİZELGELER LİSTESİ..... | x |
| SİMGELER VE KISALTMALAR LİSTESİ..... | xiii |
| 1. GİRİŞ | 1 |
| 1.1 Vücut Yüzeyi Potansiyel Haritalama (VYPH) Çalışmaları..... | 3 |
| 1.2 Kateterlere Dayalı Haritalama Çalışmaları | 4 |
| 1.3 Tez Çalışmasının Amacı ve İçeriği..... | 5 |
| 1.4 Tez Çalışmasının Özgünlüğü..... | 7 |
| 2. TEMEL BİLGİLER..... | 9 |
| 2.1 Dolaşım Sistemi..... | 9 |
| 2.2 Kalp Anatomisi ve Fizyolojisi..... | 10 |
| 2.3 Koroner Sistem | 12 |
| 2.4 Kalp Elektrofizyolojisi | 13 |
| 2.5 Aritmi | 14 |
| 2.6 Kalp Haritalaması..... | 17 |
| 2.6.1 Elektrokardiyogram (EKG)..... | 18 |
| 2.6.2 Endokardiyal haritalama | 19 |
| 2.6.2 Epikardiyal haritalama | 23 |
| 2.7 Vücut Yüzeyi Potansiyellerinin (VYP) Haritalanması | 24 |
| 2.8 Yapay Sinir Ağları | 28 |
| 2.9 Kümeleme Yaklaşımları | 33 |
| 2.9.1 Kohonen SOM kümeleme..... | 34 |
| 2.9.2 Bulanık kümeleme | 36 |

| | |
|---|------------|
| 2.10 Sınıflandırma..... | 41 |
| 2.10.1 Olasılıksal yapay sinir ağı (OSA) | 41 |
| 2.10.2 Geri yayılım ağları (GYA)..... | 44 |
| 2.10.3 Diskriminant analiz (DA) | 45 |
| 2.10.4 k en yakın komşu (kNN) tahmini | 47 |
| 2.10.5 Destek vektör makineleri (DVM) | 48 |
| 2.11 Genetik Algoritmalar (GA) | 52 |
| 2.12 Özellik (Feature) Seçimi..... | 58 |
| 2.12.1 Karhunen–Loeve dönüşümü (KLD)..... | 59 |
| 2.13 Çapraz Sağlama | 63 |
| 2.14 Kümeleme Kalitesi | 64 |
| 3. YÖNTEMLER..... | 66 |
| 3.1 Deneysel Veri | 67 |
| 3.2 Benzetim Verisi | 69 |
| 3.3 Kümeleme Yaklaşımları..... | 74 |
| 3.4 Kademeli Odaklanma..... | 75 |
| 3.5 Kümeleme Kalitesi | 78 |
| 3.6 Aritmi Kaynağının Tespitinde YSA ve Sınıflandırma Yöntemleri..... | 79 |
| 3.6.1 Deneysel Veri..... | 79 |
| 3.6.2 Benzetim Verisi | 82 |
| 3.6.3 VYPH Verisi..... | 83 |
| 4. SONUÇLAR | 94 |
| 4.1 Deneysel Veri Üzerindeki Uygulamalar..... | 94 |
| 4.2 Benzetim Verisi Üzerindeki Uygulamalar | 101 |
| 4.3 VYPH Verisi Üzerindeki Uygulamalar | 122 |
| 5. SONUÇ VE ÖNERİLER | 125 |
| KAYNAKLAR LİSTESİ..... | 128 |

ŞEKİLLER LİSTESİ

| | <u>Sayfa</u> |
|--|--------------|
| Şekil 2.1 Dolaşım sistemi | 10 |
| Şekil 2.2 Kalbin fiziksel yapısı..... | 11 |
| Şekil 2.3 Kalbin ana koroner damarlar | 12 |
| Şekil 2.4 İnsan kalbinin iletim sistemi..... | 14 |
| Şekil 2.5 Kalp haritalaması yöntemleri..... | 17 |
| Şekil 2.6 CARTO ile elde edilmiş sağ ve sol kulakçıkların haritaları..... | 20 |
| Şekil 2.7 Çok elektrotlu sepet kateter görüntüsü..... | 21 |
| Şekil 2.8 Temassız haritalama ile yerel sağ atriyal taşikardinin haritalanması ve ablasyonu. | 22 |
| Şekil 2.9 Perikardiyal boşluğa haritalama/ablasyon kateterinin yerleştirilmesi. | 24 |
| Şekil 2.10 Normal bir kişiden alınmış vücut yüzeyi potansiyeli haritası | 25 |
| Şekil 2.11 Epikardiyal ve torso haritalamaları. | 28 |
| Şekil 2.12 Yapay sinir ağı katmanları..... | 29 |
| Şekil 2.13 Perseptron yapısı..... | 30 |
| Şekil 2.14 Çokkatmanlı yapay sinir ağı yapısı..... | 31 |
| Şekil 2.15 Yapay sinir ağlarının genel kullanım bölgeleri | 32 |
| Şekil 2.16 Ölçüm veri tabanlı kümeleme yaklaşımı olarak kullanılan Kohonen SOM yapısı. | 36 |
| Şekil 2.17 Kullanıcı tarafından atanan üyelik fonksiyonları..... | 37 |
| Şekil 2.18 Optimal yüksek uzayı bulmayı amaçlayan bir SVM'nin eğitimi. | 50 |
| Şekil 3.1 Çalışmada kullanılan veri setlerinin ve yöntemlerin genel blok gösterimi..... | 67 |
| Şekil 3.2 490 elektrotlu çorap geometrisi ve kateter elektrotlar olarak varsaydığımız 42 elektrotun geometri üzerindeki yeri..... | 68 |
| Şekil 3.3 FHN modeli hücre zarı elektriksel eşdeğer devresi | 69 |
| Şekil 3.4 Ölçüm sisteminin şematik gösterimi | 71 |
| Şekil 3.5 Aliev-Panfilov modeli kullanılarak apeksten uyarı verilmesi sonucu elde edilen benzetim sonucu | 72 |
| Şekil 3.6 Elektriksel yayılımların karşılaştırılması..... | 73 |

| | |
|---|----|
| Şekil 3.7 Geometri veri ambarında yer alan sağ endokart, sol endokart ve epikart geometrileri ağ yapıları..... | 74 |
| Şekil 3.8 Kademeli odaklanma genel kümeleme üzerinde atanan küme, birinci komşulukları ve aritmi kaynağının gerçek yeri..... | 76 |
| Şekil 3.9 Kademeli odaklanma birinci alt kümeleme ve aritmi kaynağının gerçek yeri..... | 77 |
| Şekil 3.10 kademeli odaklanma ikinci alt kümeleme ve aritmi kaynağının gerçek yeri..... | 77 |
| Şekil 3.11 Farklı dağılımlara sahip üç küme ve bunların küme içi yayılma sayıları..... | 78 |
| Şekil 3.12 Aritmi kaynağının (uyarı noktası) iki komşu küme arasındaki sınırda olduğunda birinci komşuluk kümelerindeki kaynak yeri tahminini şematik gösterimi. | 80 |
| Şekil 3.13 Epikart potansiyelinden torso potansiyeline geçiş işlemi..... | 84 |
| Şekil 3.14 Kullanılan özellik çıkarım yöntemleri. | 84 |
| Şekil 3.15 Torso potansiyeli..... | 85 |
| Şekil 3.16 RMS eğrisi. | 86 |
| Şekil 3.17 RMS eğrisi üzerinde yapılan işaretlemeler. | 86 |
| Şekil 3.18 QRS ve QRST aralıklarının çıkarımı. | 87 |
| Şekil 3.19 QRS ve QRST integrallerinin çıkarımı..... | 88 |
| Şekil 3.20 Karhunen–Loeve özdeğerleri. | 89 |
| Şekil 3.21 İlk on özdeğer vektörlerine karşılık gelen RMS hataları ve %Trace değerleri..... | 89 |
| Şekil 3.22 İlk on özdeğer vektörüne karşılık gelen VYPH. | 90 |
| Şekil 3.23 Epikart üzerindeki test noktaları. | 91 |
| Şekil 3.24 Eğitim setindeki uyarım noktalarının elle kümelenmesi. | 91 |
| Şekil 3.25 10dB gürültü eklenmiş örnek bir torso potansiyeli. | 92 |
| Şekil 3.26 Orjinal ve 10dB gürültü eklenmiş QRS integralleri VYP haritaları..... | 92 |
| Şekil 3.27 Orjinal ve 10dB gürültü eklenmiş QRST integralleri VYP haritaları..... | 93 |
| Şekil 4.1 Deneysel veri üzerinde elle Kümeleme ve OSA optimizasyonu..... | 94 |
| Şekil 4.2 Deneysel veri üzerinde BCO ve OSA optimizasyonu. | 95 |
| Şekil 4.3 Deneysel veri üzerinde Kohonen SOM ve OSA optimizasyonu..... | 95 |
| Şekil 4.4 Kümeleme sonuçları..... | 97 |

| | |
|---|-----|
| Şekil 4.5 Kümeleme yöntemlerinin küme içi yayılma sayıları ve karşılaştırmaları. | 97 |
| Şekil 4.6 Benzetim verisinde üç katman üzerinde yapılan eğitici-siz bölgelemenin üç boyutlu gösterimi. | 109 |
| Şekil 4.7 Benzetim verisi üzerinde bölge düzeltmesi öncesi epikart üzerindeki genel bölgeleme. | 109 |
| Şekil 4.8 Benzetim verisi üzerinde bölge düzeltmesi sonrası epikart üzerindeki genel bölgeleme. | 110 |
| Şekil 4.9 Benzetim verisi üzerinde bölge düzeltmesi öncesi epikart üzerindeki birinci alt bölgeleme. | 110 |
| Şekil 4.10 Benzetim verisi üzerinde bölge düzeltmesi sonrası epikart üzerindeki birinci alt bölgeleme. | 111 |
| Şekil 4.11 Benzetim verisi üzerinde bölge düzeltmesi öncesi epikart üzerindeki ikinci alt bölgeleme. | 111 |
| Şekil 4.12 Benzetim verisi üzerinde bölge düzeltmesi sonrası epikart üzerindeki ikinci alt bölgeleme. | 112 |
| Şekil 4.13 QRS integralleri üzerinde elle kümeleme ve OSA optimizasyonu. | 122 |
| Şekil 4.14 QRST integralleri üzerinde elle kümeleme ve OSA optimizasyonu. | 123 |
| Şekil 4.15 VYP haritasından geriçatılarak elde edilen SOM kümelemesi. | 124 |
| Şekil 4.16 VYP haritasından geriçatılarak elde edilen bulanık C ortalamalı kümeleme. | 124 |

ÇİZELGELER LİSTESİ

| | <u>Sayfa</u> |
|--|--------------|
| Çizelge 2.1 Genetik algoritmaların işleyiş basamakları..... | 54 |
| Çizelge 4.1 Aritmi yerini tespitinde kümeleme ve sınıflandırma yöntemlerinin başarımları yüzdeleri karşılaştırmaları.. | 98 |
| Çizelge 4.2 Tahmin algoritması sonuçları..... | 98 |
| Çizelge 4.3 Kohonen SOM kümeleme ve OSA kullanılarak elde edilen düzensizlik (Confusion) matrisi..... | 99 |
| Çizelge 4.4 Bulanık C ortalama kümeleme ve OSA kullanılarak elde edilen düzensizlik (Confusion) matrisi..... | 100 |
| Çizelge 4.5 kNN ile katman ayırmada farklı uzaklık ve sınıflandırma yöntemleri ile elde edilen hata yüzdeleri..... | 102 |
| Çizelge 4.6 DA ile katman ayırmada farklı diskriminant yöntemleri ile elde edilen hata yüzdeleri..... | 103 |
| Çizelge 4.7 Benzetim verisi üzerinde OSA ile katman ayırma uygulamasının başarımları yüzdeleri..... | 105 |
| Çizelge 4.8 Benzetim verisi üzerinde kNN ile katman ayırma uygulamasının başarımları yüzdeleri..... | 116 |
| Çizelge 4.9 Benzetim verisi üzerinde DA ile katman ayırma uygulamasının başarımları yüzdeleri..... | 107 |
| Çizelge 4.10 Benzetim verisi üzerinde DVM ile katman ayırma uygulamasının başarımları yüzdeleri..... | 108 |
| Çizelge 4.11 Epikart benzetim verisi üzerinde OSA sınıflandırması kullanılarak yapılan kademeli odaklanma sonuçları..... | 113 |
| Çizelge 4.12 Sol endokart benzetim verisi üzerinde OSA sınıflandırması kullanılarak yapılan kademeli odaklanma sonuçları..... | 114 |
| Çizelge 4.13 Sağ endokart benzetim verisi üzerinde OSA sınıflandırması kullanılarak yapılan kademeli odaklanma sonuçları..... | 115 |
| Çizelge 4.14 Epikart benzetim verisi üzerinde kNN sınıflandırması kullanılarak yapılan kademeli odaklanma sonuçları..... | 116 |
| Çizelge 4.15 Sol endokart benzetim verisi üzerinde kNN sınıflandırması kullanılarak yapılan kademeli odaklanma sonuçları..... | 117 |
| Çizelge 4.16 Sağ endokart benzetim verisi üzerinde kNN sınıflandırması kullanılarak yapılan kademeli odaklanma sonuçları..... | 118 |

| | |
|--|-----|
| Çizelge 4.17 Epikart benzetim verisi üzerinde DA sınıflandırması kullanılarak yapılan kademeli odaklanma sonuçları..... | 119 |
| Çizelge 4.18 Sol endokart benzetim verisi üzerinde DA sınıflandırması kullanılarak yapılan kademeli odaklanma sonuçları..... | 120 |
| Çizelge 4.19 Sağ endokart benzetim verisi üzerinde DA sınıflandırması kullanılarak yapılan kademeli odaklanma sonuçları..... | 121 |

SİMGELER VE KISALTMALAR LİSTESİ

| | |
|------|---|
| AV | Atriyoventriküler Düğüm |
| BCO | Bulanık C Ortalama |
| BEM | Sınır Elemanları Yöntemi |
| BKT | Büyük Kalp Toplardamarı |
| CT | Bilgisayarlı Tomografi |
| DA | Diskriminant Analiz |
| EKG | Elektrokardiyografi |
| EPS | Elektrofizyolojik Çalışma |
| FEM | Sonlu Element Yöntemi |
| GA | Genetik Algoritmalar |
| ICD | Kalp İçi Defibrilatör |
| kNN | k En Yakın Komşu (k nearest neighbor estimation) |
| KS | Koroner Sinüs |
| MRI | Manyetik rezonans Görüntüleme |
| OKT | Orta Kalp Toplardamarı |
| OSA | Olasılıksal Sinir Ağları (Probabilistic Neural Network) |
| RF | Radyo Frekans |
| RPM | Gerçek Zamanlı Pozisyon Yönetimi |
| SA | Sinoatrial Düğüm |
| SOM | Öz Örgütlemeli Harita (Self Organizing Map) |
| SÖİ | Sol Ön İnen Atardamar |
| SKAT | Sol Karıncık Arka Toplardamarı |
| SV | Sol Ventrikül |
| SVM | Destek Vektör Makineleri (Support Vector Machines) |
| VYP | Vücut Yüzeyi Potansiyel |

| | |
|------|------------------------------------|
| VYPH | Vücut Yüzeyi Potansiyel Haritalama |
| YSA | Yapay Sinir Ağları |

1. GİRİŞ

Kalp, senkron bir şekilde çalışan vücudumuzun kan pompasıdır. Kalbin senkron çalışması; üst ve alt odacıklarının, yani sırasıyla atriya ve ventriküllerin, düzenli ve birbirini takip eden bir şekilde elektriksel olarak uyarılması ve onun sonucu olarak kasılması (elektromekanik faaliyet) anlamına gelmektedir. Kalbin kendine özel bir iletim sistemi bulunmaktadır, ve bu sistem senkron çalışmada başrolü oynamaktadır.

Aritmi, kalp ritmindeki bozukluk demektir. Günümüzde Türkiye’de yaklaşık 1 milyon aritmi hastası bulunmaktadır. Kalp kaslarında, kapaklarında, damarlarında veya elektriksel iletim sistemindeki problemler, aritmilerin oluşmasına sebep olmaktadır. Aritmiyi oluşturan sebebe bağlı olarak belirli bölge veya noktalar anormal faaliyetin kaynağı olarak davranmaktadır. Bu bölge veya noktalar atriya veya ventriküller üzerinde olabilir. Bir noktadan ya da küçük bir bölgeden kaynaklanan aritmilere “fokal (odaksal) aritmiler” denmektedir. Kaynağın ventriküllerin birinde olması aritmiyi daha riskli hale getirmektedir. Ayrıca, 20 yıl kadar önce yapılan çalışmalarda, kaynakların kalbin en dış katmanında (epikartta) olduğu durumların bütün ventriküler aritmi vakalarının %5 ila 15’ini teşkil ettiği ifade edilmiştir [1;2]. Bu istatistik bize kaynakların çoğunun kalbin iç yüzeyinde (endokartta) bulunduğunu da göstermektedir.

Aritmiler, kasılma örüntüsünde anormallikler olarak kendini gösterirken aynı zamanda kalbin üzerindeki elektriksel faaliyetin hücreden hücreye yayılımının örüntüsünü de ciddi oranda değiştirmektedir. Dolayısıyla, aritmilerin karakterize edilmesi elektriksel yöntemlere dayanmaktadır. Bu elektriksel yöntemlerden ilki kardiyolojide en çok kullanılan teşhis yöntemi olan elektrokardiyografidir (EKG). Bu yöntemin temel mantığı, kalbin elektriksel faaliyeti sonucu ortaya çıkan ve vücut hacim iletkeni içinden iletilen akımların vücut yüzeyine yerleştirilen elektrotlarla potansiyel olarak algılanmasıdır. Ölçülen bu potansiyellerdeki zamanlama ya da dalga şekillerinin teşhiste ciddi faydalarının olduğu anlaşılmıştır. Bu yöntemin en önemli varsayımı, kalp üzerindeki karmaşık elektriksel faaliyetin sadece bir dipolle gösterilebileceğidir. Bu yöntemde göğüs kafesine, kollara (ya da omuzlara) ve bacaklara yerleştirilen 10 adet elektrottan alınan potansiyellerden 12 potansiyel fark türetilerek 12 kanal bilgi elde edilmektedir. Bu kanallardaki potansiyellerin,

kalp dipolünün faklı düzlemlere izdüşümleri olduğu varsayılmaktadır. Hekimin zihninde, bu 12 adet zamanla değişen potansiyelden yola çıkarak kalbin üzerindeki elektriksel faaliyet canlanmaktadır. Aritmilerin varlığı veya yokluğu, ilerlemişlik seviyesi ve aritmi çeşidi, çoğunlukla 12 kanallı EKG ile tespit edilmektedir. Elbette, çok tecrübe isteyen bu teşhis yöntemi bazı vakalarda istenen seviyede başarılı değildir. Koyulan teşhis üzerine hastaya, ilaç tedavisi, hayat tarzında ve diyetinde değişiklikler tavsiye edilmektedir. Ancak, bazı aritmi çeşitlerinde, özellikle ventriküllerden kaynaklanarlarda, ilaç tedavisine beklenen cevabı vermeyen riskli hastalarda ve hayat boyu ilaç kullanmak istemeyen genç hastalarda, aritminin karakterize edilmesi ve dolayısıyla kaynağının yerinin belirlenmesi amaçlanmaktadır. Kaynağın yerinin belirlenmesi ile kalbin içinden problemlı bölgeyi yakmak üzere enerji uygulanarak (ablasyon), aritmi bir daha tekrar etmeyecek şekilde durdurulmaya çalışılmaktadır.

Kaynağın yerinin belirlenmesinde EKG bir çok açıdan yetersiz kalmaktadır. Bu yöntemin eksiklerini gidermek üzere EKG'de kullanılan elektrotlardan daha fazla sayıda (16 ila 240) elektrotun vücut yüzeyine yerleştirilmesiyle elde edilen tek kutuplu elektrokardiyogramların vücut yüzeyi üzerindeki konumsal dağılımını gösteren "vücut yüzeyi potansiyel haritalama"dan (VYPH), açık-kalp ameliyatı gerektiren yöntemlere kadar çok farklı yaklaşımlar zaman içinde geliştirilmiştir.

Vücudun içine küçük bir kesi ile damaryolu kullanılarak yerleştirilen uzun, ince, esnek tüplere "kateter" denmektedir. Kateterler vücudun içine ilaç zerkedilmesi, damarların açılması gibi alanlarda kullanıldığı gibi kalpten elektriksel bilgiler almak ve problemlı bölgeyi ablasyonla yakmak için de kullanılmaktadır. Çok az girişimsellik içermesi, manevra kabiliyetinin iyi olması, floroskopi altında koroner damarlara ve kalbin odacıklarına rahat yerleştirilebilmeleri, kateterleri kalp haritalamada çok daha cazip hale getirmektedir. Bu yaklaşımlar aritmi teşhis ve tedavisi alanlarında köklü değişiklikler meydana getirmiştir.

Bu tez çalışmasında, girişimsel olmayan VYPH ve az girişimsel olan kateterlere dayalı yöntemlerle aritmi kaynağının yerinin tespiti için yeni yöntemler araştırıldı. Bu tez kapsamında geliştirdiğimiz yaklaşımların ayrıntılarına girmeden önce, bu

yöntemlerle ilgili literatürde mevcut bulunan çalışmalardan bir özet sunmak uygun olacaktır.

1.1 Vücut Yüzeyi Potansiyel Haritalama (VYPH) Çalışmaları

Son 40 yılda VYPH üzerine klinik ve deneysel amaçlı yüzlerce makale yayınlanmıştır. Yayınlanan ilk makaleler yöntemin bazı hastalıklar için EKG'ye üstünlüklerini göstermektedir. VYPH, akciğer embolisi, aort yırtığı, atriyal dalgalanma [3], Wolff-Parkinson-White sendromunda iletim yolunun bulunması [4], miyokardiyal enfarktüsün boyutunun ve yerinin tespiti [5;6], ventriküler veya atriyal aritmilerin kaynak yerinin belirlenmesi [7], doğuştan gelen kalp hastalıklarının teşhisi [8] gibi durumlarda kullanılmıştır. Şu anda daha çok bir araştırma aracı olarak kullanılmaktadır. Kalpteki faaliyetin vücut yüzeyine yansımaları noktasındaki temel araştırmalarda sıkça kullanılmaktadır.

VYPH ile ilgili klinik makalelerin sayısı, en üst düzeye ulaştıkları 1980'lerin ortalarından itibaren hızla azalmaktadır. Bu azalmanın nedeni ölçüm-kayıt sistemi ve haritaların analizi ile ilgili zorluklardır.

VYPH üzerine kardiyak elektrik alan ve ilintili matematiksel modellerle ilgili makaleler literatürde hızla artmaktadır. Ayrıca, son on yıldır yapılan bazı çalışmalar VYPH'yi kliniğe yaklaştırmak adına ve aritmi kaynağının yerinin tespitine yönelik olarak dikkat çekmektedir [9;10;13]. Bu çalışmalarda vücut yüzeyi ile kalp yüzeyi arasında ileri problem yaklaşımı ile geometrik bir bağlantı kurulmaktadır. Bu bağlantının kurulması için son dönemlerde bilgisayarlı tomografi (BT) kullanılmaktadır. Elektrotlar hastanın üzerindeyken, elektrotların bulunduğu yerler ile kalbin yeri birbiriyle karşılaştırılmaktadır. Bu bilgi kullanılarak ileri matris oluşturulmakta, ardında da geri problem çözümü yaklaşımları ile vücut yüzeyinden elde edilen potansiyellerle kalbin üzerindeki potansiyel veya hangi bölgenin ne zaman elektriksel olarak faal hale geldiğini gösteren aktivasyon zamanı dağılımı hesaplanmaktadır. Şimdiye kadar yapılan çalışmalarda, Modre ve arkadaşları ve Oster ve arkadaşları [9;14] 8-10 mm, Cheng ve arkadaşları ise [10] 17.3 mm'lik doğruluk değerleri elde etmişlerdir. Bin He ve arkadaşları üç boyutlu kardiyak aktivasyon görüntüleme ile ventriküler damar tıkanıklığının lokalizasyonunu yaklaşık 6 mm ile gerçekleştirdiklerini ifade etmişlerdir [11;12]. Her bir hasta için

özel bir ileri matris hesaplama zorunluluğu, ileri problemde bulunan geometrik hatalar, geri problem yaklaşımlarının yumuşatıcı etkileri gibi sebepler bu yöntemin dezavantajları olarak söylenebilir.

1.2 Katetere Dayalı Haritalama Çalışmaları

Günümüzde kateter dayalı haritalama teknikleri belirli sayıda elektrot içeren standart elektrofizyolojik kateterler kullanırlar. Bu kateterler koroner damarlardaki önceden belirlenmiş yerlere, endokarta ve epikarta yerleştirilerek kardiyak atımın oluşturulması için yerel elektriksel aktiviteyi kaydederler. Bu tip kateterler kullanılarak aktivasyon dizisi haritalarının çıkarılması, teknik olarak zor, tekrarlanamayan ve bazı aritmi çeşitlerinde uygulanamaz olan bir yöntemdir [15]. Çok elektrotlu temassız kateterler, balon kateterler, çok elektrotlu temaslı sepet kateterler son yıllarda bu güçlükleri yenmek için kullanılmaya başlanmıştır [16;17;18;19]. Özellikle, klinikte tercih edilen iki ticari ürün olan CARTO ve EnSite 3000 gibi teknolojiler, sırasıyla kalp yüzeyine temas eden kateterleri ve temas etmeyen sepet kateterleri kullanır. Bu teknolojiler, haritalanan odacığın endokardiyal geometrisini geriçatmayı içeren anatomi bilgisini sağlayan kateter yerleşim ve yönlendirimi ve elektriksel bilginin birleştirilmesine (elektroanatomik haritalamaya) imkân vermektedir. CARTO ölçüm yapabilmek için pahalı, özel kateterler ve birden fazla kalp çevrimi gerektirir. Bu işlem zaman alıcı olduğu için, özellikle taşikardi süresiz ve hemodinamik olarak düşük toleranslı ise, veri noktaları ve haritalama çözünürlüğü sınırlı olabilir [20]. Miyokardiyal enfarktüs sonrası oluşan ventriküler taşikardiye sahip hastalar dışında, %80'den daha çok hastada aritmi dizisel haritalama için yeterince uzun zaman boyunca kendisini gösteremez. Ensite 3000 sisteminin temassız elektrogramlar ve kateter lokalizasyonu doğruluğu, in vitro [21], hayvan deneyleri [21;22] ve insanlar [23;24] üzerinde onaylanmıştır. Klinik olarak da sistemin dört odacığını ilgilendiren anormallikler üzerinde haritalama ve ablasyon yapılmasında etkili olduğu görülmüştür [25;26]. Bu sistemin en büyük dezavantajı çok büyük çapa sahip bir katetere olan ihtiyaçtır. Balonun merkezine olan uzaklık ve elektriksel faaliyetin karmaşıklığı haritalamada sıkıntılar meydana getirmektedir. Bu sistem de özel ve pahalı kateterler gerektirmektedir.

Bu yöntemlerin haricinde özellikle epikartı haritalamaya yönelik olarak transvenöz haritalama tekniği geliştirilmiştir. Bu teknik, çok elektrotlu damar içi kateterlerin kardiyak toplardamarlara yerleştirilmesi suretiyle epikardiyal elektrogramların kaydedilmesini içermektedir. Bu teknik, cerrahi işleme göre daha kolay ve güvenli olarak sayılsa da kardiyak toplardamar sistemi ile sınırlıdır [27;28;29].

Bu yöntem kullanılarak koroner atardamar kolları civarındaki epikardiyal ventriküler taşikardilerin haritalanması da gerçekleştirilmiştir [30]. Toplardamar içine yerleştirilen kateterlerden epikartın haritalanmasına yönelik, Yılmaz vd. köpek kalpleri üzerinde yapılan deneylerden elde edilen veriler ile istatistiksel kestirim ve aradeğerleme yöntemlerinden faydalanmıştır [31;32;33]. Kullandıkları yöntemler ile yaklaşık 10 mm'lik hata ile kaynak tespitinin yapılabileceğini göstermişlerdir.

Epikardiyal haritalamada kullanılan bir diğer yöntem ise perkütanöz haritalama tekniğidir. Bu yöntemde bir kılıf subksifoid delik içerisinde perikardiyal boşluğa geçirilir [23]. Daha sonra haritalama ve ablasyon kateterleri kullanılarak epikardiyal haritalama gerçekleştirilir. Göğüsten açılan delik içerisinde oluşabilecek komplikasyonlar ve perikartın zarar görmesi gibi dezavantajlar mevcuttur. Epikardiyal haritalama endokardiyal haritalamanın gideremediği bazı uygulamalarda kullanılarak başarılı sonuçlar elde edilmiştir [34;35;36].

Katetere dayanan yaklaşımların bir diğer önemli problemi de epikardiyal ve endokardiyal kaynakların birbirinden ayrılmasıdır. Kaynağı epikardiyal olup endokardiyal zannedilerek içeriden ablasyon yapılan hastalarda aritminin devam ettiği gözlenmiştir. Bir çalışma, bu tip hastalarda epikardiyal haritalama ve ablasyonun çok daha başarılı sonuçlar verdiğini göstermiştir [37]. Bu çalışmalar, bu ayırımın daha iyi yapılması gerekliliğini göstermektedir.

1.3 Tez Çalışmasının Amacı ve İçeriği

Bu tez çalışmasında, vücut yüzeyi potansiyel haritalamaya ve venöz kateterlere ve endokarta temas eden sepet kateterlere dayalı yaklaşımlarla epikarttan ya da endokarttan fokal olarak kaynaklanan ventriküler aritmilerin kaynağının yerinin tespiti için yeni yöntemler geliştirildi. Bu amaçla kalbin yüzeyi, çeşitli eğitici ve eğitici kümeleme algoritmaları kullanılarak, belirli sayıda bölgeye (küme)

ayrıldı. Daha sonra sınıflandırma yaklaşımları kullanılarak aritmi kaynağının kalbin üzerindeki hangi bölge içinde olduğu belirlendi.

Bu çalışmada iki farklı veri kümesi kullanıldı. Bunlardan ilki; Utah Üniversitesi (Salt Lake City, A.B.D.), Kardiyovasküler Araştırma ve Eğitim Enstitüsü'nde gerçekleştirilen 13 adet köpek kalbi deneyinden elde edilmiştir. Bu deneylerde, 490 elektrotlu ince ve esnek bayan çorabının ayak kısmından yapılmış çorap elektrot dizisi iki karıncığı kaplayacak şekilde geçirilmiştir [31;38]. Ardından 470 farklı noktadan elektriksel uyarılar verilerek fokal aritmeye benzer durumlar oluşturulmuştur ve 520 farklı aritmik atım elde edilmiştir. Çorap geometrisi üzerinde olan ve aynı zamanda koroner toplardamarların yerlerine karşılık gelen bölgelerdeki 42 elektrot, kateter elektrot seti olarak varsayılmıştır.

Kullandığımız ikinci tip veri kümesi için, kalbin üç boyutlu elektriksel faaliyetini matematiksel olarak modellemek üzere geliştirilmiş olan Aliev-Panfilov modeli gerçekçi bir köpek kalbi geometrisi üzerinde uygulanmış ve aktivasyon zamanı değerleri elde edilmiştir. İki tip veri de fokal ventriküler aritmilere benzer atımlara karşılık gelmektedir.

Tez çalışmasının ilk aşamasında, deneysel aktivasyon zamanı haritaları üzerinde bölgelere ayırma, epikart yüzeyine yakın damarların içerisine yerleştirildiği varsayılan kateterlerdeki elektrotlardan alınan ölçümlerin sınıflandırma yöntemleri ile aritmi kaynağının yerinin tespiti çalışmaları gerçekleştirilmiştir. Bölgelere ayırma yöntemleri olarak elle, Kohonen özörgütlemeli haritalar (self organized maps, SOM) ve bulanık C ortalama (fuzzy C means, BCO), sınıflandırma yöntemleri olarak da k en yakın komşu (kNN), diskriminant analizi (DA), geri yayılım ve olasılıksal sinir ağları (OSA) yaklaşımları kullanıldı. Bazı parametrelerin optimizasyonunda genetik algoritma kullanılmıştır.

Tez çalışmasının ikinci aşamasında, benzetim veri kümesi üzerinde çalışılmıştır. Bu aşamada ilk olarak kalbin iç ve dış yüzeyindeki ölçüm noktaları Kohonen SOM ve BCO yöntemleri kullanılarak bölgelere ayrılmıştır. Dış yüzeyden venöz kateterler ile iç yüzeyden de sepet kateterler ile alındığı varsayılan ölçümler kullanılarak aritmi kaynağının önce hangi katmanda olduğu ve ardında da hangi bölgede olduğu belirlenmiştir. Sınıflandırma uygulamaları olarak ilk çalışmadaki

yöntemler bu aşamada da kullanılmıştır. Bunlara katman ayırmada destek vektör makineleri (DVM) eklenmiştir. Eğitici veri kümesinin adım adım aritmi kaynağının olduğu bölgeye odaklanması gerçekleştirilmiştir.

Tez çalışmasının son aşamasında, bir deneyden epikartın 72 farklı noktasından uyarılarak elde edilmiş potansiyel verileri daha önce hesaplanmış olan ileri matris ile çarpılarak ve sentetik gürültü eklenerek vücut yüzeyi potansiyel (VYP) haritaları oluşturulmuştur. Bu çalışmada, sadece vücut yüzeyinden alınan potansiyel verileri kullanılarak sınıflandırma uygulamalarının performansı araştırılmıştır. Önce epikart üzerindeki 72 elektriksel uyarım noktası bölgelere ayrılmıştır. Ardından, VYP haritaları üzerinde Karhunen–Loeve dönüşümü (KLD), QRS ve QRST integral hesaplamalarıyla, OSA’da kullanılmak üzere özellikler seçilmiş ve epikart üzerinde aritmi kaynağının yerinin tespiti gerçekleştirilmiştir.

1.4 Tez Çalışmasının Özgünlüğü

Yukarıda bahsi geçen problemlerin çözümü için ilk defa olarak kümeleme, sınıflandırma ve yapay sinir ağları yaklaşımları kullanılmıştır. Günümüzde kullanılan haritalama yöntemleri, aritmi anındaki elektriksel faaliyetin konumsal ve zamansal dağılımlarını vermektedir. Özellikle fokal aritmilerde belirli bir bölge erken aktive olmakta ve aktivasyon zamanı değerleri düşüktür. Hem VYPH’de geri problem çözümü olarak hem de kateterler kullanılarak yapılan haritalamada en erken aktive olan nokta, aritmi kaynağı olarak belirlenmekte ve gerçek kaynaktan uzaklığı tahmin hatası olarak ifade edilmektedir. Haritalama sonucunda elde edilen haritalar ölçüm noktaları arasındaki değerlerin aradeğerleme ile bulunmasını gerektirmektedir. Bu da aslında erken aktive olan bir noktadan değil bir bölgeden bahsetmek gerekliliğini ortaya koymaktadır. Bu tezde klinik problemin çözümüne yaklaşımımız bu düşünceden kaynaklanmaktadır. Haritalama sonucunda kaynağın tam olarak hangi nokta olduğu ve kaynaktan uzak diğer yerlerdeki potansiyel veya aktivasyon zamanı değerlerinin ne olduğu ile değil, sadece kaynağın kalbin hangi bölgesinde olduğu sorusuna cevap aranmıştır. Bu hususta değinilmesi gereken diğer bir nokta da, ablasyon esnasında kullanılan kateterin ucu çok küçük değildir ve ablasyon işlemi bir sıra halinde bir bölgeyi yakmak şeklinde icra edilmektedir. Bu yüzden bir nokta vermek yerine bölge olarak sonucu vermenin de klinik olarak kabul edilebilir olduğunu düşünmekteyiz.

Daha önce venöz kateterlerden epikardiyal kaynakların tespiti için gerçekleştirilen çalışmada kaynak noktası yerine kaynağın bulunduğu bölge yaklaşımı, Cunedioğlu ve Yılmaz [39] tarafından basit seviyede denenmiştir. Bizim tez çalışmamızın ilk kısmının temellerini oluşturan bu makalede, kalbin üzerindeki bölgeler elle kümelenmişken, kateterlerden gelen elektriksel verilerin kendilerinin kümelemede kullanılmasının daha doğru bir yaklaşım olduğu bulunmuştur. Bahsi geçen çalışmada, sınıflandırmada yalnızca geri yayılım ağları kullanılırken bu çalışmada problemin doğasına daha uygun olan olasılıksal sinir ağları ve istatistiksel yöntemler kullanılmış ve daha iyi performans elde edilmiştir.

VYPH çalışmalarında söz konusu olan ileri matrisin elde edilmesi, bu hesaplama esnasında mevcut bulunan geometrik gürültüler, geri problem çözümünde kullanılan matrislerin kötü konumlandırılmasına karşılık düzenleme çalışmalarındaki yumuşatma etkisi gibi sıkıntılar, bunlara ihtiyaç duymayan bir yöntem olan yapay sinir ağları ile aşılmıştır.

Çok pahalı kateterler ve sistem yatırımı gerektiren CARTO ve Ensite 3000 gibi elektroanatomik yöntemler yerine daha ucuz bir çözüm sunmak adına venöz kateterler ve sepet kateterler bu çalışmanın konusu olmuştur. Floroskopi altında kalp odacığına veya toplardamarlara yerleştirilen bu kateterlerden alınan verilerle tek bir kalp atımında aritminin kalbin hangi bölgesinden kaynaklandığını bulmak amaçlanmıştır. Bazı haritalama yöntemleri yukarıda da bahsedildiği gibi sonucun elde edilmesi için birden çok kalp atımını gerektirmektedir.

Son olarak Baysoy vd. istatistiksel kestirim [40] ve Yılmaz vd. aradeğerleme [41] yöntemleri kullanarak kaynağın endokarttan mı epikarttan mı kaynaklandığını bulmak amacıyla çalışmalar gerçekleştirmişlerdir. Bu çalışmalarda bizim de yararlandığımız benzetim verileri kullanılmıştır. Bu iki çalışmaya oranla bizim çalışmamız daha yüksek başarı ile bu problemin çözülebileceğini göstermektedir.

Bu tezin geri kalanındaki organizasyon şöyledir: Bölüm 2'de kalbin anatomisi, koroner damarlar, kardiyak elektrofizyolojinin temelleri, kardiyak aritmiler, mekanizmaları ve tedavi yöntemleri, elektrokardiyografik karakterizasyon teknikleri (kardiyak haritalama), yapay sinir ağları ve kullanımları, genetik algoritmaların temelleri hakkında kısa bilgiler verilmiştir. Bölüm 3'de araştırmada kullanılan veri


setleri, kümeleme ve sınıflandırma algoritmaları ayrıntılarıyla anlatılmıştır. Bölüm 4'de bu çalışmada geliştirilen yöntemin çeşitli veri setleri üzerinde uygulamalarının sonuçları verilmiştir. Son olarak, Bölüm 5'de çalışmanın özeti, tartışmalar ve gelecek çalışmalar üzerinde öneriler bulunmaktadır.

2. TEMEL BİLGİLER

Bu kısımda, çalışmada kullanılan yöntemlerin ve sonuçların anlaşılması için gerekli olan bazı temel bilgiler verilmiştir. İlk olarak insan dolaşım sisteminden ve insan kalbinin temel yapısından bahsedilmiştir. Aritmiler ve insan sağlığındaki önemi hakkında bilgi verildikten sonra aritmi tespitini amaç edinmiş olan kalp haritalaması ve yöntemlerinin temelleri açıklanmıştır. Daha sonra bu çalışmada kullanılan yapay sinir ağlarının temel yapısı hakkında bilgi verilmiştir. Kalp katmanlarını bölgelere ayırmada kullanılan kümeleme yaklaşımları temelleri ile anlatılmıştır. Aritmi kaynağının yerini bu bölgelerden hangisinde olduğunu bulmak amacı ile bu çalışmada yararlanılan sınıflandırma algoritmalarının özelliklerinden bahsedilmiştir. Kalp haritalamasında kullanılan veri setlerinde özellik çıkarımı ve seçiminde kullanılan algoritmalar konusunda bilgi verilmiştir. En son olarak, kümeleme ve sınıflandırma algoritmaların optimizasyonların nasıl gerçekleştirildiği hakkında temel bilgiler verilmiştir.

2.1 Dolaşım Sistemi

Kan, organizma içinde sürekli hareket eder; kanın bu hareketine kan dolaşımı denir [42]. Bu dolaşım devamlı kapalı devrededir. Kanda, besinler ve oksijen, artık ürünler, hormonlar bulunur. Kan dolaşımı ile ilgili organlar kalp ve damarlardır. Kalp kanı damarlara gönderir; damarlar kanı dokulara yayarlar ve toplayarak kalbe getirirler. Dolaşım sisteminin çalışması sinir sistemi tarafından kontrol edilmektedir. Kalp ve damarların çalışmalarında aynı zamanda hormonlar ve diğer maddeler de etkili olurlar. İnsan kan dolaşımının genel yapısı Şekil 2.1'de verilmiştir ([42]'dan alınmıştır). Atardamarlara arter, toplardamarlara ven ismi verilir. Kalbin kendisini beslemek üzere koroner damarlar mevcuttur.




Şekil 2.1 Dolaşım sistemi.

2.2 Kalp Anatomisi ve Fizyolojisi

Dolaşım sisteminin en önemli parçası olan kalp iki akciğer arasında, alt yüzüyle diyaframa komşu, kassal yapıda, koni şeklinde bir organdır. İskelete göre önden göğüs kemiği, arkadan göğüs omurları ile komşuluk yapar [42]. Yetişkin bir insanda kalbin 2/3'ü solda, 1/3'ü sağdadır. Bir tabanı (basis) ve bir ucu (apex) vardır. Ucu aşağıdadır ve sol meme başının biraz altına düşer. Kalbin ön, arka ve alt yüzleri bulunur. Büyüklüğü kişiye, yaşa, cinsiyete ve kişinin işine göre değişir. Erişkin bir insanda ortalama 300 gram ağırlığa sahiptir.

Kalp uzunlamasına bir bölme ile sağ ve sol yarıma ayrılır. İki yarım birbirleriyle doğrudan ilişkili değildir. Her yarım ince birer duvarla üst ve alt boşluklara ayrılırlar. Üst boşluklar kulakçıklar (atriyum), alt boşluklar karıncıklar (ventrikül) adını alırlar. Boşlukların her birinin hacmi ortalama 120 cm³ tür. Kulakçıklar alıcı, karıncıklar dağıtıcı etkiye bulunurlar. Bir yarımdaki iki boşluk arasında atrioventriküler (AV) delik bulunur. Şekil 2.2'de kalbin boşlukları, bunlara bağlanan damarlar ve kapakçıklar görülmektedir ([www.ahmetalpman.com] adresinden değiştirilmiştir).


Kalpte dıştan içe üç katman görülür. Bunlar perikart, miyokart ve endokart katmanları olarak adlandırılırlar. Dışkat (perikart), kalbi çevreleyen ince, saydam bir zardır. Alttan diyaframa, üstten de kalpten çıkan büyük damarlara tutunmuş bir torba gibidir. Bu şekilde meydana gelen boşluk içinde kalp bulunur. Perikart iki yapraktan oluşur. Dış yaprak torbayı, iç yaprak kalbin dışını kaplayarak kalp dış katını (epikart) oluşturur. Perikartın dış yaprağı tarafından oluşturulan kesenin içyüzü sulu (seröz) bir sıvıyla örtülüdür. Bu sıvı kalbin çalışması sırasında kayganlık sağlar, sürtünmeyi ve incinmeyi önler. Ortakat (miyokart), kalp kası hücreleri denilen özel yapılı hücrelerce oluşturulan kas katmanına denir. Kalbin en kalın katmanıdır. Kas hücreleri enine çizgилilik gösterirler ve istemsiz çalışırlar. Bu katman içinde ayrıca uyarı iletimiyle ilgili özgün yapılı kas hücreleri kümeleri ve demetleri bulunur. Bunlar ilettikleri uyarı ile kalp kas hücrelerinin birlikte düzenli ve denetimli çalışmalarını sağlarlar. Bu özgün kas hücreleri, beyinden gelen emirlerle uyarı üretirler ve kalp kas hücrelerine dağıtırlar. Belirtilen özgün kas hücreleri kümeleri ve demetlerine “kalbin uyarı iletili dizgesi” denir. İçkat (endokart), kalp duvarının belirgin iç katıdır. Yüzeyi tek katlı yassı epitel hücreleriyle (endotel) örtülüdür. Bu epitel hücreleri arter ve venlerde devam eder. Epitel katın altında bağdokudan ince bir katçık bulunur. Kalpteki deliklerde ve ilgili damarlardaki deliklerde bulunan kapakçıklar endokart denilen bu içkatın yaptığı katlantılardan meydana gelirler.



Şekil 2.2 Kalbin fiziksel yapısı.

2.3 Koroner Sistem

Kalbe oksijenlenmiş kanı taşıyan ve oksijeni azalmış kanı kalpten toplayan damarların oluşturduğu ağa koroner dolaşım denir. İki ana damar olan sağ ve sol koroner atardamarlar kalbe kan sağlar. Sol koroner atardamar iki ana kola ayrılır; sol ön inen atardamar, karıncıkların ön duvarları ve septumun (sağ ve sol ventriküler boşlukların arasında kalan kalın kas yapısı) 2/3'lük kısmını besler, sirkumfleks atardamar sol ventrikülün yan duvarlarına kan götürür. Sağ koroner atardamar sağ ventrikülün duvarına kan taşır. Ana koroner damarlar ve bunların ilk kolları kalbin dış yüzeyinde bulunur. Oksijenlenmiş kan miyokarta giren daha küçük damarlarla taşınır. Şekil 2.3'de görüldüğü gibi küçük miyokart içi damarlar kanı toplar ve koroner sinüs, büyük orta kardiyak toplardamar, sağ karıncık alt toplardamarı gibi daha büyük toplardamarlarda birleşir ve sağ kulakçıktaki bir açıklığa kanı boşaltır.



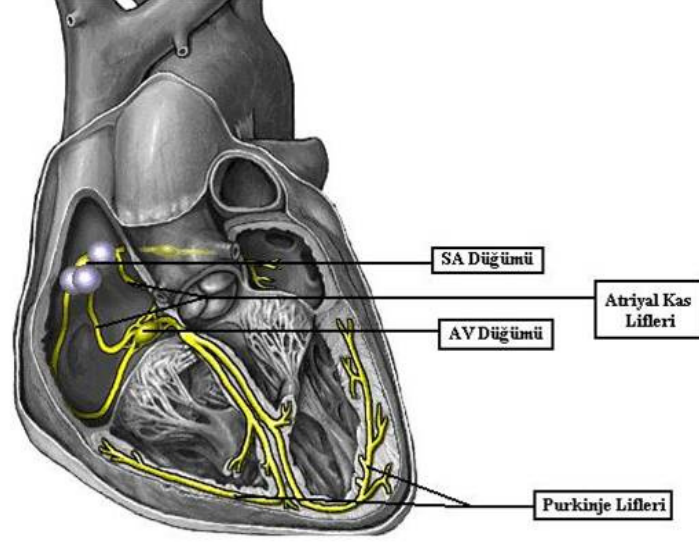
Şekil 2.3 Kalbin ana koroner damarları.

2.4 Kalp Elektrofizyolojisi

Aritmilerin oluşum mekanizmalarını ve yapılarını anlamak için kalp elektrofizyolojisi, iletim sistemi, kalp ritminin nasıl oluştuğu konularında bilgi sahibi olmalıyız. Kalp iletim sisteminin temel bileşenleri şunlardır [42]:

- A. İleti sistemi, benzersiz elektriksel özellikleri olan modifiye kardiyak kası hücrelerinden oluşmaktadır.
- B. Sinoatrial (SA) düğüm:
 1. SA düğüm sağ atriyumun üst sağ köşesinde küçük (1 mm) bir hücreler topluluğudur.
 2. SA düğüm, en hızlı intrinsik depolarizasyon hızına (60-100 atım/dk) sahip olmasının verdiği özelliklerle kalbin ritmini kontrol eder.
 3. SA düğüm atriyal sistolü başlatarak kardiyak siklusü başlatır.
- C. Atrioventriküler (AV) düğüm:
 1. AV düğüm interatrial septumun inferior kısmında yerleşiktir.
 2. Av düğümün iki fonksiyonu vardır:
 - a. Ventriküler sistolden önce atriyumların dolmasına olanak veren fizyolojik bir ileti gecikmesini sağlar.
 - b. Ventrikülleri, atriyumlardan kaynaklanan atriyal fibrilasyon gibi, aşırı stimülasyona maruz kalmaktan korur.
- D. His-Purkinje sistemi:
 1. His dalı, sağ ve sol dallar olmak üzere ikiye ayrılır.
 2. Sol dal daha sonra sol anterior ve posterior dalcıklara (fasikül) ayrılır.
 3. His-Purkinje sistemi ventriküllerin düzenli olarak depolarize olmasını sağlar.

Kalp iletim sistemi Şekil 2.4'de gösterilmiştir ([43]'den alınmıştır). Bu yapıdaki iletim bozuklukları, iletim gecikmeleri kalp ritminde düzensizlikler olarak ortaya çıkar.



Şekil 2.4 İnsan kalbinin iletim sistemi.

2.5 Aritmi

Bu kısımda çalışmanın odak noktası olan aritminin oluşum nedenleri, yapıları, teşhis ve tedavileri üzerinde durulmuştur.

Aritmi, kalp ritmindeki düzensizlik demektir. Normalde kalp atımı, sağ kulakçıkta başlar. Sağ kulakçıkta elektrik uyarılar çıkaran sinüs düğümü adı verilen özel hücre grupları vardır (doğal tempo tutucu). Uyarı kulakçıkta atrioventriküler düğümüne gelir. Atrioventriküler düğüm, uyarıyı karıncıklara taşıyan yollarla (sağ dal, sol dal) bağlantılıdır. Uyarının bu yollar aracılığı ile bütün kalpte dolaşması sonunda önce kulakçıklar kasılarak kan karıncıklara pompalanır. Saniyeden kısa bir süre içinde kasılan karıncıklar yardımıyla kan tüm vücuda dağıtılır. Bu işlem normalde dakikada 60-100 kez tekrarlanır. Gerek uyarının sinüs düğümünden başka yerlerden çıkması, gerek iletim yollarındaki aksaklıklar (blok) ve gerekse sinüs düğümünün anormal çalışması bu normal süreci bozar ve aritmi denilen kalp atım bozukluklarına neden olur. Aritmi, atımlar arasındaki aralıkların kısalıp uzaması ve atım sayısının anormal ölçüde artmış (taşikardi) veya azalmış (bradikardi) olması halidir. Değişik kalp hastalıkları (kalp kası hipertrofisi, kalp

kasının iltihabi hastalıkları, elektrofizyolojik anormallikler), kalp kapaklarındaki bozukluklar, koroner arter hastalığı, kalp yetersizliği, kafein, kokain, bazı astım ve soğuk algınlığı ilaçları ve bazı bitkiler (ephedra-denizüzümü, guarana-kafein içeren Brezilya bitkisi, licoricemeyankökü) aritminin oluşma sebepleridir. Aritmiler hiçbir sebep olmadan da ortaya çıkabilir.

Genel olarak kalbin ventriküllerinden çıkan aritmiler atriyumlardan çıkan aritmilere göre daha ciddidir. Bazı aritmi türleri şunlardır [44;45]:

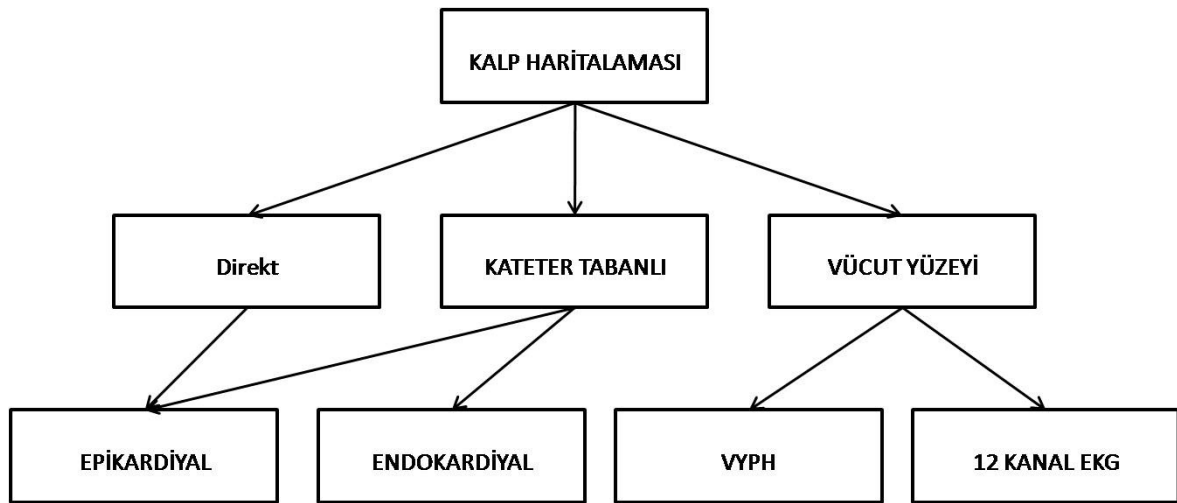
- **Atriyal Fibrilasyon:** Atriyal fibrilasyonda kalbin atriyumlarında kaslar organize olarak kasılmayıp sadece titreşir. Atriyumlar ventrikül ile koordine çalışmaz. Hasta düzensiz ve boyunda dolgunluk hissi verebilen farklı şiddette nabız atışları hisseder. Atriyal fibrilasyon kalp hızında artışa neden olur ve kalbin kan pompalamasını azaltabilir.
- **Bradikardi:** Bradikardi kalp hızının düşük olması demektir. Bradikardi kalbin doğal ritim düzenleyicisi sinüs düğümünün düşük bir ritim çıkarması veya hiç atım başlatmaması ile oluşur. Sinüs düğümünün iyi çalışmadığı durumlarda kalbin diğer odakları daha düşük hızlarda ritim oluşturur.
- **Paroksizmal Supraventriküler Taşikardi:** Normal olarak kalbin alt ve üst boşlukları arasında tek bir sinyal iletim yolu vardır. Elektrik sinyal normal sinyal iletim yolundan geçip anormal ikinci bir sinyal yolu ile geri dönerse bir kısa devre oluşur ve kalp çok hızlı atmaya başlar.
- **Ventriküler Taşikardi:** Ventriküler taşikardi daha nadir rastlanan fakat en tehlikeli aritmi türüdür. Kalp düzenli bir şekilde atar fakat çok hızlıdır. Ritim sinüs düğümü yerine ventriküllerden çıkar. Bu tür çarpıntılar, genelde altta yatan kalp hastalıkları olduğunda ortaya çıkar.
- **Ventriküler Fibrilasyon:** Ventriküler fibrilasyon en ciddi aritmi türüdür. Kalp düzensiz ve hızlı ritim yüzünden kasılmayıp sadece titreşmektedir bu yüzden kan pompalayamamaktadır. Ventriküler fibrilasyonda dolaşım durmakta ve şuur kapanmaktadır (kardiyak arrest). Bu aritmi türünde dakikalar içerisinde müdahale yapılmazsa kalıcı beyin hasarı ve ölüm gerçekleşebilmektedir.

Aritmi tanısı; elektrokardiyografi (EKG), Holter testi, transtelefonik izleme ve elektrofizyolojik çalışma (Electrophysiological Study, EPS) yöntemleri ile konur. EKG, kalbin elektriksel aktivitelerinin kaydedilmesidir. Holter testi, hastanın günlük hayatı sırasındaki EKG değişikliklerini kaydeden bir cihazdır. Bu test sayesinde diğer EKG testlerinde görülemeyen ritm bozuklukları veya iskemik bulgular saptanır. Transtelefonik izleme, hastanın kaydedici cihazı 24 saatten daha uzun süre taşıdığı ve hasta aritmi hissedince bu bilgiyi, izleme istasyonuna ya anında ya da kaydederek daha sonra telefon yardımıyla iletildiği aritmi teşhis yöntemidir. Bu test daha çok nadir gelen aritmileri saptamakta yararlıdır. EPS yönteminde, genellikle kasık toplardamarından girilerek, ince ve esnek bir tüp (kateter) yardımıyla sağ kulakçık ve karıncığa ulaşılır. Gerekirse farklı yaklaşımlarla kalp sol tarafına da ulaşılabilir. Kalbin elektriksel aktivitesi izlenir. Bu test, doktorların aritminin tipini ve tedaviye nasıl cevap verdiğini saptamalarına yardım eder.

Aritmi teşhisinin konulmasının ardından tedavi olarak ilaç tedavisi, kardiyoversiyon, kalp içi defibrilatör (ICD), kalp pili (pacemaker), ablasyon gibi yöntemler uygulanabilir. İlaç tedavisinin yan etkileri fazladır. Aritmiyi artırabilir. Dozun tesbitinde sürekli doktor kontrolü ve EKG testleri kullanılmalıdır. Kardiyoversiyon, kalbi normal ritmine döndürmek için acil durumlarda, doktorlar tarafından göğüs duvarına uygulanan elektrik şokudur. ICD, ani ölümlere sebep olacak ciddi ventriküler aritmiler söz konusu olan durumlarda kullanılır. Cihazın gövdesi göğüs kasının içinde oluşturulan yuvaya, elektrotlar kalp içine yerleştirilir. Bu cihaz, kalp ritmini izler. Önemli ve tehlikeli aritmileri ayırdeder. Gerekliğinde elektrik şoku vererek ölümcül aritmileri düzeltir. Kalp hızının yavaşlamasına bağlı ölüm riski taşıyan hastalarda ayrıca pacemaker fonksiyonundan da yararlanılmaktadır. Kalp pili, sinüs düğümünün düzgün çalışmadığı durumlarda veya kalp içi elektriksel iletim yollarında blok varsa, bu cihaz elektiriksel uyarılar göndererek kalbin düzgün çalışmasını sağlar. Ablasyon, elektrofizyolojik araştırma ile aritmiye sebep olan odak bulunabildiği takdirde bu odağın radyo-frekans dalgaları yardımıyla susturulması yöntemidir [46].

2.6 Kalp Haritalaması

Kardiyak haritalama aritminin teşhisi ve yerinin belirlenmesi işlemidir. Kalp haritalaması (cardiac mapping), kalbin elektriksel potansiyelinin konumsal dağılımının zaman fonksiyonu veya aktivasyon zamanı fonksiyonu olarak elde edilmesini ifade eden genel bir terimdir. Kalbin haritalanmasında, aritminin ortaya çıkmasında önemli rol oynayan anormal iletim bölgelerinin bulunması ve tedavinin o bölgelere yönlendirilmesi hedeflenmektedir. Haritalama için kullanılan prensipler ve teknikler aritminin kaynaklandığı kalp dokusuna bağlı olarak değişim gösterir. Hastanın geçmişi, ekokardiyografi ve diğer görüntüleme verileri, sinüs ritmi (normal ritim) ve klinik aritmi sırasında alınan 12 kanal elektrokardiyogram bilgileri haritalamanın başlangıç stratejisinin seçiminde fayda sağlarlar. Geleneksel temas kateterleri ile yapılan haritalama en çok kullanılan yöntemdir. Kalbin uygun yerlerine; sağ atriyum, atriyoventriküler (AV) düğüm, koroner sinüs, sağ ventrikül, sol atriyum veya ventriküle, kateterlerin yerleştirilmesiyle alınan bilgiler operatör tarafından normal ve normal olmayan hastalarda sinüs ritmi, atım ya da taşikardi sırasındaki aktivasyon olarak ayırt edilir. Elektrogramlardan elde edilen morfolojik ve zamanlama bilgileri ve belki gezici bir kateterden alınan bilgiler tamamlayıcı bilgilerdir. Bu bölümde kalp haritalamasında kullanılan yöntemler 12 kanallı EKG, VYPH, kateter tabanlı (endokardiyal ve epikardiyal) haritalama olmak üzere üç grup altında anlatılacaktır. Şekil 2.5’de kalp haritalaması yöntemleri şematik olarak gösterilmiştir.



Şekil 2.5 Kalp haritalaması yöntemleri.

2.6.1 Elektrokardiyogram (EKG)

Kalp haritalaması yöntemlerinden birisi olan 12 kanal EKG ve klasik EKG yapısı, gelişimi ve kullanım alanları bu kısımda kısaca özetlenmiştir.

Klasik elektrokardiyografi 1913 yılında Einthoven ve arkadaşlarının [47] yapmış olduğu çalışmayla başlar. Bu çalışmada sağ ve sol kol ile sol bacak üzerine yerleştirilen LA, RA, LL elektrotları suretiyle ölçüm sistemi oluşturulmuştur. Ventriküllerin değişik kesimlerinde yayılan depolarizasyon dalgaları birer elektriksel dipolle temsil edilebilir. Kalpteki tüm elektriksel dipollerin toplamı sonucu elde edilen bileşke vektör [48], aynı zamanda kanal voltajlarının birleştirilmiş sonucu olup kalp dipolü veya kalp vektörü, V , olarak adlandırılır. Standart 12 kanallı EKG düşük veya yüksek kalp atımı, Wolff-Parkinson-White (WPW), AV düğümü yakınındaki ektopik atriyal aritmi, AV blok, miyokardiyal enfarktüs gibi anormalliklerin tespitinde önemli bir yere sahiptir [20]. 12 kanallı EKG klinikte sık kullanılmasına rağmen iki önemli dezavantaja sahiptir. Bunların birincisi; EKG değerlendirmesinde doktorun tecrübesi önemlidir ve bu nedenle kişisel yetenek ön plana çıkmaktadır. Diğer dezavantajı ise; elektrotların vücut yüzeyindeki yerleşimleri göz önüne alındığında birbirlerinde uzakta olduğu görülür ve bu da vücut yüzeyinde az noktadan potansiyel almaya sebep olmaktadır. Teknolojik gelişmelerle beraber bilgisayar-tabanlı elektrokardiyografik sistemlerle yüksek çözünürlüklü EKG alınabilmekte ve EKG'ye ek olarak birçok öznelik oluşturulabilmektedir. Bu öznelikler ortalama alma, Fourier analizi gibi teknikleri içerir. Bu yöntemler normal olarak görünmeyen ve ölçülemeyen elektrokardiyografik nitelikleri ortaya çıkarır.


Bu nedenle yüksek çözünürlüklü EKG standart EKG ile alınamayan kardiyak sinyallerin vücut yüzeyinden ölçülmesi ile ilgilidir. Sinyal-ortalı EKG, yüksek çözünürlüklü EKG'nin en genel şeklidir [49]. Bu teknikle girişimsel olmayan His-purkinje kayıtları [50], geç potansiyel incelemesi [51;52;53], güçlendirilmiş P-dalgası [54;55] ve QRS analizi [56;57] gibi uygulamalar son 30 yılda artış göstermiştir.

2.6.2 Endokardiyal Haritalama

Endokardiyal haritalama, bu çalışmada kateter tabanlı olarak yapılmıştır. Bu kısımda aritmi yerinin tespitinde kullanılan bu haritalamanın temel yapısı, CARTO ve temassız haritalama gibi bazı yöntemlerinden kısaca bahsedilmiştir.


Geleneksel kalp haritalaması yöntemleri aktivasyon dizisi haritalama, uyarı haritalama, sürüklenme (entrainment) haritalaması gibi yöntemlerdir. Kateterlerden alınan verilerin ve iki boyutlu floroskopik görüntülerden alınan konum bilgisinin yorumlanması açısından doktorun yeteneği işlem başarısında önemli bir rol oynamaktadır. Endokardiyal haritalamada geliştirilen yeni haritalama teknolojileri ise ablasyon ve lokalizasyon bilgilerini sağlayan sistemlerin kullanımını içermektedir. Bazı yöntemler haritalanan bölümün endokardiyal sınırlarının geriçatılmasını da sağlamaktadır. Birden fazla kaynak oluşturma ile daha fazla noktadan elektriksel bilgi almayı sağlayan ileri haritalama yöntemleri ile haritalama çözünürlüğü artırılmıştır.

CARTO ve temassız haritalama (EnSite 3000) gibi teknolojiler ile haritalanan odacığın endokardiyal geometrisini geriçatmayı içeren anatomi bilgisini sağlayan kateter yerleşim ve yönlendirimi ve elektrofizyolojik bilginin birleştirilmesine imkân vermektedir. Bu teknolojilerin önemli farklarından biri elektrofizyolojik verinin nasıl alındığıdır, bu da, CARTO'da dizisel, temassız haritalamada eşzamanlıdır. Genişleyebilir sepet (basket) kateterleri içeren sistemler eşzamanlı haritalamanın yanında aktivasyon haritalarının elde edilmesine izin vermekte olsa da bu sistemlerde kateter lokalizasyonu mümkün olmayıp harita çözünürlüğü sınırlıdır. Bu teknolojilerin klinik kullanımını güçlendirecek yazılım ve donanım geliştirilmesi üzerine çalışmalar devam etmektedir [20]. LocaLisa ve Gerçek Zamanlı Pozisyon Yönetimi (RPM) gibi teknolojiler temelde kateter lokalizasyonunu kolaylaştırır. Daha sonradan geometri geriçatması ve aktivasyon haritalaması için değiştirilmiş olan ikinci sistemde temas eden kateterler yardımıyla alınan elektrofizyolojik veriler entegre edilir [58]. Şekil 2.6'da CARTO'dan alınan potansiyeller, kalp geometrisine oturtulmuş olarak verilmiştir. Burada his demeti hegzagon ile gösterilmiştir. Kırmızı renk negatif potansiyelleri, mavi renk ise pozitif potansiyelleri göstermektedir ([20]'den alınmıştır).




Şekil 2.6 CARTO ile elde edilmiş sağ ve sol kulakçıkların haritaları.

Daha öncede bahsettiğimiz gibi CARTO ve RPM gibi gelişmiş haritalama teknikleri birden fazla kalp çevrimi gerektirir. Bu işlem zaman alıcı olduğu için, özellikle taşikardi süresiz ve hemodinamik olarak düşük toleranslı ise, veri noktaları ve haritalama çözünürlüğü sınırlı olabilir [20]. Miyokardiyal enfarktüs sonrası oluşan ventriküler taşikardiye sahip hastalar dışında %20'den daha az hastada aritmi dizisel haritalama için yeterince uzun zaman boyunca kendisini gösterir. Bu nedenle elektrogram verilerinin tüm odacıktan eşzamanlı olarak alınması daha etkilidir. Sepet kateter ve temassız haritalama temelli sistemler kalp odacığında birden fazla noktadan eş zamanlı veri almayı sağlar. Buna rağmen sepet kateterlerin kullanımı ile elde edilen haritalar elektrotlar arası uzaklığın fazla olması ve endokarta yaklaşmalarının tam olmaması nedeniyle sınırlı çözünürlüğe sahiptir. Şekil 2.7'de bir sepet kateterin farklı açılardan görüntüleri verilmiştir. Burada A-H harfleri kateter üzerindeki sekiz kolu ifade eder. Bu kollar üzerine belli sayıda elektrotlar yerleştirilir.



Şekil 2.7 Çok elektrotlu sepet kateter görüntüsü.

Temassız haritalama sistemi, haritalanacak odacığa yerleştirilen çoklu elektrot dizisi, kayıt, yükselteç ve grafik yazılımı gibi bölümlerden oluşur. Yükseltecin temas kateterlerinden gelen elektrogramlar için 16, EKG'ler için 12 girişi bulunmakta olup çoklu elektrot dizisinden gelen sinyalleri de kabul edebilir. Diziden gelen uzak alan elektrografik verisi yükselteç sistemine verilir, 1,2 kHz ile örneklenip filtrelenir. Düşük genlik ve frekanslı uzak-alan potansiyelleri matematiksel olarak yükseltilir. Laplace eşitliğine dayalı geri problem çözümü ile uzakta algılanan sinyalin kaynakta nasıl olduğu tahmin edilmeye çalışılır. Geri problem çözümünde gerekli olan çoklu elektrot dizisi ile endokart yüzeyi arasındaki geometrik ilişkinin tespitinde sınır elemanları yöntemi (boundary elements method) kullanılır [59]. Şekil 2.8'de temassız haritalamadan elde edilen kateter tabanlı haritalamaya bir örnek verilmiştir. Burada (1) Çoklu elektrot dizisini (MEA) ve haritalama kateterini (MAP) gösteren floroskopik görüntüdür, (2) sağ atriyal eşpotansiyel haritası, beyaz bölge en erken aktive olan endokardiyal bölgesi ifade eder ([20]'den alınmıştır).



Şekil 2.8 Temassız haritalama ile yerel sağ atriyal taşikardinin haritalanması ve ablasyonu.

Geleneksel haritalama kateteri ile temassız kateter üzerindeki halka elektrotlar arasındaki düşük akımlı 5,68 kHz'lik "yerleştirici" sinyali haritalama kateterinin göreceli yerinin bulunmasında kullanılır. Haritalama kateterini hareket ettirmek ve endokart sınırını izlemek suretiyle sistem, noktaların üç boyutlu konumunu alarak endokartın üç boyutlu modelini oluşturur (Şekil 2.8). Bu lokalizasyon sistemi aynı zamanda sanal endokart üzerinde hareketi sağlayarak floroskopi gerekmeksizin ablasyon ve haritalamaya rehberlik eder. Laplace denkleminin geri çözümü ile sistem temassız dizinin 64 elektrotundan elde edilen potansiyellerden 3360 sanal endokardiyal elektrogramı oluşturur. Temassız elektrofizyolojik veriler geriçatılmış sanal elektrogramlar, eşpotansiyel harita serileri veya eşzaman haritaları olarak gösterilebilir. Bu sistemin temassız elektrogramlar ve kateter lokalizasyonu doğruluğu in vitro [21], hayvan deneyleri [21;22] ve insanlar [23;24] üzerinde onaylanmıştır. Klinik olarak da sistemin dört odacığını ilgilendiren anormallikler üzerinde haritalama ve ablasyon yapılmasında etkili olduğu görülmüştür [25;26].


Ventriküler taşikardilerin çoğunun orijini alt-endokart olsa da, kritik kısımları alt-endokart ile alt-epikart arasında miyokartın herhangi bir bölümünde olabilir [23]. Bu taşikardilerin %5 ile %15 arasındaki bölümünün alt-epikardiyal alanda olduğu düşünülmekte olup [24] bunlarla ilgili yeterli tanımlama tedavi için kritiktir [20].

2.6.2 Epikardiyal Haritalama

Endokardiyal haritalama, epikardiyal haritalama gibi bu çalışmada kateter tabanlı olarak gerçekleştirilmiştir. Bu kısımda haritalamanın esasları, haritalama yöntemleri ve uygulamaları hakkında kısaca bilgi verilmiştir.

Epikardiyal haritalama göğüsün açılması suretiyle proplar, parmak elektrotları, plakalar ve epikardiyal çoraplar gibi çoklu veri elde etme sistemleri ile direkt olarak ölçümü içerir. Açık cerrahi işlemlerin fazla girişimsel olması kullanımlarını sınırlandırmıştır. Bu işlemler ancak kapakçık değişimi gibi diğer cerrahi operasyonlarla beraber gerçekleştirilmektedir [20]. Açık cerrahi işlemlerinin fazla girişimsel olması nedeniyle daha az girişimsel olan yöntemler geliştirilmiştir. Transvenöz haritalama tekniği elektrotları içeren haritalama kateterlerinin kardiyak toplardamarlara (coronary veins) yerleştirilmesi suretiyle epikardiyal elektrogramların kaydedilmesini içermektedir. Bu teknik, cerrahi işleme göre daha kolay ve güvenli olarak sayılsa da kardiyak toplardamar sistemi ile sınırlıdır [26;27;29]. Bu yöntem kullanılarak koroner atardamar kolları civarındaki epikardiyal ventriküler taşikardilerin haritalanması da gerçekleştirilmiştir [30].

Epikardiyal haritalamada kullanılan bir diğer yöntem ise perkütanöz haritalama tekniğidir. Bu yöntemde bir 7-Fr kılıf subksifoid (subxiphoid) delik içerisinde perikardiyal boşluğa geçirilir [23]. Bu işlem Şekil 2.9'da gösterilmiştir ([20]'den alınmıştır). Daha sonra farklı haritalama ve ablasyon kateterleri kullanılarak epikardiyal haritalama gerçekleştirilir. Bu yöntemin avantajları trombolik komplikasyonlar ve antikoagülasyon gibi kateter manipülasyonlarını içermemesidir. Bu avantajlara rağmen göğüsten açılan delik içerisinde oluşabilecek komplikasyonlar ve perikartın zarar görmesi gibi dezavantajlar da mevcuttur. Epikardiyal haritalama endokardiyal haritalamanın gideremediği bazı uygulamalarda kullanılarak başarılı sonuçlar elde edilmiştir [34;35;36]. Bu yöntemin diğer uygulamaları ventriküler aritmilerin yapısını anlamaya yönelik olarak gerçekleştirilen deneysel çalışmalardır [37;38].



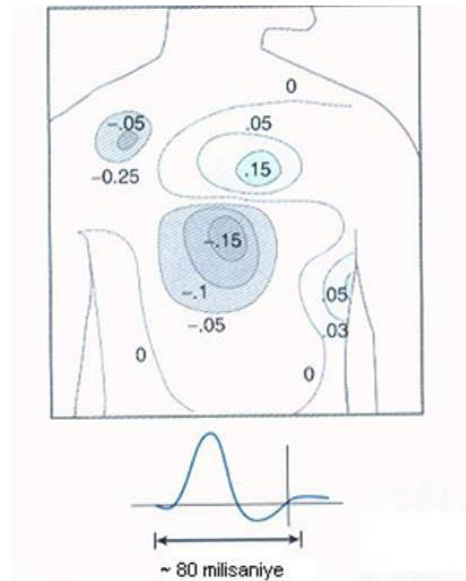
Şekil 2.9 Perikardiyal boşluğa haritalama/ablasyon kateterinin yerleştirilmesi.

2. 7 Vücut Yüzeyi Potansiyellerinin (VYP) Haritalanması

Kalp haritalama yöntemlerinden birisi olan VYP haritalaması, girişimselliği olması nedeniyle bu çalışmada aritmi yerinin tespitinde kullanılan yöntemlerden biridir. Bu kısımda VYP haritalarının tanımı, kullanım alanları ve temel zorlukları hakkında bilgi verilmiştir.

12 kanallı EKG sistemlerindeki düşük konumsal çözünürlük, vücut yüzeyine (toraksa), ek olarak başka elektrotların yerleştirilmesi ile aşılmaya çalışılmıştır. Toraksın ön ve arka kısımlarına 16 ila 240 arası yerleştirilen elektrotlarla alınan verilerin 12 kanallı EKG ile alınan verilerden bazı hastalıkların teşhisinde çok daha detaylı ve faydalı bilgiler verdiği tespit edilmiştir. Bu tekniğe vücut yüzeyi potansiyel (VYP) haritalaması denilmektedir ve kalpteki potansiyellerin vücut yüzeyi üzerindeki konumsal dağılımını gösterir. Bu haritalar, vücut yüzeyinden alınan tek kutuplu elektrokardiyogramlardan (EKG) elde edilir [60;61]. EKG'lerin genlikleri PQRSTU aralıklarında belirli zamanlar için ölçülür. Değerler milivolta çevrilir ve vücut yüzeyini temsil eden harita üzerinde çizilir. Daha sonra, genellikle doğrusal aradeğerleme (enterpolasyon) tekniğiyle, eş potansiyel eğrileri çizilir (Şekil 6) [62]. VYP haritaları 12 kanallı EKG'ye göre daha fazla elektriksel ve tanısal bilgi sağlar: (1) Yeterli sayıda elektrot kullanarak vücut yüzeyinde elde edilebilecek elektriksel bilginin tümünü içerir; (2) 12 kanallı EKG sistemi ile alınamayan önemli elektriksel bilgiyi ortaya koyar; (3) çoğu zaman, ardı ardına gerçekleşen bir veya daha fazla elektriksel belirti, örneğin uyarılma toparlanma

veya sağ ve sol karıncığa doğru yayılan iki ayrı uyarılma dalgasını gösterir; (4) vücut yüzeyi elektrotlarının herhangi bir çifti veya kombinasyonundan elde edilebilen herhangi bir EKG'nin hesaplanmasını sağlar (5) VYP haritaları epikardiyal potansiyel dağılımları, uyarılma zamanı ve elektrogramların girişimsel olmadan geriçatılmasında (reconstruction) kullanılabilir [62]. Son yıllarda bazı çalışmalar, vücut yüzeyine yerleştirilen elektrotlar vasıtasıyla endokardiyal uyarılma zamanlarının da geriçatıldığını göstermektedir [63]. Son 40 yılda VYP haritaları üzerine klinik ve deneysel amaçlı yüzlerce makale yayınlanmıştır. VYP haritaları, atriyal dalgalanma [5], Wolff-Parkinson-White sendromu [6], miyokardiyal enfarktüs [7;8], ventriküler veya atriyal aritmilerin kaynak yerinin belirlenmesi [9], doğuştan gelen kalp hastalıklarının teşhisi [10] gibi durumlarda kullanılmıştır. Şekil 2.10'da örnek bir VYP haritalaması verilmiştir. Burada alt taraftaki şekil sağ kol üzerinden alınmış elektrokardiyogramı göstermektedir. QRS'ten ST aralığına geçiş sırasında uyarılma potansiyelleri (+0.15 mV ve -0.15 mV) hala görülebilmekte ve repolarizasyon potansiyelleri (-0.05 mV ve +0.05mV) görülmeye başlamaktadır ([20]'den değiştirilmiştir).



Şekil 2.10 Normal bir kişiden alınmış vücut yüzeyi potansiyeli haritası.

Son 30 yılda EKG ve VYP haritalar kullanılarak birçok yeni vücut yüzeyi haritaları oluşturulmuştur. Bunlar isointegral haritaları, temel bileşen analizi, aktivasyon-repolarizasyon ve aktivasyon-repolarizasyon aralığı (ARI) haritalarıdır.

Daha önce bahsedilen avantajlarına rağmen, vücut yüzeyi elektrokardiyografik haritalanması halen klinikte rutin olarak kullanılan bir uygulama değildir. VYP haritaları üzerine araştırma makaleleri, kardiyak elektrik alan ve ilintili matematiksel modellerle ilgili makaleler literatürde hızla artmaktadır. Buna rağmen VYP haritaların klinik makaleleri en üst düzeyi ulaştıkları 1980'lerin ortalarından itibaren hızla azalmaktadır. Bu azalmanın nedeni aşağıda verilen zorluklar olabilir:

Teknik problemler: Temel teknik problemler, her hastadan binlerce ya da yüzlerce kanaldan gelen bilgilerin kayıt edilmesi ve sayıları 240'a varabilen vücut elektrotlarından oluşan sistemin karmaşık olmasından kaynaklanmaktadır. Açıkça, farklı elektrot sistemlerinden gelen haritalar farklı bilgiler içeriyor olabilirler. Kanal sayıları, yerleştirilmeleri, görülebilir özelliklerin (maksimum, minimum) büyüklükleri her sistem için değişiktir. Aynı hastadan farklı sistemlerle alınan haritaların birbirlerine dönüştürülmesi ile ilgili makaleler yayınlanmıştır.

Pratik Problemler: Sağlıklı bireylerde ve kalp hastalarında tek bir kalp atımı süre içinde VYP haritalarında ortaya çıkan anlık potansiyel yüzeylerin değişimlerini kaydetmek pratik olarak kolay değildir. Bu zorluk, integral haritaları veya pseudoisochrone VYP haritaları ile kısmi olarak giderilebilir. Bu yöntemler her hastadan alınan sadece birkaç haritayı kaydetmek üzerine kuruludur. Fakat ardışık potansiyel dağılımların sağladığı uzaysal ve zamansal bilgide kayıplara sebep olurlar.

İletim Sırasında Oluşan Kayıplar: Kalp tarafından üretilen elektriksel sinyaller, vücut yüzeyine ulaşana kadar bozulmaya ve yumuşamaya maruz kalmaktadırlar. Bunun sonucu olarak, kardiyak yüzeyde veya ventriküler duvarların ince yüzeylerinde oluşan önemli elektrofizyolojik olaylar vücut yüzeyi üzerinde gözlenememektedir.



Yorumlama Zorlukları: VYP haritalarından klinik olarak yararlanmanın önündeki en ciddi engellerden birisi yorumlama zorluğudur. Çoklu, zamanla değişen VYP

haritaların özelliklerini (sayı, yer ve potansiyellerin maksimumlarının hareketi, minimumlar vb...) karşılık gelen kalp üzerindeki olaylarla (sayı, biçim, yer ve yayılım dalga formlarının hareketi, repolarizasyon ardışıklığı vb...) ilişkilendirebilmektir. Bu zorlukların nedeni ise, vücut yüzeyi üzerinde her noktadaki potansiyelin bütün kalp yüzeyinden gelen sinyallerin ağırlıklı toplamı olmasıdır.

Epikardiyal potansiyel kaynak modeli, kalp ve vücut yüzeyi arasındaki kaynak-bağımsız hacimde Laplace eşitliğinin çözümü temellidir [64]. Her iki yüzeyi de içeren bir geometrik model ve kapsanan hacim içindeki veya ara bölgelerdeki elektriksel iletkenlik çözüm için gerekli elemanlardır. Böyle bir modelin kurulması, özellikle bilgisayarlı tomografi (CT) veya manyetik rezonans görüntüleme (MRI) gibi ayrı anatomik bilgilerin elde edilmesini gerektirir. Sonuç görüntüleri farklılaştırılmalı ve bölümlenmelidir [65], elektrot pozisyonları geometri üzerine uyarlanmalıdır ve yüzey açıklamaları için üçgenler hacim modelleri için beşgen veya altıgen poligonlar ile birbirine geçirilmiş bağlar olarak uzayda bir düğüm seti ile ifade edilen anatomik yapılar yine geometri üzerine uyarlanmalıdır [66]. Toraks (göğüs) içinde iletkenlik lokal olarak değişmektedir bu da alan kuvvetlerinin lokal olarak değişmesine sebep olmaktadır; bununla birlikte bu etkinin ters çözüm üzerindeki önemi henüz tam olarak hesaplanamamıştır. Modelde bulunan içsel organların genellikle parçalı homojen bazen de anizotropik iletkenliklere sahip oldukları kabul edilir. Geometri zamanla değişmez olarak ele alınır (pratikte durum bu değildir ama bu yaklaşım diğer gerekli yaklaşımlara yakın bir hata oluşumu sağlamaktadır) [67], bu yüzden ileri problemin zamanda her an için çözümlenmesi gerekir. Hacim iletkeninin yüklenme etkileri de ihmal edilir, fakat son zamanlardaki deneysel kanıtlar bu kabullenmenin doğru olmadığını göstermiştir [68]. Kalp yüzeyinden alınan potansiyel bilgileri (veya aktivasyon zamanları), voltajın devamlılığı ve içsel dağınıklığın akım dolaşan yüzeylerinin normal bileşenlerinin devamlılıkları ileri çözüm için sınır koşullarıdır. Ortak merkezli ya da dış merkezli küreler gibi basit geometriler ile ileri problemin analitik çözümleri mümkün ise çoğu yazar birleştirilmiş düğümlerin yapılar gibi realistik geometrileri kullanarak daha pratik yaklaşımlar üzerinde yoğunlaşırlar [69]. Maxwell denklemlerinin quasi-statik versiyonlarından hacim integral eşitliklerinin yazılması, uygun sınır koşulları ile Green teoremi yüzey integral eşitliklerinin uygulanması gibi özel çözüm

yaklaşımları geometrideki bütün yüzeylere uygulanabilir. Elde edilen integral eşitlikleri geometrik birleşimin düğümlerinde farklılaştırılır ve yüzey integralleri için sınır elemanları yöntemi (BEM) ya da hacim integralleri için sonlu element yöntemi (FEM) gibi standart teknikler kullanılarak çözülürler [70]. Bu iki yöntemi bir arada kullanan algoritmalar geliştirilmiştir [71;72]. Şekil 2.11'de epikardiyal potansiyel ve karşılık gelen vücut yüzeyi potansiyel haritası verilmiştir. Burada üç boyutlu kalp geometrisinde ve torso yapısındaki aynı renkler eşit potansiyelleri ifade etmektedir.

Kırmızı renk negatif potansiyel değerlerini, mavi renk ise pozitif potansiyel değerlerini gösterir.



Şekil 2.11 Epikardiyal ve torso haritalamaları.


2.8 Yapay Sinir Ağları

Kümeleme ve sınıflandırma için kullanılan OSA, BCO ve SOM birer yapay sinir ağı uygulamalarıdır. Bunların çalışma prensiplerini anlamak için öncelikle yapay sinir ağlarının temel çalışma mekanizmalarını anlamamız gerekmektedir.

Yapay sinir ağları, insan beyni ile benzer şekilde çalışırlar [73]. Deneyimler yoluyla öğrenirler ve karmaşık hesaplamalara dayanan sorunlara çözüm getirirler. Bir topluluk içinden belli bir yüzü nasıl seçeriz? Ya da bir uçağın iniş rotasını tahmin edip, hatalara nasıl daha oluşmadan müdahale edebiliriz? İşte bu tip durumlarda, insan beyni "sinir hücreleri" adı verilen birbirine bağlı bir grup işlem birimi kullanır.

Bu işlem birimlerinin (sinir hücreleri) öğrenmeyi ve hatırlamayı sağlayan özellikleri vardır. Her sinir hücresi bağımsızdır. Her biri kendi işini görür, diğer birimlerle eşzamanlı olarak çalışma ihtiyacı duymaz. İnsan beyninin taklidi olan yapay sinir ağlarının basit ya da karmaşık birçok çeşidi vardır. Örneğin, katmanlardan oluşan ileri beslemeli bir sinir ağında her katman işlem birimleri, yani sinir hücrelerinden oluşur. Katmanlar aldıkları veriler üzerinde bağımsız hesaplamalar yapar ve sonuçları bir sonraki katmana iletir. Son katman ise ağın çıktısını belirler [73].

Temel olarak, bir yapay sinir hücresinin iç aktivasyonu ya da ham çıktısı, girdilerin ağırlıklandırılmış toplamıdır. Ancak genelde son değeri belirlemek için bir eşik fonksiyonu da kullanılır. Çıktı 1 ise, sinir hücresi harekete geçer (aktif hale gelir). Çıktı 0 ise, sinir hücresi harekete geçmez. Yapay sinir ağlarındaki bu girdi çıktı ilişkisi Şekil 2.12’de verilmiştir.

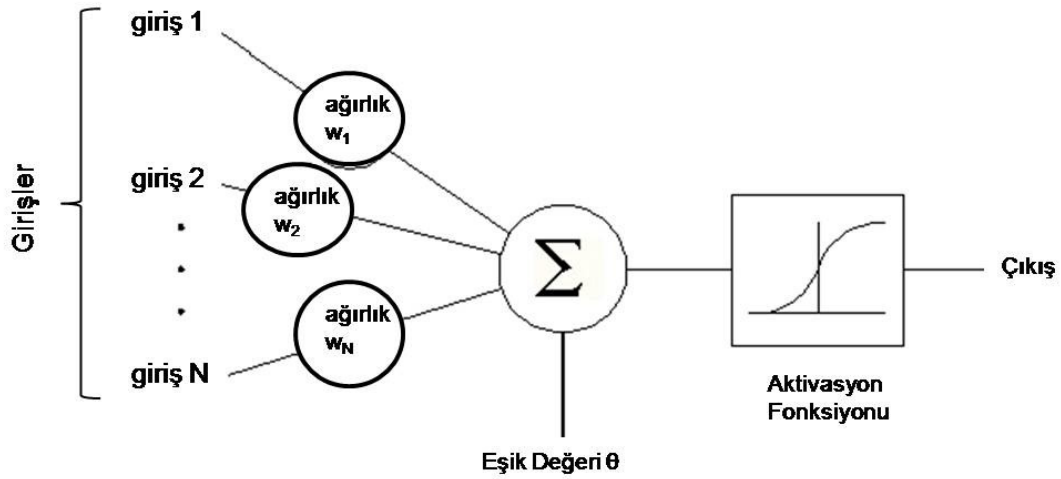


Şekil 2.12 Yapay sinir ağı katmanları.

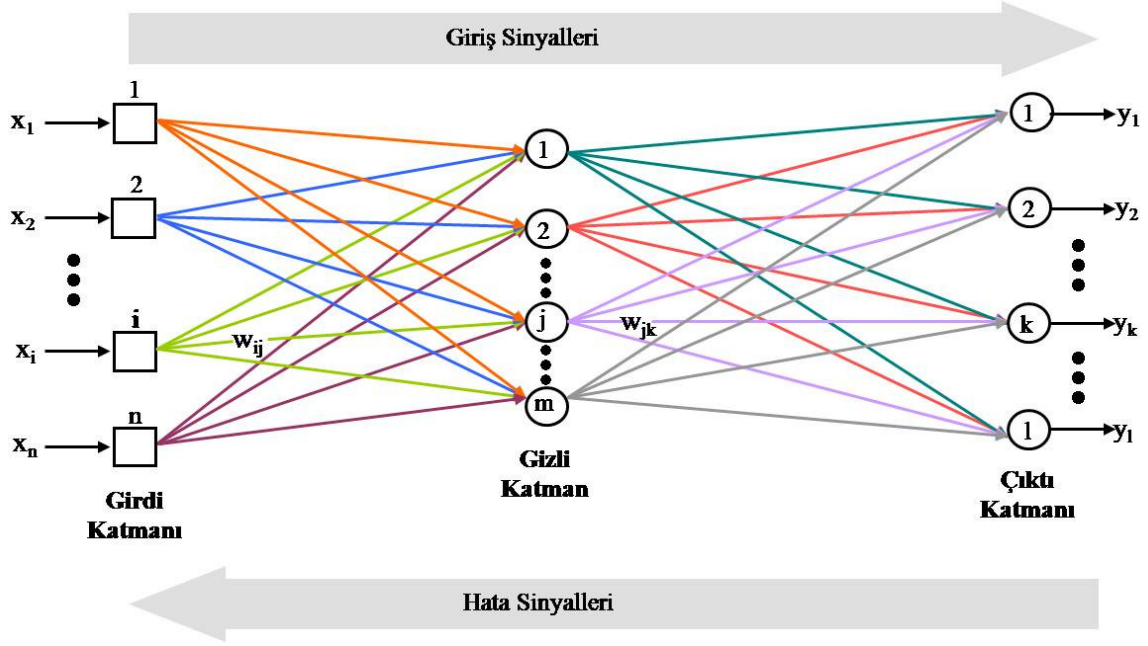
Yapay sinir hücrelerini birbirine bağlayan bağlantıların her birinin sayısal bir ağırlığı vardır. Yapay sinir ağlarında bu ağırlıklar, uzun dönemlik hafızaya karşılık gelir. Bir yapay sinir ağı bu ağırlıkların tekrar tekrar ayarlanması sayesinde öğrenir [73]. Tek katmanlı yapay sinir ağları sadece girdi ve çıktı katmanlarından oluşur. En basit tek katmanlı sinir ağı modeli perseptron’dur. Perseptron modeli eğitilebilen tek bir yapay sinir hücresinden oluşur. Bu modelde ağırlıklandırılmış girdiler aktivasyon

fonksiyonuna uygulanır ve +1 ya da -1 şeklinde bir çıktı alınır. Perseptron'un amacı girdileri sınıflandırmaktır. Bu demektir ki n -boyutlu uzay şeklindeki gibi bir doğru ya da düzlem ile iki bölgeye ayrılır.

Çok katmanlı sinir ağları bir ya da daha fazla gizli katmanı olan ileri beslemeli sinir ağlarıdır. Genelde bu ağ bir girdi katmanı, en az bir gizli katman ve bir de çıkış katmanından oluşur. Gizli katmanlara ihtiyaç duyulmasının sebebi girdi katmanlarından gelen genellikle işlenmemiş sinyallerin özelliklerini belirlemek, ağırlıklandırmak ve sonuçları çıkış katmanına yönlendirmektir. Gizli katmanlara "gizli" denilmesinin sebebi istenilen çıktı değerini saklamasıdır. Gizli katmandaki sinir hücreleri ağın giriş ve çıkış davranışlarının incelenmesi yoluyla gözlemlenemez. Şekil 2.13'de perseptronun matematiksel modeli verilmiştir. Şekil 2.14'de ise çok katmanlı bir YSA yapısı gösterilmiştir.



Şekil 2.13 Perseptron yapısı.

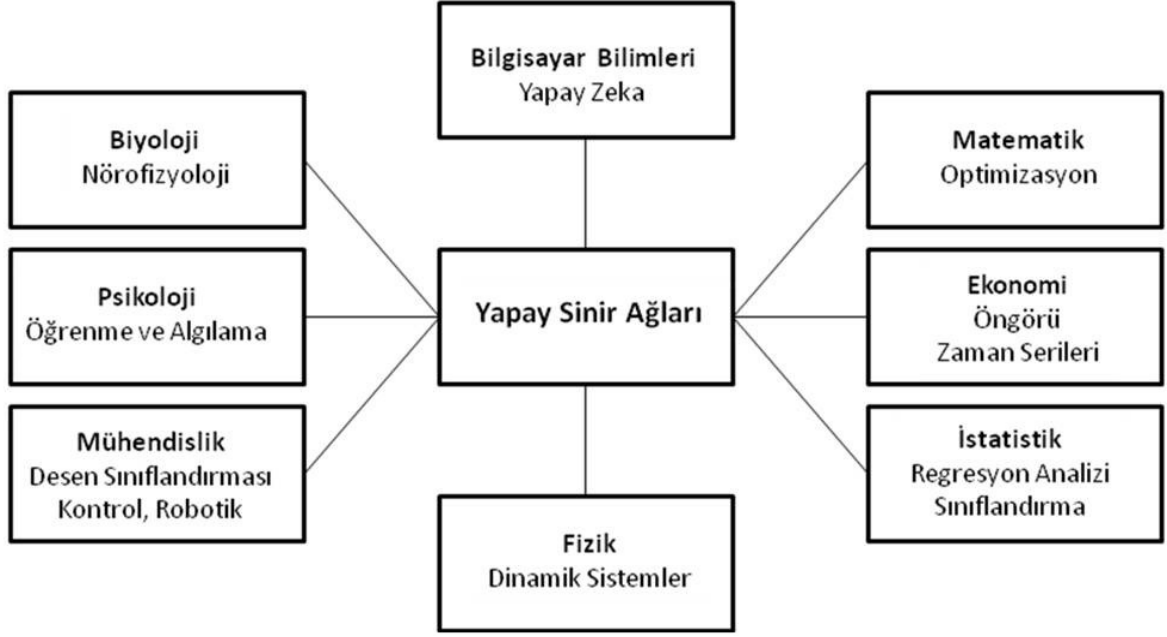


Şekil 2.14 Çokkatmanlı yapay sinir ağı yapısı.

Yapay sinir ağlarının kullanım alanları şunlardır [74]:

- **Sınıflandırma:** Kategoriler arasındaki farkları belirlemek. Bir sınıflandırma sisteminin temel amacı, bir objenin özellik vektörünü elde etmek ve bu özelliklere göre ait olduğu kategoriyi bulmaktır.
- **İlişkilendirme:** Değişkenler arasındaki ilintiyi bulmak.
- **Özellik Çıkarımı:** Veri setini içindeki değişmeyenlerin bulunması.
- **Yaklaşım:** Yeni bir girişe karşı gelen çıkışın tahmin edilmesi.
- **Desen Tamamlama:** Tamamlanmamış girişten hafızaya alınmış desenin tekrar yaratılması.
- **Kontrol:** Verilen giriş setinden doğru çıktıların hesaplanması.

Şekil 2.15'de YSA kullanım alanları çizim olarak gösterilmiştir ([74]'den alınıp değiştirilmiştir).



Şekil 2.15 Yapay sinir ağlarının genel kullanım bölgeleri.

Ayrıca tahmin sistemlerinde, optimizasyon sistemlerinde ve veri sıkıştırma sistemlerinde de yapay sinir ağlarından yararlanılmaktadır.

Yapay Sinir Ağlarının başlıca avantajları şunlardır:

- **Doğrusal Olmamak:** doğrusal olmayan fonksiyonların ve işlemlerin modellenmesini sağlar. Bütün ağ doğrusal olmamak üzerine kurulabilir. Tipik olarak her nöronun bir doğrusal olmayan çıkışı vardır.
- **Giriş – Çıkış Haritalaması:** Eğıtmensiz öğrenimde giriş-çıkış haritalaması eğitim verisinden öğrenilir. Bu çalışmada kullanılan Kohonen SOM ve BCO kümeleme yöntemleri eğıtmensiz haritalamaya örnek olarak gösterilebilir. Bazı istatistiksel kriterler kullanılır. Ağ içinde ağırlıklar bu kriterleri optimize etmek için değiştirilirler.
- **Uyum Sağlama:** Ağırlıklar (parametreler) yeni veriler ile tekrar eğitilebilirler. Çevrenin yavaş değişimlerine karşı ağ kendini düzenleyebilir.
- **Hata Toleransı:** Eğer bir nöron hasara uğramışsa sistem performansı bundan çok etkilenmez. Dijital oluşumlar bu özelliğe sahip değildirler.

- **VLSI Uyarlanabilirlik:** Yapay sinir ağıları VLSI (very large scale integrated) teknolojisine çok uygundur. Bazı nöron bilgisayarlar üretilmiştir [74].
- **Analiz ve Dizaynın İstikrarı:** Nöronlar bütün yapay sinir ağlarının temel parçalarıdır. Daha büyük ağlar yaratabilmek için çeşitli modüller ağa eklenebilir.
- **Nörobiyolojik Benzerlik:** Yapay sinir ağı, insan beyni gibi hızlıdır, güçlü bir hesaplama birimidir ve hata toleransı yüksektir.
- **Paralel Hesaplama:** Karışık sorunların çözümünde, özellikle mühendislikte yapay sinir ağlarının paralel hesaplama özelliği çok kullanışlıdır.

2.9 Kümeleme Yaklaşımları

Bu çalışmada kalp haritalamasına daha önce yapılmamış bir yaklaşımla kateter tabanlı aktivasyon zamanları veya VYP haritaları bilgileri ile aritmi yerinin tespitinde ilk olarak ilgili kalp katmanı endokardiyal veya epikardiyal haritalama ile belirli sayıda bölgelere ayrılmıştır. Daha sonra aritmi kaynağının yeri tahmin algoritmaları ile belirlenmiştir. Bu kısımda kalbin yüzeyinin bölgelere ayrılmasında kullanılan kümeleme algoritmalarının temel mantığından bahsedilecektir. Daha sonra pratik uygulamaları olduğu bilindiği için kullanılan SOM ve BCO kümeleme algoritmalarını temel işleyiş mekanizmaları anlatılacaktır.

Kümeleme analizi ya da kümeleme; aynı ya da benzer gözlemleri bir dizi alt gruplara (kümelere) atama işlemidir [73]. Kümeleme; makine öğrenmesi, veri madenciliği, görüntü tanıma, görüntü analizi ve biyoinformatik dahil olmak üzere istatistiksel veri analizi alanlarında kullanılan bir denetimsiz öğrenme yöntemidir [75]. Hiyerarşik algoritmalar, peşpeşe kümeleri bulmak için daha önce kurulan kümeleri kullanır. Bu algoritmalar her bir elementi ayrı bir küme olarak kabul ederek başlar ve kümeleri birleştirerek büyük kümeler oluşturur. Ayrıca bazı hiyerarşik algoritmalar bütün veriyi tek bir set olarak kabul eder ve bu kümeyi parçalara ayırmaya başlar. Bu tip algoritmalar bölücü hiyerarşik algoritmalar olarak bilinirler. Yoğunluk tabanlı kümeleme algoritmaları, gelişi güzel şekilli kümeleri ayırmak için oluşturulurlar. Bu yaklaşımda veri nesnesinin yoğunluğu belli bir eşik seviyesini aştığında o küme bir bölge olarak atanır. Altuzay kümeleme yöntemleri

verinin sadece belirli yansımalarından görülebilen kümelemelerini araştırırlar. Bu yöntemleri kullanarak verinin ilintisiz katkılarını gözardı edebiliriz. İki Yollu Kümeleme, Yardımcı Kümeleme ya da Tekli Kümeleme olarak ta bilinen İlintili Kümeleme’de hem nesnelere hem de onların özellikleri kümelendir. Mesela eğer veri bir veri matrisi olarak ifade edilmiş ise hem satırları hem de sütunları aynı anda kümelendirler. Çoğu kümeleme yöntemi algoritmanın çalıştırılmasından önce, kaç adet küme olacağını giriş olarak verilmesini gerektirir [76].

2.9.1 Kohonen SOM (Self Organizing Map) Kümeleme

Öz örgütlenme (Kohonen SOM) kümeleme yaklaşımı, mesafe ve yakınlık ilişkileri olabildiğince korunarak kaynak uzayındaki bütün noktaların hedef uzayında ifade edilmesini amaçlamaktadır [77]. Çok sayıda örneğin hafızaya kaydedilmesine ihtiyaç duymaz yani çok boyutlu ölçeklemeden daha az sayıda uzaya sahiptir. Aynı zamanda bu algoritma sorunun kendisinde doğrusal olmayan bir haritalama varsa oldukça kullanışlıdır.

Günümüzde Kohonen’in kümeleme algoritması kanser araştırmaları [78;79], EKG araştırmaları [80;81], medikal görüntü işleme [82;83], uyku analizi [84;85] gibi medikal uygulamalarda sıklıkla kullanılmaktadır.

SOM ağları, Teuvo Kohonen tarafından geliştirilmiştir. Genel olarak sınıflandırma yapmak için kullanılmaktadır. Bu ağların en temel özelliği olayları öğrenmek için bir öğretmene ihtiyaç duymamasıdır (denetsiz). İleri besleme/geri besleme türünde olabilir ve öğrenme algoritması olarak öz örgütlenme yöntemini kullanır. Bir girdi katmanı ve bir harita katmanı bulunur. Öz örgütlenme kullanan Kohonen Özellik Haritaları insan beynini taklit edecek şekilde tasarlanmıştır. İnsan beyninde öğrenme işlemi, sürekli tekrarlanan olaylar ve durumlar karşısında beyine iletilen sinyallerin, korteksin belli bölgelerinde yoğunlaşması sonucu bir hafıza oluşması şeklinde gerçekleşir. Benzer şekilde SOM ağlarına gönderilen sinyaller (girdi değerleri) bazı işlemlerden geçerek (iletilme, ağırlıklandırma) harita katmanına ulaşır. Bu katman 1 ya da 2 boyutlu olarak dizilmiş sinir hücrelerinden oluşmaktadır. Korteks görevini yapan bu katmana gönderilen girdiler, yapılan matematiksel hesaplamalar sonucu bir bölgede yoğunlaşırlar. Bu bölge; matematiksel işlemlerle belirlenen “kazanan sinir hücresi”dir. Bu sinir hücresine ait

bir alan mevcuttur. Aktivasyon alanı olarak adlandırılan bu bölge öğrenme esnasında küçülür. Bu küçülme, örneğin sınıflandırma işlemlerinde kesinliğin artmasına karşılık gelir. Her sınıf için ayrı bir sinir hücresi etrafındaki toplanmalar, sonuçta sınıflara ait bölgeler oluşturur. Bu şekilde de sınıflara ait öğeler daha sonra kolaylıkla tespit edilir.

Her giriş sinyali bir \mathbf{v} vektörü ile ifade edilir. Her eğitim adımında, her \mathbf{v} girişi rastsal bir $P(\mathbf{v})$ oluşma olasılığı ile seçilir. \mathbf{A} dokusundaki her bir \mathbf{r} yeri bir \mathbf{w}_r vektörü taşır. \mathbf{w}_r vektörü \mathbf{r} örgü yerlerini \mathbf{V} ile ifade edilen daha yüksek bir boyut uzayına eşleştirir.

Her eğitim adımı şu iki aşamada gerçekleştirilir:

A. Doku yerleri \mathbf{s} 'nin belirlenmesi,

$$\|\mathbf{w}_s - \mathbf{v}\| = \min_{r \in A} \|\mathbf{w}_r - \mathbf{v}\| \quad (2.1)$$


Burada \mathbf{v} vektörü şimdiki adım için giriş sinyalini ifade eder.

B. \mathbf{s} 'nin komşuluğundaki her bir \mathbf{r} sitesinin değiştirilmesi,

$$\mathbf{w}_r^{new} = \mathbf{w}_r^{old} + \epsilon h_{rs} (\mathbf{v} - \mathbf{w}_r^{old}) \quad (2.2)$$

Burada $0 \leq h_{rs} \leq 1$ fonksiyonu $\|\mathbf{r}-\mathbf{s}\|$ uzaklığının daha önceki özellikli değiştirme fonksiyonudur. ϵ ise öğrenme adım sayısıdır.

Şekil 2.16'da SOM yaklaşımının şematik ifadesi görülmektedir.




Şekil 2.16 Ölçüm veri tabanlı kümeleme yaklaşımı olarak kullanılan Kohonen SOM yapısı.

Görüldüğü üzere girdi katmanındaki her sinir hücresi, haritadaki diğer bütün sinir hücreleri ile bağlantılıdır. Sonuçta ortaya çıkan ağırlık matrisi ağırlık girdi değerlerini haritadaki sinir hücrelerine aktarmak için kullanılır. Ayrıca haritadaki bütün sinir hücreleri de kendi aralarında bağlantılıdır. Bu bağlantılar, aktivasyonun belirli bir bölgesindeki sinir hücrelerini, en büyük aktivasyona sahip sinir hücresi etrafında toplanmaya teşvik eder.

2.9.2 Bulanık Kümeleme

Bir sınıflandırıcıyı nerede oluşturacağımız ile ilgili bir problem hakkında bazen kesin olmayan bilgiler elde edebiliriz. Bulanık sınıflandırılmasında ele alınan yaklaşımın amacı, ölçülebilir bir parametreyi, öznel bir kategori üyeliğine sayısal bir şekilde çeviren “bulanık kategori üyelikleri” adı verilen fonksiyonları oluşturmaktır [86]. Burada kategori, üst üste binen özellik değerler dizisi anlamına gelmektedir. Klasik mantıktan farklı olarak, bulanık mantıkta çok sayıda özellik kullanılabilir. Örneğin aydınlık kavramının özellik değerini (feature) ele aldığımızda bunu “koyu”, “ortakoyu”, “orta”, “ortaaydınlıkta” ve “aydınlık” olmak üzere beş kategoriye ayırabiliriz. Boolean ve Klasik Mantıkta ise sadece iki kategori vardır. Bunlar 1 (aydınlık) ve 0 (koyu) kategorileridir. Bulanık mantığın Boolean Mantığından farkı insan kavrayışlarına daha yakın sözel kavramlar ile çalışabilmesidir. Kategorilerin belirlenmesinden sonra birkaç özellikteki bir nesnel

ölçüm ile ilgili kategori kararına dönüştürmemiz gerekmektedir. Bunun için son kararı vermek için kullanılmak üzere bir sayı sağlayan ve “kategori üyeliklerini” ele alan bir yol olan birleşme ya da birleşim kurallarına ihtiyacımız bulunmaktadır. Bunu sağlamak için bulanık mantık uygulayıcıları “VE”, “VEYA”, “DEĞİL” gibi bağlayıcı kurallar kullanırlar. Bununla birlikte, ne bu koşulları seçmek için nede onların, “kategorileri” belirlemek için yeterli olup olmadığı konusunda temel kurallar yoktur ve kullanıcı istediği kuralları seçebilmektedir [87]. Şekil 2.17’de oluşturulabilecek örnek bir kullanıcı fonksiyonu verilmiştir.



Şekil 2.17 Kullanıcı tarafından atanan üyelik fonksiyonları.

Tasarımcının “aydınlık” ve “şekle” bağlı olan son kategorinin “ortaaydınlıkta” ve “dikdörtgen” olarak tanımlanabileceğini düşündüğünü farzedelim. Buluşsal (heuristic) kategori üyelik fonksiyonunu $\mu(\cdot)$, nesnel ölçümleri iki “kategori üyeliğine” dönüştürürken, üyelik değerleri parçasını diskriminant fonksiyonuna dönüştürebilmek için birleşim kuralına ihtiyacımız vardır. En çok kullanılan kural “VE” kuralıdır.

$$\mu_x(x) \cdot \mu_y(y) \quad (2.3)$$

Bulanık Mantık yöntemi, Parzen Pencereleme, Olasılıksal Yapay Sinir Ağları ve Radyan Temelli Fonksiyonlar ile temelde aynı görünmektedir. Bu yöntemlerden farklı olarak bulanık kategori üyelikleri sadece olasılıksal ya da olasılıklara orantılı değildir. Bulanık yöntemleri ve kategori üyelik fonksiyonlarının girişinden bile önce istatistikçiler desen tanıma ve hatta matematik filozofları toplulukları olasılığın

temel yapısı üzerinde oldukça tartışmışlardır. Bazıları tek bir olay ile ilgili açıklamaların anlamsız olduğunu düşünerek bu kavramın tek bir tekrar edilemeyen olaylara uygulanabilirliğini sorguladılar. Bu tür tartışmalar ile olasılığın sadece tekrar edebilen olaylara uygulanmasına gerek olmadığı açığa kavuşmuş oldu. Bunun yerine 20. Yüzyılın ilk yarısından beri olasılık öznel olasılık kavramına dikkat çeken makul bir sonuç çalışmasının mantığı olarak kullanılmıştır. Aslında yukarıdaki sözü edilen bulanık tekniklerin tartışılması, olasılığın daha da geniş çapta anlaşıldığı üzere kategori üyeliklerini de kapsadığı klasik kavramlarını da içine alabilir. Bu kavramsal temellerin bütünü ile yorumlanması bizi desen tanıma tekniklerinin gelişiminden uzaklaştırırken, bulanık mantığı savunucularının iddalarını göz önünde tutmayı sağlamaktadır. Bulanık mantık uygulayıcıları bir fincan çaya yarım kaşık şeker konulduğunda tatlı kategorisindeki “üyelik” 0.5 olduğu sonucuna ulaşmanın ve çayın tatlı olduğu olasılığının 50% olduğunu söylemenin yanlış olabileceğini belirtirler. Fakat bu durum sadece 0.5 değerine sahip bazı tatlı özellik olarak görülebilir ve bu tartışmaların bu özellik değerini kapsadığı bir kaç diskriminant fonksiyonu vardır. Olasılığın temel doğasını tartışmaktan çok gerçekte sonucun doğası ile yani bir kategori sonucunu ve ölçümlerini nasıl elde edeceğimiz ile ilgilenmeliyiz.

a , b ya da c kategorilerindeki üyelikler hakkındaki inancın anlamlı derecesini, $P(a|d)$, $P(b|d)$ ve $P(c|d)$ şeklinin matematiksel fonksiyonlarından (olasılıklar zorunlu değildir) verilen d verisinde hesaplanmasının mümkün olduğunu düşünelim. Beklenen özelliklerin çok makul bir seti, Cox’un aksinomları (Cox-Jayne’nin aksinomları adı da verilir) ile elde edilir [88].

1. Eğer $P(a|d) > P(b|d)$ ve $P(b|d) > P(c|d)$ ise o zaman $P(a|d) > P(c|d)$ yani inanç derecelerinin gerçek sayılar ile verilen doğal bir düzeni vardır.
2. $P(\text{not } a|d) = F_1[P(a|d)]$ yani bir önermenin durum olmadığı inanç derecesi, durum olduğu inanç derecesinin bir fonksiyonudur. Bu tür inanç derecelerinin derecelendirilmiş değerler olduğunu unutmayınız.
3. $P(a \text{ b}|d) = F_2[P(a|d), P(b|a, d)]$

Bu üç aksiyom, inanç derecelerinin nasıl hesaplanacağını yani nasıl bir mantıklı sonuç elde edeceğimizi belirler. Herhangi bir önermenin en küçük değerinin sıfır ve en geniş değerini 1.0 olduğu bir ölçek seçebiliriz. Bu durumda $F_1(a)$ fonksiyonunun $1-a$ ifadesine eşit olduğu ve $F_2(a,b)$ fonksiyonunda $a \times b$ ifadesine eşit olduğu gösterilebilir. Bu iki fonksiyondan klasik sonuca uygun olarak olasılık kurallarını elde etmiş oluruz. Herhangi bir tutarlı sonuç yöntemi standart olasılık sonucuna resmi olarak eşittir. Bu temel konular ile ilgili tartışmak yerine çoğu uygulayıcı ne çalışırsa çalışsın onların çalışmalarının bir parçası olması gerektiğini düşünerek bulanık mantığı kullanmaktan mutluluk duyarlar. İşte bu yüzden yöntemin yöntemsel sınırlılıklarını ve güçlüklerini anlamak önemlidir. Bu sınırlılıklar şunlardır:

- Bulanık yöntemler, yüksek boyutlarda, karmaşık problemlerde ya da düzinelerce ya da yüzlerce özellikli problemlere kullanışsızdır.
- Tasarımcının bir probleme getirmesi beklenen bilginin miktarı, “kategori üyeliklerinin” genişliği, yeri ve sayısı açısından oldukça sınırlıdır.
- Normalizasyon eksikliğinden dolayı saf bulanık yöntemleri, değişen bir maliyet matrisi olan λ_{ij} 'in olduğu problemlere düşük seviyede uygunluk gösterir.
- Saf bulanık yöntemler eğitim verilerini kullanmaz. Yukarıda belirtilen bu tür saf bulanık yöntemleri kabul edilemeyen performans sergilediğinde uyarlanmış yöntemler (örneğin “neuro-fuzzy”) üzerine ekleme yapmak genel bir uğraştır.

Eğer desen tanımaya bulanık yaklaşımların katkısı varsa, bir kullanıcının yapısal şekilde bu bilgiyi alıp bunu diskriminant fonksiyonlara çevirdiği aşamaları yönlendirmede bu katkıların yeri olabilir. Saf bulanık mantıkların ciddi bir sınırlaması, onların bilgiye güvenmemesidir ve orta büyüklükteki problem üzerinde tatmin etmeyen sonuçlar olduğunda, yerine koymak üzere sinir ağları ya da diğer uyarlanmış teknikleri kullanmaya çalışmak genelde yapılan bir uğraştır.

Bulanık C Ortalama (BCO) Kümeleme: Bilginin bir parçasının iki veya daha fazla kümeye ait olmasına izin veren bir kümeleme yöntemidir. Dunn tarafından bulunan ve Bezdek tarafından geliştirilen bu yöntem, desen tanıma (pattern recognition) tekniği olarak sıkça kullanılmaktadır [88]. Bu algoritma bir hedef fonksiyonunun küçültülmesi amacını taşır,

$$J_m = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m \|x_i - c_j\|^2 \quad (2.4)$$

Burada $1 \leq m < \infty$ olmak üzere m birden büyük bir sayıdır. u_{ij} ise j kümesindeki x_i elemanının üyelik derecesidir. x_i tanım gereği kümenin d-boyutlu merkezidir. i indeks numarasıdır. $\|\cdot\|$ ise merkez ile herhangi bir ölçüm arasındaki benzerliği ifade eden norm olarak tanımlanır. Kümelerin merkezleri c_j ve u_{ij} üyeliğinin güncellenmesi ile bulanık bölme işlemi hedef fonksiyonunun tekrarlanan optimizasyonu yardımıyla yapılır.

$$u_{ij} = \frac{1}{\sum_{k=1}^C \left(\frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}} \quad (2.5)$$

$$c_j = \frac{\sum_{i=1}^N u_{ij}^m \cdot x_i}{\sum_{i=1}^N u_{ij}^m} \quad (2.6)$$

$\max_{ij} \left\{ |u_{ij}^{(k+1)} - u_{ij}^{(k)}| \right\} < \varepsilon$ gerçekleştiğinde iterasyon sona erer. Burada ε değeri 0 ile 1 arasındaki sonlandırma kriteridir. k ise iterasyon basamak değeridir. Bu işlem J_m yerel minimum değeri veya eğer noktasına yakınsar.

Algoritma şu basamaklardan oluşur:

1. $U = [u_{ij}]$ matrisini başlat, $U^{(0)}$
2. k -basamağında, merkez vektörleri $U^{(k)}$ ile hesapla $C^{(k)} = [c_j]$
3. $U^{(k)}$ değerini $U^{(k+1)}$ ile güncelle

Eğer $\|U^{(k+1)} - U^{(k)}\| < \epsilon$ ise dur; diğer durumlarda 2 aşamaya geri dön.

Günümüzde bulanık kümeleme algoritması medikal görüntülerin segmentasyonunda sıklıkla kullanılmaktadır [87;88;89].

2.10 Sınıflandırma

Kümeleme işleminden sonra, aritmi kaynağının kalp yüzeyinde oluşturulan hangi grup (bölge) içinde olduğunu bulmak için çeşitli sınıflandırma uygulamalarından yararlanılmıştır. İstatistiksel sınıflandırma, daha önce işaretlenmiş maddelerin bir eğitim setine ve bireysel maddelerin bir ya da birden fazla ayırt edici özelliklerindeki bilgilere göre maddeleri gruplara atayan öğreticili bir öğrenme sürecidir [85]. Bu kısımda, en çok kullanılan sınıflandırma yöntemleri olan Çok katmanlı Yapay Sinir Ağları, Destek Vektör Makineleri, k en Yakın Komşuluk, Gaussian, Bayes Ağları, kuadratik yapılarının genel çalışma prensipleri hakkında temel bilgiler verilmiştir [75].

2.10.1 Olasılıksal Yapay Sinir Ağı (OSA)

OSA ağları Bayes kümelemenin devamıdır. OSA ağları eğitim örneklerinin olasılıksal yoğunluk fonksiyonunu belirlemeyi öğrenebilir. Yani örneklerin dağılımının olasılık yoğunluklarını belirleyen bir fonksiyondur. OSA yapısı girişlerden sonra üç katmanda ayrılmış düğümlerden meydana gelmiştir [75]:

1. *Şekil katmanı*: Her eğitim örneği için bir şekil düğümü vardır. Her şekil düğümü kümeleme için ağırlık vektörü ile örneğin çarpımını oluşturur.

Bundan sonra, çarpım aktivasyon fonksiyonuna geçilir:

$$\exp\left[\frac{(x^T w_{ki} - 1)}{\sigma^2}\right] \quad (2.7)$$

Burada x_{ki} , k sınıfından d -boyutlu i numaralı örneği ifade eder.

2. *Toplama katmanı*: Her toplama düğümü verilen sınıfla bağlantılı şekil düğümlerinden çıktıları alır:

$$\sum_{i=1}^{N_k} \exp\left[\frac{(x^T w_{ki} - 1)}{\sigma^2}\right] \quad (2.8)$$

3. *Çıkış katmanı*: Çıkış katmanı sınıflandırma kararlarını veren ikili nöronlardır.

Çoğu desen tanıma yöntemi, zaman karmaşıklığı yerine uzay karmaşıklığını koyan bir biçime benzer şekilde uygulanabilir. Bu uygulamalar Yapay Sinir Ağlarına örnektir. Olasılıksal Sinir Ağları, Parzen pencereleme yönteminin yapay sinir ağlarına uygulanabileceğinin göstergesidir. C sınıflarından gelişigüzel örneklenmiş her bir d -tane boyuta sahip n adet desene Parzen Tahmini oluşturmak istediğimizi düşünelim. Bu durumda Olasılıksal Sinir Ağları, giriş katmanını oluşturan d -adet birimi içermektedir. Her birim n örgü birimlerinin her birine bağlanmıştır. Her örgü birimi ise sırasıyla birbirlerine ve sadece c sınıflandırma birimlerine bağlıdır. Giriş katmanından örgü birimlerine olan bağlantılar eğitilecek değiştirilebilir ağırlıkları temsil etmektedir (bu ağırlıklar sadece parametre iken θ vektörü ile tanımlanabilirler, sinir ağları terminolojisine göre ise w sembolü ile gösterilir). Her sınıflandırma birimi birbirine bağlı desen birimlerinin toplamını hesaplamaktadır.

Olasılıksal Sinir Ağları şu şekilde eğitilir. İlk olarak eğitim setinin her bir x deseni birim uzunlukta olsun diye yani $\sum_{i=1}^d x_i^2 = 1$ şeklinde ölçülebilir diye normalize edilir. İlk normalize edilmiş eğitim deseni giriş birimlerine yerleştirilir. Birim birimlerini bağlayan değiştirilebilir ağırlıklar ve ilk desen birimi $w_1 = x_1$ şeklinde yerleştirilir (x_1 normalize edildiği için w_1 'de normalize edilmiş olur). Daha sonra ilk desen biriminden bu desenin bilinen sınıfına karşılık gelen sınıflandırma birimine tek bir bağlantı yapılır. Ağırlıkları $w_k = x_k$, $k = 1, 2, \dots, n$ şeklinde ardı ardına gelen desen birimlerine yerleştirerek geri kalan eğitim desenlerinin her biri ile bu işlem tekrar edilir. Bu eğitimden sonra, giriş ve desen birimleri arasında tamamen

bağlanmış ve desenden sınıflandırma birimlerine dağınık olarak bağlanmış bir ağ elde ederiz. Eğitilmiş ağ, sınıflandırılma için şu şekilde kullanılır. Normalize edilmiş x test deseni giriş birimlerine yerleştirilir. Her desen birimi içsel çarpımı hesaplayarak ağ aktivasyonunu ya da sadece ağı elde eder ve ağın doğrusal olmayan fonksiyonu yayar.

$$net_k = w_k^t x \quad (2.9)$$

Her çıkış birimi kendisine bağlı olan bütün desen birimlerinin katkılarının toplamını ifade eder. Bu doğrusal olmayan fonksiyon $e^{(net_k-1)/\sigma^2}$ ile ifade edilir. Burada σ kullanıcı tarafından belirlenmiş bir parametredir ve etkin Gaussian penceresinin genişliğini belirler. Bu aktivasyon fonksiyonu ya da transfer fonksiyonu Parzen Pencereleme Algoritmasını uygulamak için gittikçe artan (exponential) şekilde olmalıdır. Bunu görebilmek için w_k eğitim desenlerinin birinin yerine yerleştirilmiş normalize edilmemiş bir Gaussian penceresi düşünelim. İstenen Gaussian pencereleme fonksiyonundan desen birimleri tarafından çalıştırılmış bir doğrusal olmayan bir aktivasyon fonksiyonu sonucunu elde etmek için ters yönden çalışırız. Yani eğer etkin genişliğimiz h_n sabit olursa, pencereleme fonksiyonu normalizasyon koşullarımızı $x^t x = w_k^t w_k = 1$ kullandığımız yer olur.

$$\begin{aligned} \phi\left(\frac{x-w_k}{h_n}\right) & \propto e^{-(x-w_k)^2/(2\sigma^2)} \\ & = e^{-(x^t x + w_k^t w_k - 2x^t w_k)/2\sigma^2} = e^{(net_k-1)/\sigma^2} \end{aligned} \quad (2.10)$$

Böylelikle her bir desen birimi kendisine karşılık gelen sınıflandırma birimine bir sinyal gönderir. Bu sinyal test noktasının kendisine karşılık gelen eğitim noktasının Gaussian merkezli üretilme olasılığına eşittir. Bu yerel tahminlerin toplamı (karşılık gelen sınıflandırma birimlerince hesaplanmış) altta yatan dağılımın Parzen pencere tahmini olan $g_i(x)$ discriminant fonksiyonunu verir. $\max_i g_i(x)$ operasyonu test noktası için istenen sınıflandırmayı vermektedir. Olasılıksal Sinir Ağlarının yararlarından biri öğrenme hızıdır. Çünkü öğrenme kuralı basittir ve eğitim verisinden sadece tek bir geçiş gerektirir. Olasılıksal Sinir Ağları için uzay karmaşıklığını (hafızanın miktarı) aşağıdaki şekildeki bağlantıların sayısını sayarak

belirlemek kolaydır. Örneğin bir donanım uygulamasında bu sayma işlemi oldukça zor olabilir. Çünkü hem n hem de d oldukça geniş olabilir. Böylece bu OSA yapısı depolamanın zor bir sınırlama olmadığı ve tanımlama hızının önemli olduğu kullanım yerleri bulabilir. Diğer bir yararı yeni eğitim desenlerinin daha önce eğitilmiş sınıflandırıcıya oldukça kolay bir şekilde dahil edilebilmesidir. Bu özellikle on-line uygulama için önemli olabilir.

2.10.2 Geri Yayılım Ağları (GYA)

Geri yayılma algoritması, basitliği ve uygulamadaki görüş açısı gibi başarılarından dolayı ağ eğitimi için en popüler algoritmalarından biridir [89]. Bu algoritma; hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geri yayılım ismini almıştır. Geri yayılmalı öğrenme kuralı ağ çıkışındaki mevcut hata düzeyine göre her bir tabakadaki ağırlıkları yeniden hesaplamak için kullanılmaktadır. Bir geri yayımlı ağ modelinde giriş, gizli ve çıkış olmak üzere 3 katman bulunmakla birlikte, problemin özelliklerine göre gizli katman sayısını artırabilmek mümkündür. Geri yayılım çok katmanlı ağlarda kullanılan delta kuralı için geliştirilmiştir bir algoritmadır. Bu algoritma çok katlı ağlarda hesap işlerini öğrenmede kullanılabilir. Geri yayılım ağında hatalar, ileri besleme aktarım işlevinin türevi tarafından, ileri besleme mekanizması içinde kullanılan aynı bağlantılar aracılığıyla, geriye doğru yayılmaktadır. Öğrenme işlemi, bu ağda basit çift yönlü hafıza birleştirmeye dayanmaktadır. Geri yayılım algoritmasının amacı bir uygunluk fonksiyonunu minimum yapmaktır. Uygunluk fonksiyonu YSA'nın ağırlık değerlerine bağlı olduğundan, algoritma YSA ağırlıklarının en uygun biçimde değiştirilmesi işlemlerinden oluşmaktadır [90].

Günümüzde hemem hemen tüm sınıflandırma probleminde kullanılan geri yayılım ağları; biyomedikalde özellikle medikal teşhis sistemlerinde [91;92], medikal görüntü işlemede [93;94] ve hastalık sınıflandırmasında [95;96] sıklıkla kullanım alanı bulmaktadır.

2.10.3 Diskriminant Analiz (DA)

Diskriminant analizi ve bununla ilgili olan Fisher'in Doğrusal Diskriminant yöntemi, iki veya daha fazla sayıda olayı belirleyen ya da ayıran özelliklerin doğrusal bir birleşimini bulan, istatistikte ve makine öğreniminde kullanılan bir yöntemdir. Sonuç kombinasyonu bir doğrusal sınıflandırıcı ya da daha genel haliyle sınıflandırmadan önce boyut azaltıcı olarak kullanılır. Diskriminant Analiz, ANOVA (varyans analiz) ve regresyon analizi ile alakalandırılır. Aynı zamanda bir bağımlı değişkeni diğer özelliklerin ya da ölçümlerin bir doğrusal kombinasyonu olarak ifade etmeye çalışır. Diğer iki yöntemde bağımlı değişkenin bir nümerik değer olmasına karşı diskriminant analizde bir kategoriye ait değişkendir (sınıf ismi gibi). Logistik Regresyon ve İstatistik İhtimal Regresyon diskriminant analize daha çok benzerler. Diskriminant analizde bağımsız değişkenlerin normal dağılıma sahip olmaları temel bir kabul olmasına rağmen Logistik Regresyon ve İstatistik İhtimal Regresyonunda böyle bir kabullenmeye ihtiyaç yoktur.

Veriyi en iyi açıklayan değişkenlerin doğrusal kombinasyonunu arayan diskriminant analiz bu açıdan PCA (principal component analysis) ve Faktör Analiz yöntemleri ile ilişkilendirilir. Diskriminant analiz açıkça verinin sınıfları arasındaki farkı modellemeye çalışır. Diskriminant analiz için bağımsız değişkenler ile bağımlı değişkenler arasında bir ayırım olması gerekmektedir. Diskriminant analiz her gözlem için bağımsız değişkenlerin sürekli nicelikte olduğu durumlarda çalışır. Kategoriye ait bağımsız değişkenler ile uğraşıldığı durumlarda, diskriminant analiz yönteminin eşdeğeri Diskriminant Benzerlik Analizi'dir [97;98].

İkiden fazla sınıfın olduğu durumlarda, Fisher Diskriminantın türevinde kullanılan analiz bütün sınıfların değişkenliğini içerdiği gözlenen bir alt uzayı bulmak için genişletilebilir. Her C sınıfının bir μ_i ortalamasına ve aynı Σ kovaryansına sahip olduğunu düşünelim. Sınıf değişkenliği, sınıf ortalamalarının örnek kovaryansı olarak tanımlanır.

$$\sum_b \frac{1}{C} \sum_{i=1}^C (\mu_i - \mu)(\mu_i - \mu)^T \quad (2.11)$$

Burada μ sınıf ortalamalarını ortalamasıdır. \vec{w} yönelimli sınıf ayrımı şu şekilde verilir.

$$S = \frac{\vec{w}^T \sum_b \vec{w}_b}{\vec{w}^T \sum_b \vec{w}_b} \quad (2.12)$$

Eğer \vec{w} , $\sum_b^{-1} \sum_b$ için bir özdeğer vektörü ise sınıflar arasındaki ayırım karşılık gelen özdeğer olmaktadır. \sum_b 'nin $C-1$ ranke sahip olduğundan bu sıfır olmayan özdeğer vektörlerinin özellikler arasındaki değişkenliği içeren bir vektör alt uzayı tanımlarlar. Bu vektörler özellikle vektör azaltmada kullanılabilirler. En küçük değere sahip özdeğerler eğitim verisinin iyi seçilmesine karşı çok hassas olacaklardır ve bir düzenlemeye ihtiyaç duyabilirler. Eğer boyut azaltmanın yerine sınıflandırılma gerekiyorsa, çok sayıda alternatif yöntem vardır. Mesela sınıflar ayrıldıktan sonra, standart Fisher Diskriminant veya diskriminant analiz yöntemi her bir ayırımın sınıflandırılmasında kullanılabilir. Çok kullanılan bir örnekte, bir sınıf bir gruba koyulur diğer her şey ise bir başka gruba konulur ve diskriminant analiz uygulanır. Bunun sonucu, sonuçları bir araya toplanmış olan C sınıflandırılmalarıdır. Diğer bir genel kullanım ise ikili sınıflandırmadır. Burada her bir çift sınıf için bir sınıflandırıcı atanır ve sınıflandırıcılar bir araya toplanarak bir son sınıflandırma oluşturulur. Pratik uygulamalarda, sınıf ortalamaları ve kovaryansları bilinmemektedir. Fakat bunlar eğitim setinden tahmin edilebilirler. Bu tahminlerin optimum tahminler oldukları düşünülse bile gerçek değerlerin yerine kullanılmalarının getirdiği hatlar olacaktır. Gerçek verilere diskriminant analiz uygulanmasındaki diğer bir zorluk her örnekteki gözle sayısının örnek sayısını aştığı durumlarda meydana gelir. Bu durumda kovaryans tahminleri tam rank olmaz ve tersleri alınamaz. Bunu aşmak için bazı yöntemler vardır. Yukarıdaki formülasyonlarda geleneksel matris teriminin yerine pseudo terleme işlemi yapılır. Bazı uygulamalarda varolan örneklere beyaz gürültü eklenerek kullanılabilir örnek sayısı artırılır. Bu eklemenin kovaryans üzerindeki etkisi şu şekilde olur.

$$C_{yeni} = C + \sigma^2 I \quad (2.13)$$

Burada I birim matrisdir, ve σ eklenen gürültünün miktarıdır (regularizasyon parametresi). σ 'nin değeri genellikle çapraz sağlama setinden en iyi sonuçlar alacak şekilde seçilir. Kovaryans matrisinin yeni değeri her zaman terslenebilir olur [99].

Diskriminant Analiz genellikle mali uygulamalarda kullanılır. Bu uygulamalar arasında iflas tahmin algoritmaları, üretim yönetimi, elde edilecek gelir tahmin algoritmaları ve market araştırmaları sayılabilir. Ayrıca konumlama ve yüz tanıma alanlarında da bu yöntemden faydalanılır [73;100].

2.10.4 k En Yakın Komşu (kNN) Tahmini

Bilinmeyen en iyi pencereleme fonksiyonu bulma problemi için potansiyel çözüm, hücre miktarının, örneklerin toplam sayısının bazı gelişigüzel fonksiyonundan çok, eğitim verisinin bir fonksiyonu olmasını sağlamaktır [100]. Örneğin n eğitim örneklerinden ya da prototiplerinden $p(x)$ ölçmek için, bir hücreyi x üstüne merkezleyebilir ve bu hücrenin k_n 'nin, n 'in bazı belirlenmiş fonksiyonları olduğu yerde, k_n örneklerini yakalayana kadar büyümesine izin verebiliriz. Bu örnekler x 'in k_n seviyesindeki en yakın komşularıdır. Eğer yoğunluk x 'in yanında yüksek ise hücre iyi bir kararı sağlayarak oldukça küçük olacaktır. Eğer yoğunluk düşük ise hücrenin genişleyeceği doğrudur fakat daha yüksek yoğunluk bölgelerine girdikten kısa bir süre sonra duracaktır. Her durumda eğer

$$p_n(x) = \frac{k_n/n}{V_n} \quad (2.14)$$

alırsak n sayısı sonsuza gideceğinden k_n 'nin de sonsuza gitmesini isteriz çünkü bu bize k_n/n 'nin, bir noktanın V_n hacminin hücrelerine düşme olasılığının en iyi tahmin olacağını güvencesini verir. Bununla birlikte ayrıca k_n eğitim örneklerini yakalaması beklenen hücrenin büyüklüğünün sifıra küçüleceği k_n 'nin yavaşça büyümesini isteriz. Böylece k_n/n oranının sifıra gitmesi gerektiği denklem 2.14'de açıktır. Her ne kadar kanıtlayamasakta $\lim_{n \rightarrow \infty} k_n = \infty$ ve $\lim_{n \rightarrow \infty} k_n/n = 0$ olduğu koşulların gerekli olduğu ve $p(x)$ 'in sürekli olduğu noktalardaki olasılıkta $p_n(x)$ 'in

$p(x)$ 'e yönelmesi için yeterli olduğu gösterilebilir. Eğer $k_n = \sqrt{n}$ olarak alırsak ve $p_n(x)$ 'in $p(x)$ 'e oldukça iyi bir tahmin olduğunu farzederseniz, o zaman denklem 2.14'ün $V_n \cong 1/(\sqrt{n}p(x))$ olduğunu görürüz. Böylece V_n tekrar V_1/\sqrt{n} şeklini alır. Fakat başlangıç V_1 hacmi, bizim tarafımızdaki bazı gelişigüzel seçimlerden çok verinin özelliği tarafından belirlenir. $p_n(x)$ 'nin kendisinin sürekli olmasına rağmen eğiminin sürekli olmaması ilginçtir. Ayrıca süreksizlik noktaları prototip noktaları ile nadiren aynıdır. Daha önce kullanılan veriler üzerinde, Parzen pencereleme yöntemi ile bu yöntemin performansını karşılaştırmak öğreticidir. $n=1$ ve $k_n = \sqrt{n} = 1$ ile, tahmin şu şekile gelir;

$$p_n(x) = \frac{1}{2|x - x_1|} \quad (2.15)$$

Bu tahmin açıkça sonsuzluğa yakınsa, kendi tahmini ile $p_n(x)$ 'in bir tahminidir. Her ne kadar tahminin integrali sonsuz olarak kalsada, n genişledikçe tahmin oldukça iyi olur. Bu talihsiz durum; hiçbir örneğin gelişigüzel hücre ya da pencereye düşmemesinden, $p_n(x)$ 'in asla sifıra düşmemesi gerçeği ile açıklanabilir. Bu yetersiz bir açıklama gibi görünsede, daha yüksek boyutsal uzaylarda oldukça değerli olabilir. Parzen pencereleme yaklaşımı ile $k_n = k_1\sqrt{n}$ şeklinde kabul ederek ve k_1 için farklı değerler seçerek bir tahminler topluluğu elde edebiliriz. Bununla birlikte, herhangi bir ek bilgi olmaması durumunda, bir seçenek diğer biri kadar iyi olabilir ve sadece sonuçlarının sonsuz veri durumunda doğru olacağı biçiminde emin olabiliriz. Sınıflandırma için popüler bir yöntem sınıflandırıcının ayrı bir örnek takımının üzerinde en düşük hatası olana kadar pencere genişliğini ayarlamaktır. Bu ayrı örnek takımı hedef dağılımlardan seçilmiştir.

2.10.5 Destek Vektör Makineleri (DVM)

Doğrusal makinelerin limitleri ile eğitilebileceği daha önceden bilinen bir gerçektir [73]. Destek vektör makineleri, çoğu aynı noktadan harekete geçmektedir. Fakat orijinal özellik uzayından çok daha belirgin bir yüksek seviyedeki bir boyutta desenleri göstermek için giriş verilerini ön işlemden geçirmeye dayanır. Yeteri derecede yüksek bir boyut için doğrusal olmayan uygun bir haritalama $\phi(\cdot)$ ile iki


sınıflandırılmadan veriler her zaman üst düzlem tarafından ayırt edilebilir. Burada her x_k deseninin $y_k = \varphi(x_k)$ 'ya dönüştüğünü farz edelim. n deseninin her birisi için her k deseninin w_1 ya da w_2 içinde olup olmadığına göre $z_k = \pm 1$ işlemi yapılır. Büyütülmüş y uzayı üzerindeki doğrusal diskriminantı her ağırlık vektörünün ve dönüştürülmüş vektörün büyüdüğü yerdir ($a_0 = w_0$ ve $y_0 = 1$). Böylece üst düzlemi ayırmak aşağıda verilen şekilde görüldüğü gibi çok daha fazlasını sağlar.

$$z_k g(y_k) \geq 1, \quad k = 1, \dots, n, \quad (2.16)$$

Destek Vektör Makinesini eğitmedeki amaç en geniş limit ile üst düzlemi ayırmayı bulmaktır. Ne kadar geniş bir limit olursa o kadar daha iyi sınıflandırıcının genellemesi beklenir. Şekil 2.18'de görüldüğü üzere herhangi bir üst düzlemden dönüştürülmüş y desenine olan uzaklık $|g(y)|/\|a\|$ olarak verilir ve bir pozitif b limitinin var olduğunu farz edersek

$$\frac{z_k g(y_k)}{\|a\|} \geq b, \quad k = 1, \dots, n; \quad (2.17)$$

Burada amaç b 'yi en yüksek değere ulaştırarak a ağırlık vektörünü bulmaktır. Elbette çözüm vektörü keyfi olarak ölçülebilir ve hala üst düzlemi korur ve böylece $b\|a\| = 1$ kısıtlamasını yüklediğimiz eşitliği sağlar. Böylelikle $\|a\|^2$ minimize edilir. Destek vektörleri, denklem 2.18'deki destek vektörlerinin üst düzleme yakınlığı olan eşitliği ifade ettiği dönüştürülmüş eğitim desenleridir. Destek vektörleri ideal ayrılmış üst düzlemi ifade eden eğitim örnekleridir ve sınıflandırılması en zor olan desenlerdir ve sınıflandırma konusu için en çok bilgi veren desenlerdir. İki farklı kümeleme ve kümelere ait seçilmiş DVM'leri Şekil 2.18'de gösterilmiştir ([73]'den alınıp değiştirilmiştir).



Şekil 2.18 Optimal yüksek uzayı bulmayı amaçlayan bir SVM'nin eğitimi.

Kavramsal olarak bir destek vektör makinesinin basit bir eğitim yöntemi olarak bilinen Perceptron eğitim kuralının biraz değiştirilmesine dayanmaktadır. Perceptron öğrenme kuralının sadece ağırlık vektörünün herhangi bir rastgele seçilmiş yanlış sınıflandırılmış bir desene orantılı bir miktarda güncelleştirmesini gerektirdiğini hatırlayalım. Bunun yerine bir Destek Makinesi geçerli en kötü sınıflandırılmış bir desen seçilerek eğitilebilir. Çoğu eğitim süresi boyunca böyle bir desen geçerli karar sınırının en uzağında yanlış limitinde bir tanedir. Eğitim süresinin en sonunda böyle bir desen Destek Vektörlerinden bir tanesi olacaktır. En kötü durum desenin bulmak uygulamada hesaplama bakımından pahalı bir uygulamadır çünkü en kötü sınıflandırılmış deseni bulabilmek için bütün eğitim setini araştırarak güncellemek gerekir. Bu nedenle bu basit yöntem sadece küçük problemler için kullanılır. Çok sayıda deseni olan bir Destek Vektör Makinesini daha genel bir eğitime yöntemine dönmeden önce böyle bir sınıflandırıcı yanlışını göz önünde bulundurmak gerekir.

Eğer N_s Destek Vektörlerinin toplam sayısını ifade ederse n eğitim desenleri için yanlış oranının beklenen genelleştirme değeri

$$\varepsilon_n[\text{error}] \leq \frac{\varepsilon_n[N_s]}{n} \quad (2.18)$$

olarak sınırlanır. Bu sınırlama sınıflandırmaları tanımlayan dağılımlardan alınmış n boyutunun bütün eğitim setinin üzerindeki beklentiye göre yapılır. Bu sınır $\varphi(\cdot)$ tarafından belirlenmiş, dönüştürülmüş vektörlerin uzayının boyutlarından bağımsızdır. Eğitim setinde n noktasının var olduğunu, bunlardan $n-1$ üzerinde Destek Vektör Makinesini eğittiğimizi ve kalan tek bir nokta üzerinde test ettiğimizi düşünelim. Eğer kalan nokta bütün n örneği durumu için Destek Vektörü olursa o zaman bir yanlışlığı ifade edecektir fakat aksi taktirde bir yanlışlığı ifade etmez. Eğer verileri iyi bir şekilde ayıran $\varphi(\cdot)$ dönüşümü bulabilirsek böylece Destek Vektörlerinin beklenen sayısının küçük olacağını unutmayalım. O zaman denklem 2.18'in beklenen yanlış oranının daha düşük olacağını göstermektedir.

Destek Vektör Makinelerinin eğitimi şu şekilde yapılmaktadır: İlk aşama elbette daha yüksek boyutsal uzaya girişi haritalayan doğrusal olmayan fonksiyonları seçmektir. Sık sık bu seçim alandaki problemin bilgisine sahip tasarımcı tarafından bildirilir. Bu bilgi verilmez ise polinomlar, Gaussian ya da diğer diğer fonksiyonlar seçilebilir. Haritalanmış uzayın boyutluluğu her ne kadar uygulamada hesaplanabilen kaynaklar tarafından sınırlanabilse de keyfi olarak yüksek seçilebilir. Lagrange belirlenmemiş çoklayıcıları yöntemi ile bir sınırlandırılmamış probleme ayırımı ile sınırlandırılmış olan ağırlık vektörünün büyüklüğünü azaltma problemini yeniden ele alarak başlarız. Böylece denklem 2.18'den ve $\|a\|$ 'yi küçültme amacı ile;

$$L(a, \alpha) = \frac{1}{2} \|a\|^2 - \sum_{k=1}^n \alpha_k [z_k a^t y_k - 1] \quad (2.19)$$

fonksiyonunu oluştururuz ve a ağırlık vektörü ile ilgili olarak $L(\cdot)$ 'yi küçültmeyi ve belirlenmemiş $\alpha_k \geq 0$ çoklayıcılarına uygun olarak $L(\cdot)$ 'yi büyütmeyi araştırırız. Denklem 2.19'daki son terim noktaları uygun bir şekilde sınıflandırma amacını açıklamaktadır. Bu Kuhn-Tucker adı verilen yapı kullanılarak gösterilebilir. Bu optimizasyon denklem 2.20'yi maksimize etmek için denklem 2.21 sınırlandırmasına bağlı olarak yeniden formüle edilebilir. Bu denklemler quadratik programlaması kullanılarak çözülebilirken bir kaç farklı düzenlemeler geliştirilebilir.

$$L(\alpha) = \sum_{k=1}^n \alpha_k - \frac{1}{2} \sum_{k,j}^n \alpha_k \alpha_j z_k z_j y_j^t y_k \quad (2.20)$$

$$\sum_{k=1}^n z_k \alpha_k = 0 \quad \alpha_k \geq 0 \quad k = 1, \dots, n, \quad (2.21)$$

2.11 Genetik Algoritmalar (GA)

Çalışmada kullanılan OSA, BCO, GYA ve SOM birer yapay sinir ağı uygulamalarıdır. Bu uygulamaların yayılım sabiti, iterasyon sayısı gibi bazı parametreleri, geliştirilen aritmi kaynağını tespiti yapısının başarımını etkilemektedirler. Sözü geçen diğer kümeleme ve sınıflandırma algoritmalarının optimizasyonları deneme yanılma yöntemi ile yapıldığı halde yapay sinir ağlarının parametrelerinin optimizasyonu literatürde bahsedilen Genetik Algoritmalar ile yapılmıştır. Bu kısımda GA'ların yapısı, gelişim süreçleri, geleneksel optimizasyon teknikleri ile olan farklılıkları, işleyiş basamakları ve temel yapıları hakkında bilgi verilmiştir.

Endüstri Mühendisliği dünyasında, üretim sistemleri gibi bazı optimizasyon problemlerinin çözümleri karmaşık ve geleneksel optimizasyon teknikleri ile çözülmesi zor problemlerdir [101]. 1960'lardan itibaren bunun gibi çözümü zor optimizasyon problemlerinin çözümünde yaşamı taklit eden mekanizmaların kullanımı popüler hale gelmiştir. İnsanoğlunun doğal evrimini simüle eden stokastik optimizasyon teknikleri “evrimsel algoritmalar” olarak adlandırılır. Bu algoritmalar gerçek dünyadaki uygulamalarda geleneksel optimizasyon yöntemlerine göre daha yüksek performans göstermişlerdir. Bu araştırmanın üç temel sonucu vardır: “genetik algoritmalar (GA)”, “evrimsel programlama (EP)” ve “evrimsel stratejiler (ES)”. Bugünlerde genetik algoritmalar diğer yöntemlere göre daha fazla kullanım alanları bulmuşlardır. Son zamanlarda karmaşık problemlerin çözümlerinde doğası gereği başarıyla uygulanabilen bir optimizasyon tekniği olarak genetik algoritmalar ilgiyi üzerlerine çekmektedirler. Bilinen uygulamaları arasında; zamanlama ve sıraya koyma, güvenilir dizayn, araç rota belirleme ve zamanlaması, grup teknolojisi, servislerin yerinin ve yerleşim planının belirlenmesi ve ulaşım problemleri bulunmaktadır. Genetik algoritmaların alışılmış genel yapıları Goldberg tarafından açıklanmıştır. Genetik Algoritmalar doğal seçim ve

dođal genetik mekanizmaları tabanlı stokastik araştırma mekanizmalarıdır. Diđer geleneksel araştırma yöntemlerinden farklı olarak genetik algoritmalar rastgele çözümlerin başlangıç seti yani “popülasyon” ile başlar. Popülasyondaki her bir bağımsız birey problemin her bir olası çözümü olan kromozomlar. Kromozom semboller dizisidir; gerekli olmamakla birlikte çoğunlukla bir ikili (binary) bit dizisidir. Kromozomlar “kuşaklar” olarak adlandırılan birbirini takip eden iterasyonlar ile evrimleşirler. Her kuşakta, kromozomlar “uygunluđun” bir ölçümü kullanılarak evrimleştirilir. Bir sonraki kuşağı yaratmak için aşıđıdaki yöntemlerden faydalanılır;

- a-) “çaprazlama” operatörü kullanarak mevcut kuşaktan iki kromozonu eşleştirmek.
- b-) “mutasyon” operatörü kullanarak bir kromozonu deđiştirmek.

Yeni bir kuşak uygunluk fonksiyonunu göre bazı ebeveynler ve ođullar seçilir, bazıları ise atılır ve böylece popülasyondaki birey sayısı sabit tutulur. Daha uygun olan kromozomların seçilme sansı daha fazladır. Birkaç kuşak sonra algoritma problemin çözümünün optimum çözümü olduđu düşünölen en iyi kromozoma dođru yaklaşır. Eđer $P(t)$ ve $C(t)$ mevcut t kuşağına ait ebeveynler ve ođullar olarak kabul edilirse, genetik algoritmanın genel yapısı Çizelge 2.1’de verildiđi gibidir.

Çizelge 2.1 Genetik algoritmaların işleyiş basamakları.

| Prosedür: Genetik Algoritmalar | |
|--------------------------------|---|
| Adım 1 | başla; |
| Adım 2 | $t \leftarrow 0$; |
| Adım 3 | $P(t)$ 'ye başlangıç ata; |
| Adım 4 | $P(t)$ 'yi hesapla; |
| Adım 5 | $C(t)$ 'yi oluşturmak için $P(t)$ 'yi değiştir; |
| Adım 6 | $C(t)$ 'yi hesapla; |
| Adım 7 | $P(t+1)$ 'i $P(t)$ ve $C(t)$ 'den seç; |
| Adım 8 | $t \leftarrow t+1$; |
| Adım 9 | bitir; |

Bu prosedür, Grefenstette ve Baker tarafından modifiye edilmiştir. Genellikle başlangıç değerleri rastsal olarak atanır. Çaprazlama ve mutasyon ile tekrar kombinasyon sağlanır ve oğullar elde edilir. Gerçekte genetik algoritmalarda iki çeşit işlem vardır:

1. Genetik operasyonlar: çaprazlama ve mutasyon
2. Evrimsel operasyonlar: seçme

Genetik operasyonlar her kuşakta yeni oğullar oluşturabilmek için genlerin soyaçekim işlemini taklit eder. Evrimsel operasyon ise kuşaktan kuşağa popülasyonlar yaratabilmek için “Darwinsel Evrimi” taklit eder.

Çaprazlama genetik algoritmaların temel operatorudur. Bu operator iki kromozom üzerinde işlem yapar ve bu kromozomların özelliklerini biraraya getirerek oğulları oluşturur. “Çaprazlama oranı” (p_c ile gösterilir) popülasyon boyutuna (pop_size)

her kuşakta oluşturulan oğulların sayısının oranı olarak açıklanır. Bu oran kromozomların $p_c \times pop_size$ beklenen sayısını kontrol eder. Bu oranın yüksek olması çözüm uzayının genişletilmesini ve yanlış bir optimuma yaklaşıma şansının düşmesini ifade eder. Fakat çok yüksek bir rakam ise çözüm uzayının ümit vermeyen bölgelerinde çokça hesaplama zamanının harcanması anlamına gelir. Mutasyon operatörü çok sayıda kromozomda rastgele anlık değişimleri gerçekleştiren arka planda bir operatördür. “Mutasyon oranı” (p_m ile gösterilir) popülasyondaki toplam gen sayısının yüzdesi olarak tanımlanır. Mutasyon oranı, yeni test genlerinin popülasyona tanıtılma oranını kontrol eder. Eğer bu oran çok düşük ise popülasyona yararlı olacak çok sayıda genin hiç denenmediği anlamına gelir. Eğer bu oran çok yüksek ise yeni oluşan genlerin araştırmacının geçmişinden öğrenebilme yeteneğinin düşük olmasını gösterir. Genetik algoritmaların geleneksel optimizasyon ve araştırma algoritmalarından temel olarak bazı farklılıkları vardır. Goldberg bu farkları şu şekilde özetlemiştir:

1. Genetik algoritmalar çözümün kendisi üzerinde değil bir çözüm seti üzerinde çalışır.
2. Genetik algoritmalar tek bir çözümü değil bir çözüm popülasyonu arar.
3. Genetik algoritmalar, türev ya da diğer yardımcı bilgileri değil uygunluk fonksiyonunu gösterir.
4. Genetik algoritmalar deterministik kuralları değil olasılıksal kuralları kullanır.

Genetik algoritmalar, alışılmışın dışında bir optimizasyon tekniği olması potansiyeli nedeniyle oldukça ilgi gördü. Genetik algoritmaları, optimizasyon problemlerine uygularken 3 temel avantaj bulunmaktadır.

1. Genetik algoritmalar, optimizasyon problemleri ile ilgili çok fazla matematiksel işlemler gerektirmez. Evrimsel doğaları nedeniyle Genetik algoritmalar, problemin özel içsel çalışmalarına bakmaksızın çözümler araştırır. Genetik algoritmalar, her türlü nesnel fonksiyonlar ve farklı devam eden ya da karışık araştırma uzayları üzerinde tanımlanmış her çeşit sınırlamalar (örneğin doğrusal ya da doğrusal olmayan) ile baş edebilir.

2. Evrimsel operatörlerin ergodikliği (olasılıktaki) global araştırmayı uygulamada Genetik algoritmaları oldukça etkili hale getirmektedir. Geleneksel yaklaşımlar, ilgili en iyi noktalara hareket eden ve en yakın noktaların değerlerini karşılaştıran birleşik adımsal süreç ile yerel araştırmayı gerçekleştirirler. En iyi global uygun durum, eğer problem herhangi bir en iyi yerel durumun en iyi global bir durum olmasını özellikle garantileyen belirgin dışbükeylik özelliklerine sahipse, en iyi global durum bulunabilir.
3. Genetik algoritmalar, belirli bir problem için etkili bir uygulama yapmak üzere alana bağlı bulucular ile melezleştirme yapabilmek için bize mükemmel bir esneklik sağlar.

Genetik algoritmanın en basit şekli; seçim, çaprazlama (tek bir nokta) ve mutasyon olmak üzere üç çeşit operatörden oluşmaktadır.

Seçim: Bu operatör, yeniden üretim için popülasyondaki kromozomları seçer. Kromozom ne kadar uygun olursa, yeniden üretim için o kadar daha fazla seçilebilir.

Çaprazlama: Bu operatör, rasgele bir hat seçer ve ikili oğul oluşturan iki kromozomun arasındaki hattın öncesi ve sonrasındaki elde edilenleri değiştirir. Örneğin; 10000100 ve 11111111 dizileri üçüncü bir hat üzerine çaprazlanabilir ve her biri iki 10011111 ve 11100100 oğul üretir. Çaprazlama operatörü kabaca ikili-tekil kromozom(yarı kromozomlu hücre) organizmalar arasındaki yeniden biyolojik birleşmeyi taklit eder.

Mutasyon: Bu operatör, bir kromozomdaki bitlerin bazılarını rasgele çevirip döndürür. Örneğin; 00000100 dizisi, 01000100 dizisi oluşturmak için ikinci bir pozisyonda mutasyona uğrayabilir. Mutasyon, genellikle çok küçük (örneğin; 0.001) bazı olasılıklar ile bir dizideki her bir bit pozisyonunda meydana gelebilir.

Çözülmesi gerektiği bilinen bir problem ve aday çözümler için bir bit dizisi sunumu için, basit bir algoritma şu şekilde çalışmaktadır:

1. Bir probleme olası çözümleri ifade eden n tane 1 bit kromozomların rasgele üretilmiş bir popülasyonu ile başlayın.
2. Popülasyondaki her bir x kromozomu için uygunluk fonksiyonunu $f(x)$ hesaplayın.
3. n tane oğulu yaratılana kadar aşağıdaki aşamaları tekrar edin.
 - a. Mevcut popülasyondan bir çift ebeveyn kromozomu seçin, bu seçimin olasılığı uygunluk fonksiyonunun artan bir fonksiyonu olmalıdır. Seçim, aynı kromozomun ebeveyn olabilmesi için birden fazla seçilebileceği anlamına gelen “yerleştirme” ile gerçekleşir.
 - b. İki oğul oluşturabilmek için, rasgele seçilmiş bir noktada (seçilmiş bir tek olasılık ile), p_c olasılığı (“çaprazlama olasılığı” ya da “çaprazlama oranı”) ile, çifti çaprazlayın. Eğer çaprazlama gerçekleşmezse, ebeveynlerin ayrı ayrı herbir kopyası olan iki oğul oluşturun. Çaprazlama oranının, iki ebeveynin tek bir noktada çaprazlanabilme olasılığına göre belirlendiğini unutmayınız. Basit algoritmanın değişik bir biçimi olan “çoklu-nokta çaprazlama” şekli de vardır. Burada, her bir ebeveyn çiftinin çaprazlama oranı, çaprazlamanın olduğu nokta sayısıdır.
 - c. Her hata, p_m olasılığı (mutasyon olasılığı ya da mutasyon oranı) ile iki oğulu mutasyona uğrattın ve yeni popülasyona sonuç kromozomlarını yerleştirin.

Eğer n tek sayı ise, yeni bir popülasyon üyesi rasgele atılabilir.

4. Mevcut popülasyonu yeni popülasyonla yer değiştirin.
5. 2.aşamaya dönün.

Her tekrarlanan bu sürece üretim adı verilir. Genetik algoritma, 50'den 500'e kadar her yer ya da daha fazla nesiller için her zaman tekrarlanır. Nesillerin toplam setine, popülasyonda sıklıkla bir ya da daha fazla yüksek uygunlukta kromozomlar vardır. Rasgelelik her bir seride büyük bir rol oynadığından, farklı rasgele sayı tohumları ile iki seri, genellikle farklı ayrıntılı davranışlar üretecektir. Genetik algoritma araştırmacıları, aynı problemdeki genetik algoritmanın çoğu zaman aynı problem üzerinde ortalamada yanı olmak üzere farklı çözümler ürettikleri istatistikçiler tarafından bildirilmiştir (örneğin en iyi uygunluk fonksiyonuna sahip aynı popülasyondaki farklı bireylerin sonuç olarak atanması).

Bu kısımda açıklanan prosedür, çoğu genetik algoritma uygulamalarının temel yapısıdır. Popülasyon büyüklüğü, çaprazlama ve mutasyon olasılıkları gibi algoritmanın başarımına etki eden faktörlerde bulunmaktadır. Genetik algoritmaların farklı ve gelişmiş versiyonları bulunmaktadır (örneğin diziler yerine terimler ile çalışan yapılar veya değişik çaprazlama ve mutasyon operatörlerine sahip yapılar). Daha önceki kısımlarda sadece temelleri ve operatörleri açıklanan genetik algoritmaların çok sayıda bilimsel ve mühendislik problemlerine adapte edilmiş, uygulanmış modelleri bulunmaktadır. Bu uygulama alanlarının bazıları şunlardır. Elektronik devre çizimleri, yüz tanıma problemleri, nümerik optimizasyon gibi çok geniş bir yelpazedeki optimizasyon görevlerinde genetik algoritmalar kullanılmaktadır.

2.12 Özellik (Feature) Seçimi

VYP haritalarından elde edilen veri ile bu çalışmada geliştirilen aritmi yerinin tespiti mekanizmasının test edilmesi sırasında, veri boyutunun çok büyük olması nedeniyle zamansal ve uzaysal azaltıma gidilmiştir. Bu kısımda öncelikle özellik çıkarımı ve seçimi yönteminin temel mantığı kısaca açıklanmıştır. Daha sonra literatürde medikal veri setlerinde kullanıldıkları bilinen Karhunen-Loeve Dönüşümü, QRS ve QRST İntegrallerinin temel özellikleri anlatılmıştır.

Bir sisteme giren girişlerin bütün bir bilgi olarak değil de bu bilgiyi oluşturan özelliklerden bazılarının çıkarılması ve sistemin bu özellikler üzerine kurulması işlemine özellik seçimi denilir [102]. Örneğin bir miktar resimden içinde çimen bulunanların tespit edilmesi isteniyor olsun. Bilindiği üzere çimenler yeşildir ve

resimlerden yeşil tonun ağırlıkta olanlarının çimen içermesi ihtimali yüksektir. Öyleyse sisteme giren bir resmin tamamının işlenmesi yerine resmin histogramının (renk kodlarının dağılımının işlenmesi buna bir örnek olabilir. Resim, basitçe histogramından çok daha karmaşık ve büyük bir veridir. Bu veri histogramı çıkarılmak suretiyle küçültülmüş ve istenen amaca yönelik olarak işlenmiştir. Özellik çıkarımı işlemi bir boyut azaltma (dimension reduction) işlemidir. Buna göre karmaşık olan bir verinin boyutları azaltılarak daha basit bir problem haline indirgenir. Doğru yapılmış bir özellik çıkarımı ve bu özelliklere uygun bir sistem tasarımı sonucun başarılı olması ve performansını etkileyen unsurlardır. Ayrıca özellik çıkarımı sonucunda elde edilen birden fazla özelliğin karşılığını tutan veri yapısına özelliklik vektörü (feature vector) adı da verilmektedir [103].

Resim işleme ve yapay sinir ağlarında sıkça kullanılan özellik çıkarımı üzerinde de çalışmalar sürmektedir [104;105]. Örneğin borsa verilerinin ses sinyallerinin veya doğaya yönelik ölçümlerin her geçen gün arttığını görmekteyiz. Kanser araştırmalarında [106] ve medikal görüntü işlemede [107] özellik seçiminden yararlanılmaktadır. Bu yöntemler dışında En İyi "Lead" Yöntemi, Eş Güç Hesaplanması, Çok Kanallı Uzaysal Güç Spektrumu ve Dalgacık Dönüşümü gibi yöntemlerde mevcuttur. Fakat yukarıda bahsedilen iki yöntemin YSA'lar ile kullanımında istenilen başarı sağlanamadığından ve elimizde yeterli veri seti olmadığından diğer özellik seçimi yöntemleri uygulanmamıştır.

2.12.1 Karhunen–Loeve Dönüşümü (KLD)

VYP Haritalarında en çok kullanılan dönüşüm tekniğidir [74]. Genel dijital görüntüler için desen tanımadaki, özellik miktarının belirlenmesinde, sıkıştırılmasında ve ifade edilmesinde sıklıkla kullanılır [108]. İlk olarak deneysel uzaysal kovaryans matrisinin özdeğer (eigen) ayrıştırılması yapılır. Daha sonra uzaysal KL katsayılarının çok kanallı zaman serilerini üretmek için bağımsız zaman örneklerinin öz nitelik vektörleri üzerinde izdüşümü alınır. Katsayıların bir azaltılmış boyutlu çok kanallı zaman dizileri formu elde etmek için sadece en büyük özdeğerler kullanılır (200 sayıda özdeğerden yaklaşık 15-20 tanesi yeterlidir). Zaman eksenini boyunca KL işleminin tekrarlanması için katsayıların zamansal korelasyon matrisi kullanılır. 320:1 oranına kadar varan sıkıştırma oranı iyi bir kesinlik için yeterlidir [109;110]. Elde tutulan uzaysal özdeğer vektörleri

veride en çok görülen tipik dağılım modellerinin temsilcileri olarak düşünülür ve kümeleme algoritmaları için özelliklerin çıkarılmasında kullanılır [111;112;113]. Bu yöntem geniş bir eğitim veri setini gerektirir. Ayrıca bu yöntemin kullanılabilmesi için sensörlerin yerlerinde sabit kalmaları, ölçüm boyunca hareketsiz olmaları gerekmektedir ki bu koşul direkt epikardiyal kayıtlarda pek geçerli değildir. Stokastik işlemlerde; Karhunen-Loeve teoremi (Kari Karhunen ve Michel Loeve tarafından isimlendirilmiştir) bir stokastik işlemin dik (ortogonal) fonksiyonların sonsuz doğrusal kombinasyonları olarak ifade edilir. Bu ifadenin bir benzeri sınırlı bir aralıkta tanımlı olan Fourier Serileridir. Buradaki ayırım Fourier katsayılarının rastsal değişkenler olmasıdır. Bu biçimdeki sonsuz seriler tarafından verilen stokastik işlemler daha önce Damodar Dharmananda Kosambi tarafından düşünülmüştür [114].

Fourier Serilerinde katsayıların gerçekte sayılar olmasına ve genişleme temellerinin sinüs fonksiyonlarından (sinüs ve kosinüs) oluşuyor olmalarına karşın Karhunen-Loeve teoreminde ise katsayılar rastsal değişkenlerdir ve genişleme temelleri işlemin gidişine bağlıdır. Gerçekte, bu ifadedeki dik temel fonksiyonları işlemin kovaryans fonksiyonları tarafından hesaplanırlar. Eğer bir stokastik işlemi F ile ifade edilen $[a,b]$ aralığında tanımlı bir rastsal değişken olarak kabul edersek, bu teorem F 'nin bir rastsal ortogonal açılımı olur [115;116]. Eğer $\{X_t\}_{t \in [a,b]}$ teknik süreklilik durumunu sağlayan bir ortalanmış stokastik bir işlemse (burada ortalanmış ifadesinin anlamı $E(X_t)$ beklentisinin t parametresinin $[a,b]$ aralığında bütün değerleri için sıfıra eşit olmasıdır) aşağıdaki ayrışmaya uygun olmalıdır.

$$X_t = \sum_{k=1}^{\infty} Z_k e_k(t) \quad (2.22)$$

Burada Z_k ilintisiz rastsal değişkenlerdir ve e_k ise $L^2[a,b]$ içinde ortogonal olan $[a,b]$ üzerinde tanımlı, sürekli gerçekte değerli fonksiyonlardır. İşlemin ortalanmış olmayan genel durumu, bir rastsal olmayan fonksiyon olan tahmin fonksiyonunun e_k temeli üzerinde genişletilmesi olarak ifade edilebilir. Eğer işlem bir Gaussian işlemi ise, Z_k rastsal değişkenleri Gaussian ve stokastik olarak bağımsız değişkenlerdir. Bu sonuç Karhunen-Loeve dönüşümünün genelleştirilmiş halidir. $[0,1]$ aralığında ortalanmış bir gerçekte stokastik işlem örnek Wiener işlemidir ve Karhunen-Loeve teoremi bu

işlem için bir kanonik ortogonal ifade sağlanması için kullanılır. Bu durumda genişleme fonksiyonu sinüs fonksiyonudur [117]. İntisiz rastsal değişkenler üzerinde yapılan bu genişleme işlemi Karhunen-Loeve Genişlemesi veya Karhunen-Loeve Ayrışması olarak bilinir. Bu ifadenin ampirik (deneysel) versiyonu ise Principal Component Analysis (PCA), Proper Ortogonal Decomposition (POD) ya da Hotelling Dönüşümü olarak bilinir. Burada sonucu karmaşık değerli stokastik işlem olarak vereceğiz. Gerçek değerli stokastik işlemlerde ise bir gerçek sayının karmaşık konjugatinin kendisine eşit olduğu unutulmamalıdır. Eğer X ve Y rastsal değişkenler ise, içsel çarpım işlemi matematikte aşağıdaki gibi tanımlanır.

$$\langle X|Y \rangle = E(X * Y) \quad (2.23)$$

Burada $*$ karmaşık konjugate işlemi temsil etmektedir. İçsel çarpma işlemi, X ve Y 'nin ikisinde sınırlı ikinci momentleri varsa ya da ikisinde kare integraller (square integral) ise tanımlıdır. İçsel çarpım kovaryans ve korelasyon ile ilintilidir. Özellikle sıfır ortalamalı rastsal değişkenlerde içsel çarpım ve kovaryans birbirinin karşılığıdır. Otokovaryans fonksiyonu şu şekilde tanımlanır.

$$\begin{aligned} K_{XX}(t, s) &= Cov[X(t), X(s)] = \langle X_t | X_s \rangle = E\{[X(t) - \mu_X(t)] [X(s) - \mu_X(s)]\} \\ &= E\{X * (t) X(s)\} - \mu_X^*(t) \mu_X(s) \\ &= R_{XX}(t, s) - \mu_X^*(t) \mu_X(s) \end{aligned} \quad (2.24)$$

Eğer $\{X_t\}_t$ ortalanmış bir işlem olarak tanımlanırsa bütün t 'ler için $\mu_X(t) = 0$ olur. Bu durumda K_{XX} otokovaryans fonksiyonu ile R_{XX} otokorelasyon fonksiyonları aynı olur.

$$K_{XX}(t, s) = R_{XX}(t, s) \quad (2.25)$$

$\{X_t\}_t$ ortalanmış bir işlemse ve $t_1 \leq t_2 \leq \dots \leq t_N$ noktaları $[a, b]$ içerisindeyse,

$$\sum_{k,l} Cov_X(t_k, t_l) = Var\left(\sum_{k=1}^N X_k\right) \geq 0 \quad (2.26)$$

olur. Burada ilk olarak Bir kalp atımını ifade eden görüntü dizisinin uzaysal kovaryans matrisi elde edilir.

$$\sum_x = E[(X - E[X])(X - E[X])^T] \quad (2.27)$$

Bu matrisin öz (eigen) ayrışımı (decomposition) gerçekleştirilir.

$$\sum_x \phi_k = \lambda_k \phi_k \quad (k = 0, \dots, N-1) \quad (2.28)$$

Bunun matris formunda ifadesi

$$\sum_x \Phi = \Phi \Lambda \quad (2.29)$$

olarak verilir. Daha sonra, bağımsız zaman örneklerinin özvektörlerin üzerindeki izdüşümleri hesaplanır (KL katsayıları).

$$y = \begin{bmatrix} y_0 \\ y_1 \\ \dots \\ y_{N-1} \end{bmatrix} = \Phi^T x = \begin{bmatrix} \phi_0^T \\ \phi_1^T \\ \dots \\ \phi_{N-1}^T \end{bmatrix} x \quad (2.30)$$

Burada y_i 'nin i ifadesi

$$y_i = (\phi_i, x) = \phi_i^T x \quad (2.31)$$

olarak verilir. En son olarak, bu bileşenlerden en büyük özdeğerlere ait olanlardan bazıları seçilir.

$$\phi_i \quad (i = 0, \dots, K-1) \quad K < N \quad (2.32)$$

Günümüzde özellikle dağıtılmış sinyal işlemeyi içeren birçok uygulamalarda, Karhunen-Loeve Dönüşümü uygulamak imkansızdır. Bu durumlar için Michael Gastpar ve arkadaşları dağıtılmış Karhunen-Loeve dönüşümlerini geliştirmişlerdir [118].

2.13 apraz Saęlama

Bu alıřmada geliřtirilen aritmi yerinin tespiti algoritması iki veri seti üzerinde denenmiřtir. İlk veri setinde bir deneyden elde edilen veriler test veri seti; dięer deneylerden elde edilen veriler ise eęitim seti olarak kullanılmıřtır. Eęitim kateter veri seti kmeleme yntemleri iin giriř setini oluřturmuřtur. Test veri setinden ise aritmi yerinin sınıflandırılmasında yararlanılmıřtır. Fakat benzetim veri setinde eęitim ve test veri setleri mevcut deęildir. Kmeleme ve sınıflandırma iin gerekli bu veri seti ayrımı, istatistikte olduka sık kullanılan apraz saęlama ile saęlanmıřtır. Bu kısımda apraz saęlama ynteminin temel yapısı, amacı ve k kat apraz saęlamanın anlamı açıklanmıřtır.

Bazen dnme tahmini diye de adlandırılan apraz-saęlama teknięi, bir baęımsız veri setine karřı bir istatistiksel analiz sonularının nasıl genelleneceęini tahmin eder [43;119;120]. Bu teknik genellikle amacın tahmin olduęu uygulamalarda, eęer tahmin algoritması gerekte ne kadar kesinlikle alıřacaęı merak ediliyorsa kullanılır. apraz-saęlamanın ilk ařamasında bir rnek veri seti birbirini tamamlayan alt setlere ayrılır. Daha sonra bir alt set (eęitim seti) iin analiz yntemi alıřtırılır ve dięer alt set (test setleri) zerindeki saęlaması yapılır. Deęiřkenlięi azaltmak iin farklı ayırmalar zerinde ok sayıda apraz-saęlama iřlemi yapılır ve saęlama sonularının ortalaması alınır.

apraz saęlama teknięi zellikle rneklerin zarar grdę veya toplanmalarının ok olduęu durumlarda ortaya atılan hipotezi desteklemede kullanılır. Bu gibi durumlarda bu yntem olduka nem kazanır [121].

apraz Saęlamanın Amacı: Bir ya da daha fazla sayıda bilinmeyen parametreye sahip ve bir model zerinde alıřtıęımızı ve bu modele uyan bir tek veri setinin (eęitim seti) elimizde olduęunu dřnelim. Kullandıęımız uygunluk iřlemine model parametrelerini eęitim setine bakarak olabildięi kadar optimum hale getirmeye alıřır. Eęer aynı poplasyondan saęlama verisinden bir baęımsız rneęi eęitim verisi olarak alırsak, model bu rneęe eęitim setindeki rnek kadar uyum saęlayamayacaktır. Bu duruma ařırı uyumluluk (overfitting) denir ve genellikle eęitim setinin kk, modeldeki parametre sayısının fazla olduęu durumlarda

meydana gelir. Modele uyan kesin bir sağlama seti yoksa, çapraz sağlama yöntemi modele uyacak bir set tahmin etmekte oldukça etkilidir.

k kat çapraz – sağlama: k kat çapraz sağlama yönteminde orjinal örnek rastsal olarak k sayıda alt örneğe ayrılır. Bu alt örneklerden bir tanesi modelin test edilmesinde diğer k-1 alt model ise modelin eğitilmesinde kullanılır. Her bir örnek test datası olacak şekilde bu işlem k defa tekrarlanır (k kat). Bu işlemlerden elde edilen k adet sonucun ortalaması alınır (ya da biraraya getirilir) ve tek bir tahmin elde edilmiş olur. Bu yöntemin tekrar eden alt örnek uzaylarındaki avantajı her bir gözlemin hem eğitim hemde sağlamada kullanılabilmiş olmasıdır. Genellikle 10 adet k kat sayısı seçilir [122;123].

2.14 Kümeleme Kalitesi

Bu kısımda, çalışma sırasında çeşitli yöntemler kullanılarak (elle kümele, SOM, Bulanık C Tane Ortalama vb...) elde edilen kümelerin odaklılıklarını ve birbirlerinden ayrımlarını ya da kalitesini hesaplamak için kullanılan yöntemler açıklanmıştır. Kümeleme kalitesi hem kümeleme sonucunu hem de sınıflandırma sonucunu dolayısıyla geliştirdiğimiz yöntemin performansını doğrudan etkilemektedir. Kümelemenin kalitesini mümkün olduğunca arttırmak için kullandığımız araçlar bu kısımda anlatılmıştır.

Kümeleme doğruluğunu, sağlamlığını hesaplamak için bir çok kriter geliştirilmiştir [124-130]. Bu kriterlerin hepsi sıkılaştırılmış, yoğun ve diğerlerinden iyice ayrılmış bir kümeyi bulma amacı taşırlar. Örnek olarak Davies-Bouldin indeksi, toplam iç-kümelemenin kümeler-arası boşluğa oranının bir fonksiyonu olarak tanımlanmıştır [124]. Bu yaklaşımın amacı iç-kümelemeyi maksimum, kümeler-arası boşluğun ise maksimum yapılmasıdır. Bezdek ve Pal, Dunn tarafından ortaya atılan indeksi geliştirmişlerdir [126]. Kümeler arasındaki uzaklık fonksiyonunun beş farklı ölçüsünü ve küme çaplarının üç farklı ölçüsünü ele alarak Dunn indeksine genel bir yaklaşım getirmişlerdir. Genellikle kümeleme kalitesi, sağlamlığını hesaplamak için iki temel hesaplama yapılması gerekmektedir [128;129]:

İntra-Kümeleme (Küme içi yayılma): Aynı kümenin içindeki küme elemanlarının arasındaki uzaklıkların ortalaması alınarak bir küme için küme İçi Yayılma sayısı

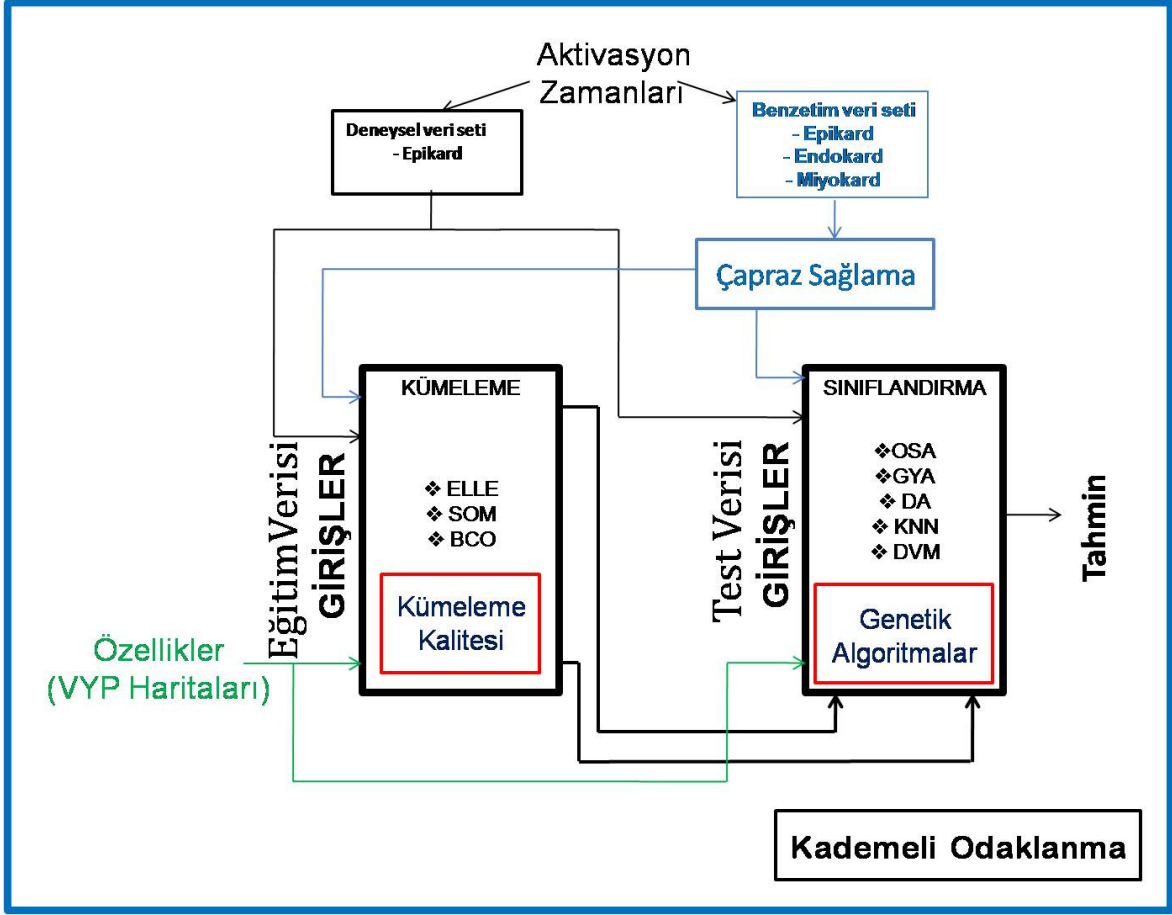
elde edilmiş olur. Eğer birden fazla küme oluşturulmuş ise, her bir kümenin küme içi yayılma sayısı elde edilir, daha sonra bunların ortalaması alınarak kümeleme işleminin geneli hakkında bir kanıya ulaşılabılır. Noktalar arasındaki mesafeyi hesaplamak için çeşitli uzaklık hesaplama algoritmaları kullanılabilir. Euclidean, Mahalanobis, Chebyshev, Minkovski veya Metrik uzaklık hesaplama yöntemlerinden yararlanılabilir. Bu çalışmada uzaklık hesaplaması olarak Euclidean uzaklığı kullanılmıştır.

İnter-Kümeleme (kümelerarası yayılma): Bir kümedeki elemanların diğer kümelerdeki elemanlara olan uzaklıklarının ortalamasıdır. Eğer birden fazla küme oluşturulmuş ise, her bir kümenin inter-kümeleme sayısı elde edilir, daha sonra bunların ortalaması alınarak kümeleme işleminin geneli hakkında bir kanıya ulaşılabılır. Noktalar arasındaki mesafeyi hesaplamak için çeşitli uzaklık hesaplama algoritmaları kullanılabilir. Euclidean, Mahalanobis, Chebyshev, Minkovskiveya Metrik uzaklık hesaplama yöntemlerinden yararlanılabilir. Bu çalışmada uzaklık hesaplaması olarak Euclidean Uzaklığı kullanılmıştır. Kümenin sağlamlığının veya kalitesinin yüksek olması için küme içi yayılma sayısının düşük, inter-kümeleme sayısının ise yüksek olması hedeflenir. Bazı uygulamalarda, küme elemanlarının küme merkezine olan uzaklıkları ve diğer kümelerin merkezlerine uzaklıkları intra ve inter-kümeleme sayılarının hesaplanmasında kullanılır [131].

3. YÖNTEMLER

Bu bölümde; fokal aritmilerin yerlerinin tespitinde eğitim ve test verisi olarak kullanılan deneysel ve benzetim veri setleri ve yöntemlerinin bu veri setlerine nasıl uygulandıkları, parametrelerinin değerleri ve nasıl optimize edildikleri ayrıntıları ile açıklanmıştır.

Bu çalışmada kullanılan yöntemlerin genel blok yapısı Şekil 3.1 **Error! Reference source not found.**'de verilmiştir. Burada deneysel veri seti ve benzetim veri seti asla aynı anda kullanılmamıştır. Kateter tabanlı kalp haritalamasında aktivasyon zamanı veya VYP haritalarından çıkarılan özellikler kullanılmıştır. Aktivasyon zamanı haritaları için iki veri setinden yararlanılmıştır. Deneysel veri setinin eğitim verisi kümeleme yaklaşımlarına giriş olarak verilmiş ve katmanın bölgelerini içeren hedef vektörü elde edilmiştir. Deneysel veri setinde kümeleme için Elle Kümeleme, SOM ve BCO uygulanmıştır. Elde edilen hedef vektörü ve sınıflandırma yöntemlerinin girişi olarak deneysel test veri seti kullanılarak aritmi yerinin bulunduğu bölge tahmin edilmiştir. Deneysel veri seti için Şekil 3.1'de gösterilen sınıflandırma algoritmalarının hepsi kullanılmıştır. Özellik veri setinde ise kümeleme için Elle Kümeleme, SOM ve BCO kullanılırken sınıflandırma için sadece OSA'dan yararlanılmıştır. Benzetim veri setinin eğitim ve test veri seti olarak ayrımı çapraz sağlama ile gerçekleştirilmiştir. Eğitim verisi, BCO kümelemenin girişi olarak atanmıştır. Aritmi yerinin tahmininde OSA, DA, kNN ve DVM kullanılmıştır. Kümeleme sonucunda oluşan bölgelerin odaklılığı ve birbirlerinden ayrılmışlığı kontrol edilmiş ve genetik algoritmalar ile hem kümeleme kalitesi hemde tahmin başarımları optimize edilmiştir. Kademeli odaklanma ile atanan kümenin alanı azaltılmıştır.

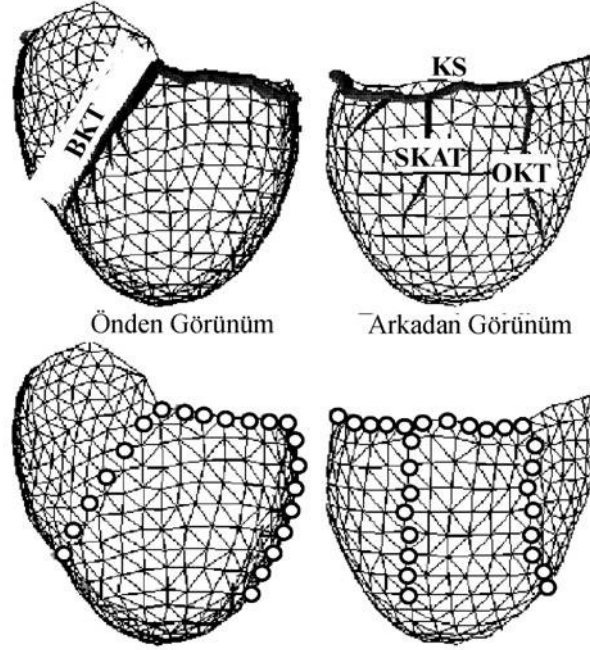


Şekil 3.1 Çalışmada kullanılan veri setlerinin ve yöntemlerin genel blok gösterimi.

3.1 Deneysel Veri

Bu çalışma sırasında kullanılan deneysel veri seti, Utah Üniversitesi, Kardiyovasküler Araştırma ve Eğitim Enstitüsünde gerçekleştirilen 13 adet köpek kalbi deneyinden elde edilmiştir. Deneysel verimiz kalbin dış yüzeyine 490 elektrotlu ince ve esnek bayan çorabının ayak kısmından yapılmış çorap elektrot dizisinin (sock electrode array) iki karıncığı kaplayacak şekilde geçirilmesiyle elde edilmiş olup ortalama elektrotlararası uzaklığı 4.3 mm'dir [38;132]. Elektrotların dizilimi orta boydaki bir köpek kalbinin karıncıklarının şeklindeki işaretlemeleri takip etmiştir. Aynı enstitüde daha evvel yapılan çalışmalar, venlerin içerisinde alınan elektriksel verilerle, çok yakınında bulunan epikard bölgesinden alınan verilerin aktivasyon zamanlamaları ve biçimsel olarak yüksek oranda benzerlikleri olduğunu göstermektedir. Dolayısıyla, 490 elektrotlu çorap geometrisi üzerinde olan ve aynı zamanda koroner toplardamarların yerlerine karşılık gelen bölgelerdeki 42 elektrotu kateter elektrot seti olarak varsaydık. Bu kabul bize bu tarz fizibilite

çalışmalarında esneklik ve kolaylık sağlamaktadır. Şekil 3.2, **Error! Reference source not found.** bu çalışmada kullandığımız çorap geometrisini ve kateter elektrotlar olarak varsaydığımız 42 elektrotun o geometri üzerindeki yerlerini göstermektedir. Burada ağdaki her bir düğüm bir elektrota karşılık gelmektedir.



Şekil 3.2 490 elektrotlu çorap geometrisi ve kateter elektrotlar olarak varsaydığımız 42 elektrotun o geometri üzerindeki yeri.


Venöz kateterlerin yerleştirildiğini varsaydığımız toplardamarlar şunlardır: Büyük Kalp Toplardamarı (BKT), Kononer Sinüs (KS), Sol Karıncık Arka Toplardamarı (SKAT) ve Orta Kalp Toplardamarı (OKT). Epikardiyal elektrot çorap dizisi elde edilen potansiyelleri kaydetmek için 1024 kanallı, 12 bit çözünürlüğe kadar çıkabilen ve 1 KHz örnekleme frekansına sahip manyetik diskli bir veri alma sistemi kullanılmıştır [133]. Elde edilen kayıtların işlenmesinde ilk basamak her üç saniyelik kayıtlardan bir örnek atımın elle seçilmesi olmuştur. İkinci aşamada her elektrogramın QRS kompleksinde maksimum negatif eğim zamanları (minimum zaman türevi) ile aktivasyon-zaman değerleri elde edilmiştir. Son olarak elde edilen aktivasyon-zaman haritalarındaki düzensiz özellikler ve hatalar bulunup düzeltilmiştir. 520 epikardiyal aktivasyon-zaman haritasından oluşan veri seti eğitim ve test veri setleri olmak üzere ikiye ayrılır. Eğitim veri seti, 12 köpekten 231 sol karıncıkta ve 239 sağ karıncıkta olmak üzere toplam 470 farklı noktadan

elektriksel olarak uyarılmış atımları içerir. Test veri seti ise sol karıncıktan 23 ve sağ karıncıktan 27 kalp atımlarını içermektedir.

3.2 Benzetim Verisi

Benzetim verisinin oluşturulmasındaki temel hedef, daha önce potansiyel verisi elimizde olmayan kalbin endokart, miyokart gibi katmanlarından da veri tabanı oluşturmak ve elimizdeki veri setinin örnek sayısını arttırabilmektir. Bu sayede tam bir kalp haritalamasına ulaşılabilecektir.

Benzetim verileri Aliev-Panfilov elektriksel modeline dayanmaktadır. İki değişkenli Aliev-Panfilov modeli FitzHugh-Nagumo (FHN) modelinin değiştirilmiş bir şeklidir [134]. FHN modelinde hücre zarı elektriksel eşdeğeri Şekil 3.3 **Error! Reference source not found.** ile şematize edilmiştir ([135]'den alınmıştır). Kapasitör membran kapasitesini, doğrusal olmayan akım-voltaj elemanı hızlı akım için, seri bağlı direnç-indüktör-batarya elemanları toparlanma (recovery) akımını ifade etmektedir.



Şekil 3.3 FHN modeli hücre zarı elektriksel eşdeğer devresi.

Bu devre üzerinde Kirşoff kanunlarını kullanarak aşağıdaki iki önemli denkleme ulaşılır.


$$\begin{aligned}
\frac{\partial u}{\partial t} &= \frac{\partial}{\partial x_i} \cdot d_{ij} \cdot \frac{\partial u}{\partial x_j} - ku(u-a)(u-1) - uv \\
\frac{\partial v}{\partial t} &= \varepsilon(u, v)(-v - ku(u-a-1)) \\
\varepsilon(u, v) &= \varepsilon_0 + \mu_1 v / (u + \mu_2)
\end{aligned} \tag{3.1}$$

Bu denklem setinde u transmembran potansiyeli ve v refrakter dönem ile ilgili durum değişkenleri, a aktivasyon eşik değeri ile ilgili parametre ve k transmembran potansiyelini kontrol eden parametre olup, ε_0 , μ_1 , μ_2 refrakter dönem özelliklerini belirleyen $\varepsilon(u, v)$ fonksiyonunun değişkenleridir. d_{ij} iletkenlik tensörü olup uzunlamasına (longitudinal) ve yana doğru (transvers) fiber yönleriyle ilgili katsayılar d_1 ve d_2 , fiber yönündeki birim vektör α cinsinden aşağıdaki şekilde yazılır [136].

$$\begin{aligned}
\frac{\Delta u}{\Delta t} &= L(i, j, k) - ku(u-a)(u-1) - uv \\
\frac{\Delta v}{\Delta t} &= \varepsilon(u, v)(-v - ku(u-a-1))
\end{aligned} \tag{3.2}$$

(3.1) ve (3.2) denklemlerinde $k=8$, $a=0.15$, $\varepsilon_0=0.002$, $\mu_1=0.2$, $\mu_2=0.3$ olmak üzere $\Delta x=0.6$ mm ve $\Delta t=0.07$ ms değerleri kullanılarak çözüm yaklaşımsal olarak gerçekleştirilir. Daha sonra veri seti oluşturulmaya başlanır. Üç veri ambarı oluşturulmuştur: Geometri veri ambarı, benzetim veri ambarı ve bilinen noktalar veri ambarı.


Benzetim geometrisi 532552 noktadan oluşmaktadır. Bu noktalardan 14984'ü kalbin sol endokartında, 13310'u sağ endokartında, 42992 tanesi ise epikartta yer alan noktalardır. Bu noktalar sol endokart için 562'ye, sağ endokart için 488'e, epikart için ise 1540'a düşürülerek geometri veri ambarı oluşturulmuştur. Bunun yanı sıra bu noktalar için ağ geometrileri map3d programında oluşturulmuştur. Ayrıca miyokart için endokarttaki toplam 1050 (562+488) ve epikarttaki 1540 nokta sayısı arasında geçişi sağlayacak 1290 nokta seçilmiştir [136]. Şekil 3.4'de fiber yönelimi ve konum bilgisinin alınmasında kullanılan düzenek verilmiştir. Burada alt kısım, veri alma aşamasının ayrıntılı gösterimini içerir ([135]'den alınmıştır).



Şekil 3.4 Ölçüm sisteminin şematik gösterimi.


Aliev-Panfilov modeli kullanılarak bu noktalardan ayrı ayrı benzetimler gerçekleştirilmiş ve toplam 3880 benzetim haritası elde edilmiştir. Bu haritalar benzetim veri ambarına atanmıştır.

Şekil 3.5 (a)'da uyarı verilen bölgenin görülmesini sağlayan apeksten görüş, (b)'de transvers bir kesit üzerinde benzetim sonucu, (c)'de frontal kesit üzerinde benzetim sonucu, (d)'de sagittal bir kesit üzerinde benzetim sonucu ve (e)'de renklere karşılık gelen aktivasyon zamanı sürelerini milisaniye cinsinden gösteren renk barı verilmiştir ([135]'den alınmıştır). Burada uyarı apeksten verilmişti. Bu harita üzerinde elektriksel aktivitenin apeksten ventrikülerin üst kısmına (baz) ulaşması yaklaşık olarak 100 milisaniye sürmüştür.



Şekil 3.5 Aliev-Panfilov modeli kullanılarak apekten uyarı verilmesi sonucu elde edilen benzetim sonucu.

Şekil 3.6 (a)'da benzetim sonucu elde edilen aktivasyon zamanı haritası, (b)'de deneyden elde edilen aktivasyon zamanı haritası verilmiştir ([135]'den alınmıştır). Burada apeks bölgesinden uyarım sonucu elde edilen deneysel ölçüm haritası ile aynı bölgeden uyarım verilmesi sonucu elde edilen benzetim haritasının görsel karşılaştırmasını sunmaktadır. Görüldüğü gibi deneysel harita ile benzetim haritasındaki yayılım birbirine oldukça benzemektedir.




Şekil 3.6 Elektriksel yayılımların karşılaştırılması.

Şekil 3.7 **Error! Reference source not found.**'de geometri veri ambarında yer alan 488 noktalık sağ endokart geometrisini, 562 noktalık sol endokart geometrisini ve 1540 noktalık epikart geometrisini göstermektedir. Burada Kırmızı noktalar kateterleri temsil etmektedir. Geometri veri ambarı bu geometrilere ek olarak 1290 noktalık miyokart geometrisi de içermektedir, fakat miyokart noktaları bir yüzey olarak ifade edilmediklerinden ağ yapıları oluşturulmamıştır. Bu nedenle miyokart noktaları burada gösterilmemektedir.

Benzetim geometrisi üzerinden seçilen bazı noktalar, sanal kateter elektrot noktalarına karşılık gelecek şekilde seçilmiştir. Seçilen noktalar şunlardır:

- Çok elektrotlu sepet kateter noktaları olarak sol ve sağ endokartta 64'er nokta (**Sol_Sepet** ve **Sağ_Sepet**)
- Venöz kateter noktaları olarak epikartta 91 noktadır.



Şekil 3.7 Geometri veri ambarında yer alan sağ endokart, sol endokart ve epikart geometrileri ağ yapıları.

3.3 Kümeleme Yaklaşımları

Uyarı noktalarının hedef vektörü olarak oluşturulmasında elle kümeleme için basit bir yaklaşım kullanıldı. İlk olarak üzerinde elektrotların yerini gösteren bir ventriküler geometri bilgisayar ekranına aktarıldı, daha sonra birbirine yakın elektrotlar birer grup olarak kümelendirildiler. Sonuç olarak deney setinde her birinde ortalama 15 elektrot olan 28 ayrı grup (bölge) yaratıldı. Bu yöntem deney verilerinde ve VYPH çalışmalarındaki kümeleme işlemlerinde kullanılırken, benzetim verisinde tercih edilmemiştir. Bu yöntem sadece muhtemel aritmi kaynaklarının kalp geometrisi üzerindeki yerlerinden yola çıkarak gruplamayı öngörmektedir.

Aritmi kaynaklarının yerlerinden ziyade kateterlerden alınan verileri temel alan (veriye dayanan) kümeleme yaklaşımları olan Kohonen SOM ve BCO bu çalışmanın hem deneysel verileri hem de benzetim verilerinin kullanıldığı bölümlerinde tercih edilmiştir. VYPH çalışmalarında bu yöntemler kullanılmamıştır.

Bu kümeleme yaklaşımlarında giriş kateter elektrotu sayısı kadar nörondan oluşmaktadır. Deneysel verilerde 42 kateter ve 470 aktivasyon haritası kullanılarak

epikart katmanı daha sonraki analizde kullanılmak üzere 28 farklı bölgeye ayrılır. Kohonen SOM'da 4X7'lik bir topografik yapı oluşturulurken ve BCO Kümelemede 3 adet gizli katmandan yararlanılmıştır. Üyelik fonksiyon matrisi (bu matrisin her sütununun en büyük değeri küme numarasını ifade etmektedir) için üstel değer 2.0, maksimum iterasyon sayısı 1000, en düşük ilerleme miktarı ise 10^{-5} olarak seçildi. Benzetim verisinde sağ ve sol endokartttaki sepet kateterlerin birinden gelen 64 ve venöz kateterlerden gelen 91 adet nokta giriş katında kullanılmıştır.

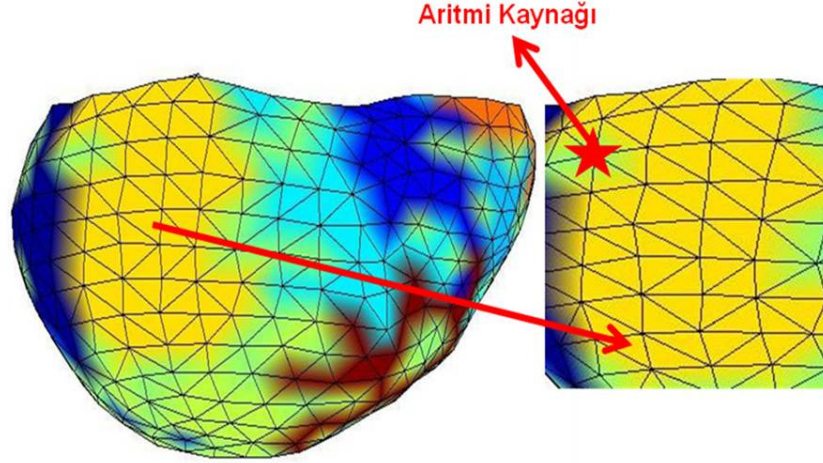
3.4 Kademeli Odaklanma

Bu tez çalışmasının amaçlarından bir tanesi kateter verisi ile eğitici veri setini olabildiğince aritmi kaynağına odaklamak, aritmi kaynağının tahmini bölgesini çok küçük bir alanda söyleyebilmektir. Bu amaç ile kalp katmanı üzerinde alt kümelemeye gidilmiş, her kümeleme aşamasında aritmi kaynağına daha da yaklaşılması sağlanmıştır.

Öncelikle kalbin herhangi bir yüzeyinden elde edilen bilgiler kullanılarak tüm yüzey üzerinde kümelemeye gidilmiştir. Kateterlere denk gelen noktalar eğitim aşamasında kullanılmıştır. Her kümenin merkezi bulunmuştur. Küme elemanlarının herbirinin merkeze olan uzaklıkları hesaplanmıştır. Bu uzaklıkların ortalaması ve standart sapması hesaplanmıştır. Her kümenin içinde "ortalama ± 2 *standart sapma" eşik değerinden uzakta olan küme elemanları bulunarak kümenin eleman listesinden çıkarılmıştır. Kümelerinden çıkarılan elemanların kümelerin merkezlerine olan uzaklıkları hesaplanmıştır. Bu uzaklıkların en küçük olduğu kümeye atamaları yapılmış ve yeni kümeler oluşturulmuştur. Bu algoritmaya "küme düzeltme" ismini verdik. Şekil 3.8'de epikart üzerinde düzeltilmiş genel kümeleme, aritmi kaynağı için atanan grup verilmiştir.

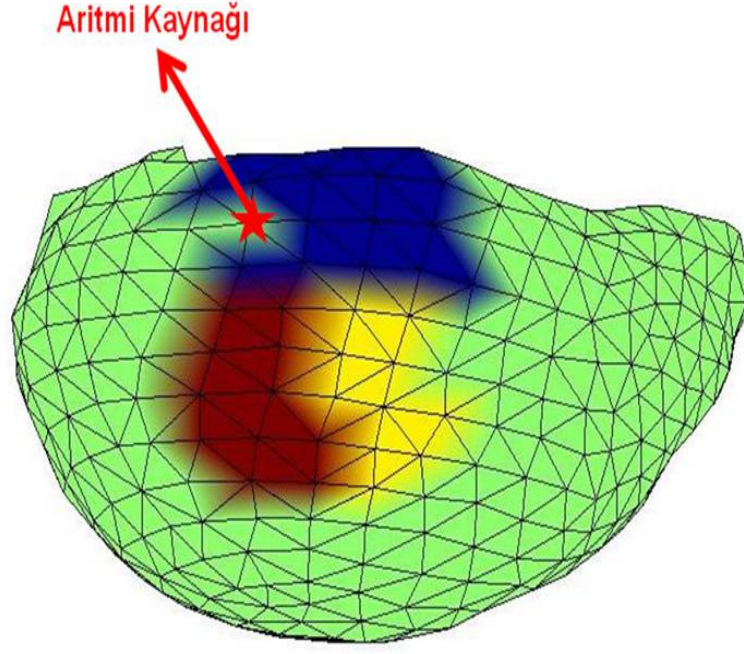
Benzetim verisi üzerinde yapılan yapay sinir ağı kümelerinde, bazı küme elemanlarının kümenin çok dışında oldukları ve başka kümelerin içinde atandıkları görülmüştür. Bu durum tüm kümelemelerde 8% dolayında görülmüştür ve kümeleme kalitesini, tahmin algoritmasının başarısını kısaca aritmi tahmin başarımını düşürdüğü fark edilmiştir. Bunu önlemek için kademeli odaklanmada her kümelemeden sonra küme düzeltme algoritması çalıştırılmıştır.

Yeniden düzeltilen kümelerin her biri için intra-kümeleme sayıları hesaplanmıştır. Daha sonra test setinden gelen test verisine bakılıp OSA yapısı ile aritmi kaynağının yeri (hangi küme içinde olduğu) tahmin edilmiştir. Atanan kümenin gerçek uyarım noktasına olan uzaklıkları (euclidean uzaklıkları) hesaplanmıştır.

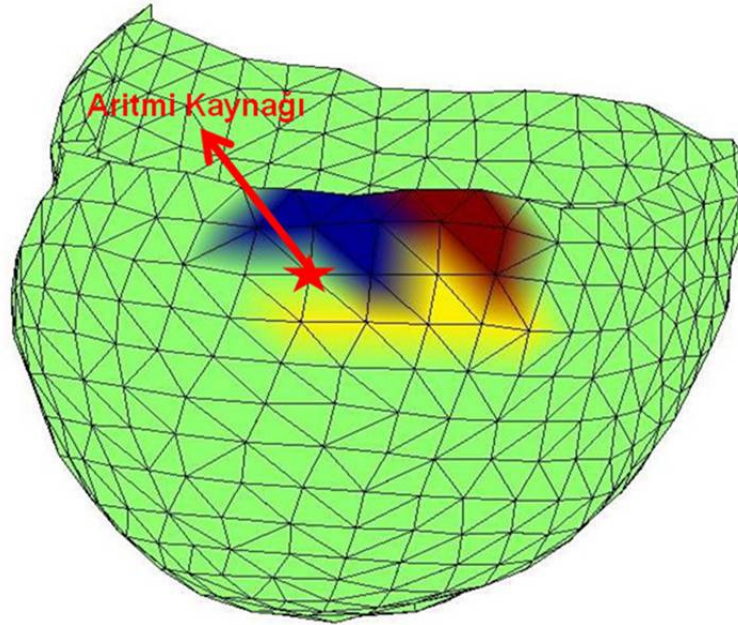


Şekil 3.8 Kademeli odaklanma genel kümeleme üzerinde atanan küme, birinci komşulukları ve aritmi Kaynağının gerçek yeri.

Atanılan küme ve birinci komşu kümeleri yeni bir kümeleme için bir listeye yazılmıştır. Bu listede bulunan uyarım noktalarının aktivasyon zamanları yeni bir eğitim ve test seti oluşturacak şekilde bir araya getirilmiştir. Bu eğitim seti kullanılarak sadece atanan bölge ve birinci komşulukların kapsadığı alanda yeniden kümelemeye gidilmiştir. Oluşturulan yeni kümeleme küme düzeltme algoritmasından geçirilmiş, Küme içi yayılma sayıları hesaplanmıştır. Test seti kullanılarak aritmi yerinin tekrar tahmini yapılmıştır. Atanan bölge ile gerçek uyarım noktasına olan uzaklığı hesaplanmıştır. Birinci alt kümelemede oluşturulan gruplar ve aritmi kaynağının yerinin tekrar atanın bölgesi Şekil 3.9'da gösterilmiştir. Kademeli odaklanma iki defa uygulanmıştır. İkinci alt kümelemeden sonra oluşan bölgeler ve tekrar aritmi kaynağı olarak atanın grup Şekil 3.10'da verilmiştir.



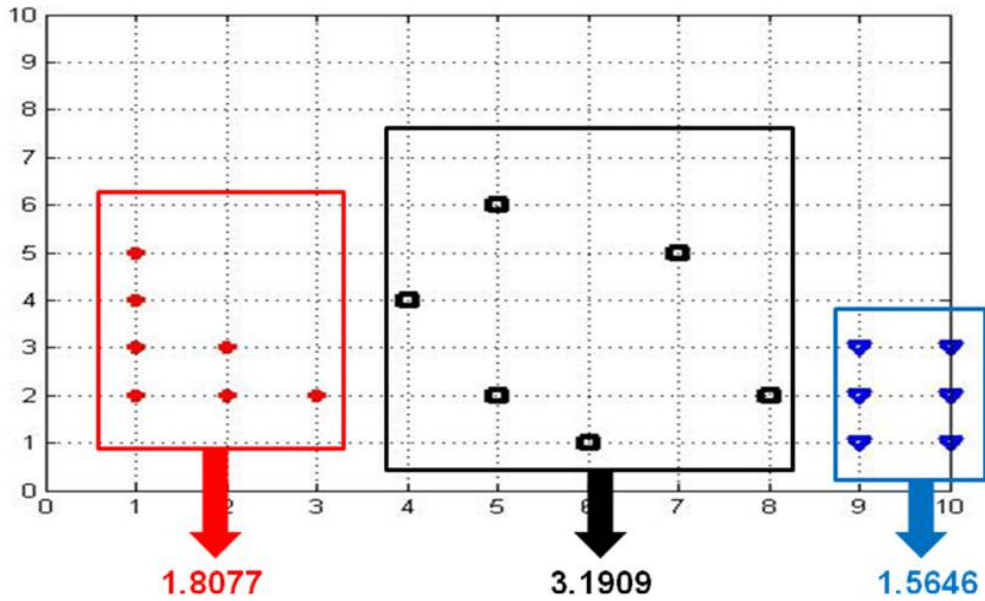
Şekil 3.9 Kademeli odaklanma birinci alt kümeleme ve aritmi kaynağının gerçek yeri.



Şekil 3.10 Kademeli odaklanma ikinci alt kümeleme ve aritmi kaynağının gerçek yeri.

3.5 Kümeleme Kalitesi

Çalışmanın bu bölümünde oluşturulan kümelerin kalitelerini hesaplamada kullanılan küme içi yayılma ve kümeler arası yayılma değerlerini hesaplayan algoritma için bir örnek gösterilmiştir. küme içi yayılma kavramı küme elemanlarının birbirinden ne kadar çok dağınık olarak bulunduğunu göstermektedir. Her bir elemanın diğer küme merkezi ile uzaklıkları hesaplanmış ve ortalamaları bulunmuştur. İnter-kümeleme kavramı ise kümelerin birbirinden ne kadar ayrıık olduğunu göstermesi açısından önemlidir. Biz bu çalışmada kümelerin dağınıklığının az olmasını istediğimiz için, küme içi yayılma değerlerini yukarıda bahsedilen odaklama işlemlerindeki küme düzeltme aşamasında dağınıklığın azalıp azalmadığını sayısal olarak görebilmek için hesapladık. Bir örnek üzerinde bu kavramları anlatabilmek için Şekil 3.11'de üç farklı kümenin iki boyutlu gösterimi ve kümelerin altlarında hesaplanan küme içi yayılma sayıları verilmiştir.



Şekil 3.11 Farklı dağılımlara sahip üç küme ve bunların küme içi yayılma sayıları.

Görüldüğü üzere mavi ile gösterilen küme en düşük küme içi yayılma sayısına sahip olduğundan en odaklı, elemanları birbirine en yakın kümedir. Buna karşılık siyah ile gösterilen küme tam tersi, en yüksek küme içi yayılma sayısına sahip olduğundan en dağınık gruplanmış kümedir.

3.6 Aritmi Kaynağının Tespitinde YSA ve Sınıflandırma Yöntemleri

Bu kısımda çalışma sırasında geliştirilen aritmi kaynağının yerini kateter tabanlı bulma yönteminin deneysel ve benzetim veri setlerine nasıl uygulandığı açıklanmıştır. Kümeleme ve sınıflandırma algoritmalarının hangi parametreler ile nasıl kullanıldıkları ifade edilmiştir.

3.6.1 Deneysel Veri

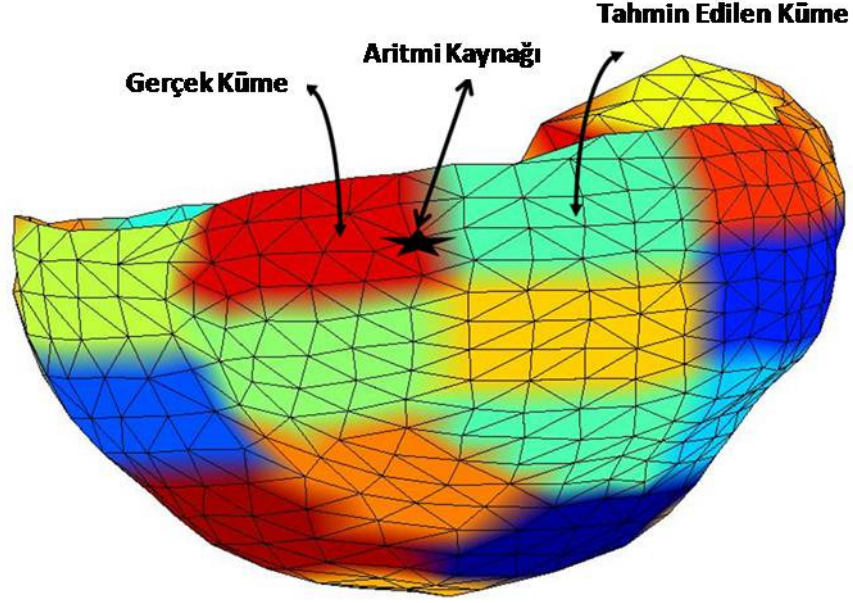
Eğitim ve test veri setleri rastgele (random) değişkenlerden oluştuğundan YSA girişine verilmeden önce sıfır ortalama ve bir varyansa çekilmiş, normalize edilmişlerdir. Elle kümeleme yönteminde ise, kümeleme için kullanılan özellik, uyarı elektrotlarının epikart üzerinde buldukları yerlerin x, y ve z koordinatlarıdır. Ayrıca oluşan bölgelerin küme içi yayılma sayıları hesaplanarak kümeleme kaliteleri hakkında bilgi edinilmiştir.

Kümeleme aşamasında elde edilen bölgeler sınıflandırma aşamasının hedef vektörlerini oluşturmaktadır. Girişi 42 nörondan oluşmaktadır. Beş farklı sınıflandırma yöntemi kullanılarak 50 aktivasyon haritasının herbirinin hangi hedef vektörüne daha yakın olduğu tahmini yapılmıştır. Burada iki doğru tahmin durumu vardır:

1. Tahmin edilen küme uyarı noktası için tam doğru bölgedir.
2. Tahmin edilen küme uyarı noktası için tam doğru bölge değildir ama birinci komşuluğundadır.

Bu iki durum, Şekil 3.12'de gösterilmiştir. Siyah yıldız, test haritasının gerçek uyarı noktasının epikart üzerindeki yerini gösterir, yıldızın sağ tarafındaki kırmızı bölge doğru küme, solundaki mavimsi yeşil bölge tahmin edilen kümedir.

Bu durum analizlerimizde sıkça rastlanan bir durumdur, çünkü birçok uyarı noktasında iki komşu kümenin ortasındaki alana denk gelmektedir.



Şekil 3.12 Aritmi kaynağının (uyarı noktası) iki komşu küme arasındaki sınırda olduğunda birinci komşuluk kümelerindeki kaynak yeri tahmininin şematik gösterimi.

Epikart üzerindeki aritmi tahmini uygulamasının bu aşamasında YSA'lardan oluşan tahmin ve eğitim algoritmalarının genetik algoritmalar kullanılarak optimizasyonu yapılmıştır. Bu optimizasyonlarda başarımların koşulu olarak tahmin edilen kümenin uyarı noktası için tam doğru bölge olması seçilmiştir. Bu başarımların koşulunun bir bölümü, genetik algoritmaların hedef fonksiyonu olarak verilmiştir. Genetik algoritma çalışma mantığı gereği bu hedef fonksiyonunu minimum olduğu noktayı (global minimum) araştırırken bize başarımların koşulunu maksimize eden YSA parametrelerinin değerlerini vermektedir.

OSA yapısında genetik algoritmalar kullanılarak yayılım fonksiyonu (spread function) değeri optimize edilmiştir. Kohonen SOM ve BCO yapılarında ise iterasyon sayısı (iteration number) değeri optimize edilmiştir. Elle Kümeleme yapısında genetik algoritma kullanılmamıştır.

Bu çalışmadaki bazı GYA parametreleri daha önceki çalışmalarda da kullanılmıştır [145]. Bu ağ yapısında, 42 giriş düğümü ve 28 çıkış düğümü, iki gizli katman ile birlikte kullanılmışlardır. Gizli katmanlarda 600 ve 500 adet düğüm bulunmaktadır.

Eđitim ařamasında 470 aktivasyon-zaman haritası giriř olarak kullanıldı, hedef vektörü olarak ise her uyarı noktası için karřılık gelen kümeye 5, karřılık gelmeyen diđer kümelere -5 sayısı atandı. Test ařamasında, 50 aktivasyon haritası ve 42 kateter ölçümü ađı beslemek için kullanıldı ve çıkıř vektörü karřılık gelen kümeyi bulmak üzere analiz edildi. Her test haritası için en yüksek deđere sahip satırlar tahmin edilen küme olarak iřaretlendi.

Diđer sınıflandırma yöntemlerin optimize edilmesi iřlemi deneme yanılma yöntemi ile yapılmıřtır. kNN sınıflandırmasında uzaklık ölçümü olarak ařađıda yöntemler denenmiřtir:

- Euclidean Uzaklıđı [Euclidean]
- Mutlak Farkların Toplamı [Cityblock]
- En yakın noktalar arasındaki açının kosinüs deđeri [Cosine]
- En yakın noktalar arasındaki korelasyon deđeri [Correlation]

Örnekleri sınıflandırma yapmak için ise ařađıdaki kurallar denenmiřtir:

- En yakın nokta kuralı [Nearest]
- Rastsal nokta seđimi kuralı [Random]
- Konsensus nokta seđim kuralı [Consensus]

Diskriminant Analiz uygulamasında diskriminant fonksiyonu olarak ařađıda yöntemler denenmiřtir:

- Her gruba azaltılmıř kovaryans tahminine sahip çokdeđiřkenli bir normal yoğunluk fonksiyonu uydurur [linear].
- Her gruba köřegen (diagonal) kovaryans tahminine sahip çokdeđiřkenli bir normal yoğunluk fonksiyonu uydurur [diaglinear].
- Grup kovaryanslarının eřdeđer olmadığını varsayarak sınıflandırma uygulanması yapar [quadratic].

- Grup kovaryanslarının eşdeğer olmadığını ve köşegen olduklarını varsayarak sınıflandırma uygulanması yapar [diagquadratic].
- Kovaryans tahminleri için Mahalanobis uzaklığını kullanır [Mahalanobis].

3.6.2 Benzetim Verisi

Aliev-Panfilov modeli kullanılarak elde edilen aktivasyon zamanı haritaları tek bir settir. Şekil 3.1 **Error! Reference source not found.**'de gösterildiği gibi benzetim verisi öncelikle çapraz sağlama kullanılarak eğitim ve test veri seti olarak ikiye ayrılmıştır. Eğitim verisi tüm veri setinin %90'ı kadardır ve çapraz sağlama 10. dereceden uygulanmıştır. Yani benzetim setinden 10 farklı eğitim seti oluşturularak fokal aritmi tespiti yapılmış, elde edilen sonuçların ortalaması alınmıştır.

İlk olarak aritmi kaynağının Sol Epikart, Sağ Epikart, Miyokart ve Endokart katmanlarından hangisinde olduğu sınıflandırma algoritmaları ile tahmin edilmiştir. Burada OSA algoritmasının bir YSA uygulaması olduğunu diğer yöntemlerin ise sınıflandırma yöntemleri arasında bulduklarını hatırlatmak isteriz. OSA'nın Genetik Algoritmalar ile optimizasyonu yapılmış, tekrar sayısı 350 ve yayılım değeri 0.95 olarak atanmıştır. kNN ile katman ayırma uygulamasında yukarıda bahsedilen uzaklık ölçümü ve kurallar denenmiştir. Diskriminant Analizi yöntemlerinde de yukarıda bahsi geçen fonksiyonlar denenmiştir. Bu iki yöntem hem katman ayırmada hem daha sonra bahsedilecek olan aritmi kaynağı tespitinde kullanılmıştır.

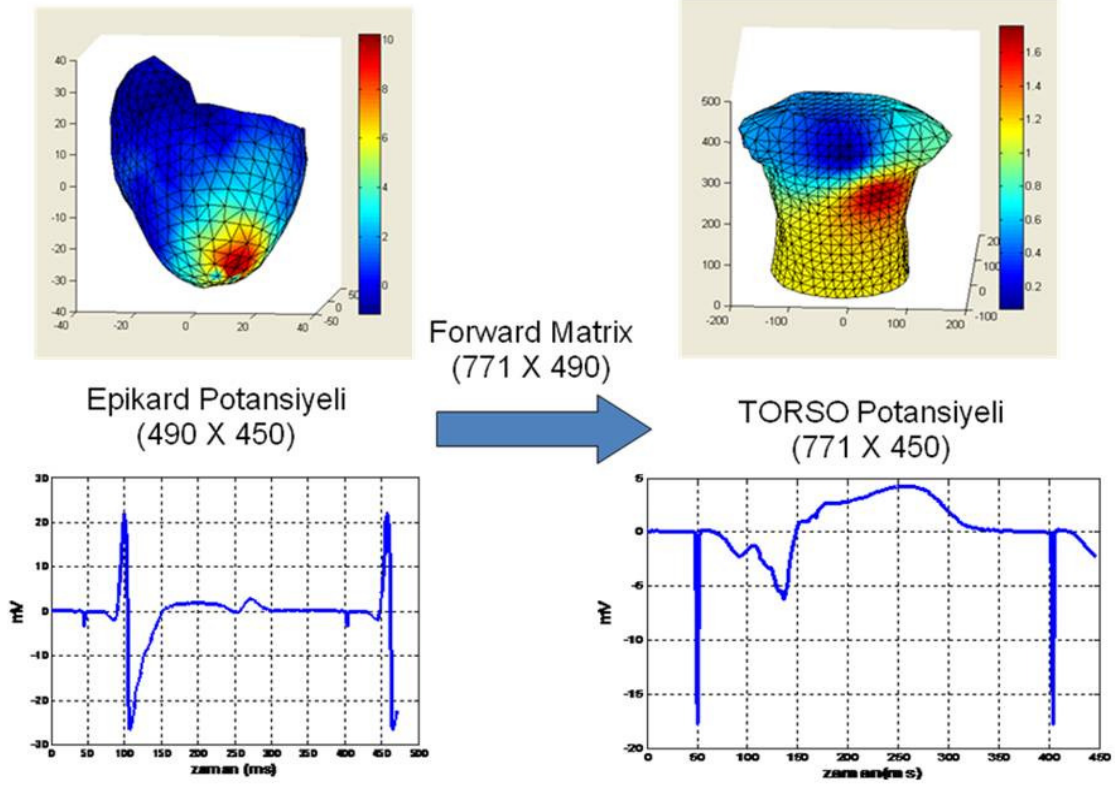
Destek Vektör Makineleri ise sadece katman ayırma uygulamasında kullanılmıştır. DVM için eğitim verisini kernel uzayına haritalandıran fonksiyonlardan aşağıdakiler incelenmiştir:

- Lineer Kernel veya Nokta Çarpımı [linear].
- Quadratik Kernel [quadratic].
- Gaussian Radyal Temelli Fonksiyonu [rbf].
- 3. Dereceden Polinomial Kernel [polynomial].
- Çokkatmanlı Perseptron [mlp].

Katman ayırmadan sonra kümeleme algoritmaları çalıştırılarak aritminin bulunduğu katman 20 adet bölgeye ayrılmıştır. Bu hedef bölgeler kullanılarak, sınıflandırma yöntemleri ile aritminin yerinin hangi kümede olduğu tahmin edilmiştir. Kademeli odaklanma iki defa uygulanmış ve tahmin edilen bölgenin yüzeyi olabildiğince küçültülmüştür. Birinci alt kümelemede 12, ikinci alt kümelemede 10 farklı bölge oluşturulmuştur. Kademeli odaklanmanın her aşamasında eğitimsiz algoritmaların oluşturdukları kümelerin küme içi yayılma sayıları hesaplanmış, kümeleme kaliteleri kontrol edilmiştir. Genetik algoritma ile YSA'ların parametreleri optimize edilmiştir. SOM ağında [4X5] yapısı oluşturulmuş, iterasyon sayısı 4575 olarak atanmıştır. Bulanık Kümelemede iterasyon sayısı 350 olarak bulunmuştur. OSA'nın yayılım fonksiyonu değeri ve iterasyon sayısı her katman için ayrı ayrı optimize edilmiştir.


3.6.3 VYPH Verisi

Çalışmanın bu kısmında vücut yüzeyinden alınan potansiyel verileri kullanarak aritmi kaynağının yerinin tespitinde yapay sinir ağlarının kullanımı ve performansı incelenmiştir. İlk olarak epikart üzerinden alınan potansiyel verilerinden, ileri matris kullanılarak torso potansiyellerine ulaşılmıştır. Torso potansiyelleri elde edildikten sonra yapay sinir ağları yapıları oluşturularak aritmi kaynağının yeri tahmin eilmeye çalışılmıştır. Deneysel verilerin açıklanması esnasında bahsedilen 13 adet deneyin birisinden elde edilen epikartın 72 farklı noktasından uyarılarak elde edilmiş potansiyel verileri daha önce hesaplanmış olan ileri matris ile çarpılarak vücut yüzeyi potansiyel haritaları oluşturulmuştur. Bu aşamada karşımıza çıkan sorun VYPH verilerinin çok büyük boyutta (72 X 771 X 450) olmasıdır. Bu veri 72 adet atım var ve her bir atımda 450 adet potansiyel bilgisi var. Bu boyutta bir veri setinin yapay sinir ağı eğitim ve test aşamasında kullanılması uygun değildir. Bu sorunu çözmek için özellik çıkarımı ve seçimi yöntemlerine başvurulmuş, zamanda özellik seçimi için QRS ve QRST integralleri, uzaysal özellik seçimi için Karhunen–Loeve Dönüşümü kullanılmıştır.



Şekil 3.13 Epikard potansiyelinden torso potansiyeline geçiş işlemi.


Bu çalışmada kullanılan özellik çıkarımı ve seçimi yöntemleri Şekil 3.14'de gösterilmiştir.




Şekil 3.14 Kullanılan özellik çıkarım yöntemleri.

Zamanda azaltım yöntemi olarak QRS ve QRST integralleri, uzaysal azaltım için ise Karhunen–Loeve dönüşümü kullanılmıştır.

QRS ve QRST integrallerini elde etmek için öncelikle Şekil 3.15’de verilen torso potansiyellerinin tüm elektrotlar üzerinden ortalamaları ve integralleri hesaplanarak RMS (Root Mean Square) eğrileri elde edilmiştir.




Şekil 3.15 Torso potansiyeli.



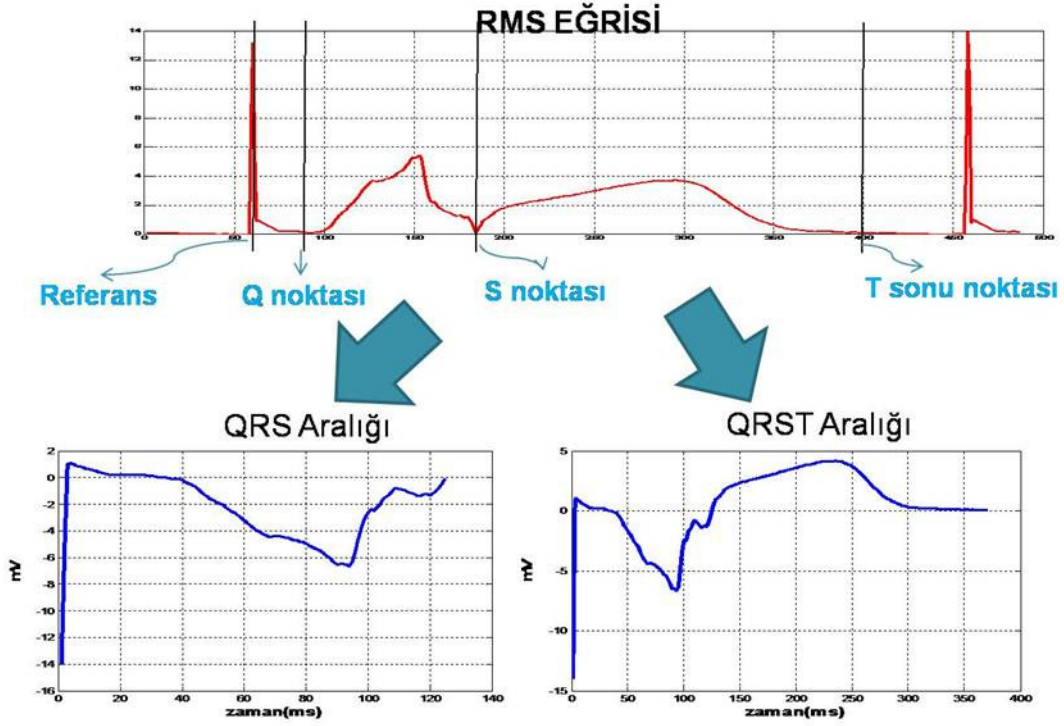
Şekil 3.16 RMS eğrisi.

Daha sonra bu RMS eğrileri üzerinde mutlak değerleri alınarak, “Referans”, “Q Noktası”, “S noktası” ve “T sonu” işaretlemesi yapılmıştır.



Şekil 3.17 RMS eğrisi üzerinde yapılan işaretlemeler.

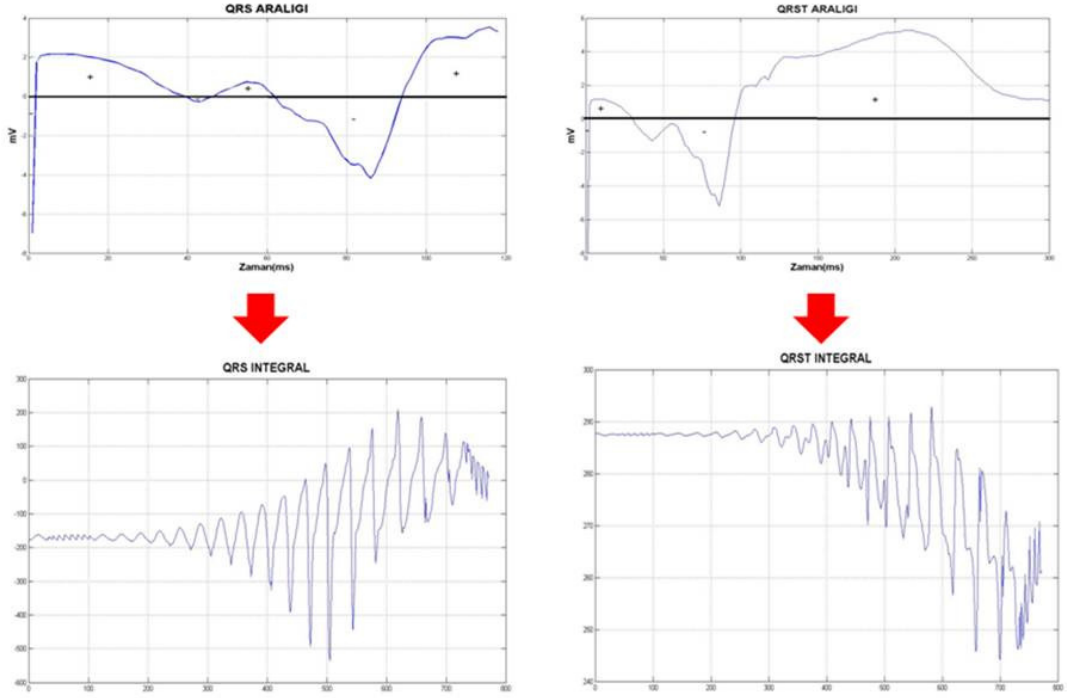
Bu noktalar kullanılarak QRS ve QRST aralıkları elde edilmiştir.



30


Şekil 3.18 QRS ve QRST aralıklarının çıkarımı.

Bu aralıkların her bir anının bütün haritalardaki toplamalarına bakılarak QRS ve QRST integralleri elde edilmiştir. Bu integraller bir kalp atımı için sadece bir vücut yüzeyi haritası kullanılmasını sağlamıştır.



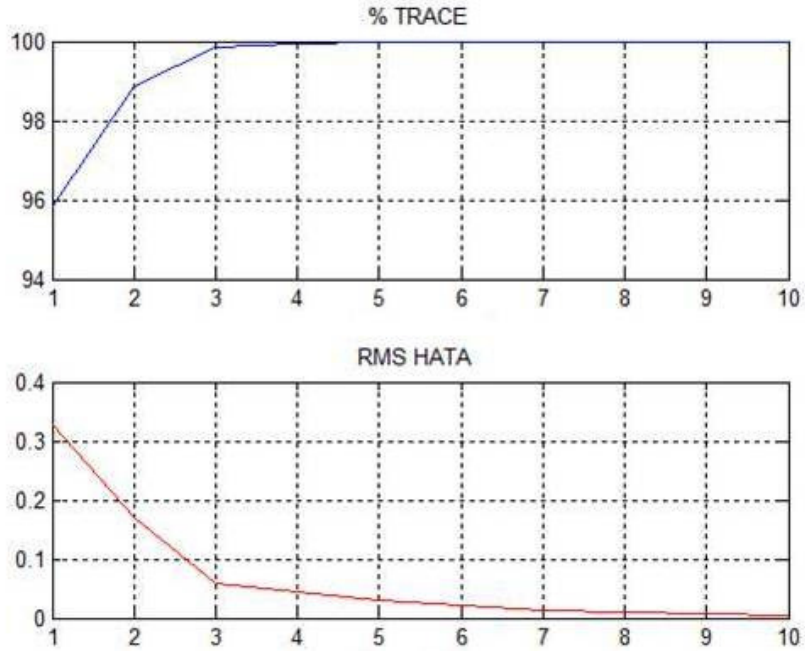
Şekil 3.19 QRS ve QRST integrallerinin çıkarımı

Torso potansiyeleri veri setinden elde edilen Karhunen–Loeve özdeğerleri Şekil 3.20’de görülmektedir. Yatay eksen KLD özdeğerinin numarasını, dikey eksen ise özdeğerin ağırlığını ifade etmektedir. İlk özdeğerin büyüklüğünün çok yüksek olduğu gözlenmiştir.




Şekil 3.20 İlk on adet Karhunen–Loeve özdeğerleri.

VYPH veri setinde %Trace ve RMS hata verisi Şekil 3.21’de verilmiştir.



Şekil 3.21 İlk on özdeğer vektörlerine karşılık gelen RMS hataları ve %Trace değerleri.


%Trace deęerlerine bakılarak ilk 10 adet Karhunen–Loeve dđnüşümü özvektörünün bütün torso verisinin yaklaşık %100'ünü ifade edebildięi görülmüştür. Analizin bundan sonraki kısmında sadece bu 10 özdeęer vektörü kullanılmıştır. Bu sayede veri boyutunun büyüklüğünden dolayı oluşan sorun ortadan kaldırılmıştır. Torso verisinde en büyük özdeęer vektörüne karşılık gelen vücut yüzeyi potansiyel haritası Şekil 3.22'de gösterilmiştir. Burada koyu kırmızı kısım pozitif potansiyel deęerini, koyu mavi kısım ise negatif potansiyel deęerini ifade eder.



Şekil 3.22 İlk on özdeęer vektörüne karşılık gelen VYP haritası.


Daha sonra seçilen özdeęer vektörleri kullanılarak epikart üzerinde bölgelemeye gidilmiştir. Karhunen–Loeve Dđnüşümü üzerinden yapılan SOM kümelemesi 5000 epok ve 10 bölge üzerinden gerçekleştirilmiştir.

72 adet kalp atımının (deney) uyarı noktaları (pacing site) görsel olarak 12 tane kümeye ayrılmıştır. Şekil 3.23'de 72 adet uyarım noktasının epikart üzerindeki dağılımları verilmiştir.



Şekil 3.23 Epikart üzerindeki test noktaları.


72 adet uyarım noktasından oluşan veri seti 60 eğitim seti ve 12 test seti olacak şekilde ikiye ayrılmıştır. Şekil 3.24'de 12 test noktasının elle kümelenmiş hali epikart üzerinde verilmiştir.




Şekil 3.24 Eğitim setindeki uyarım noktalarının elle kümelenmesi.

Kalpde oluşan potansiyeller vücut içinden torsoya doğru ilerlerken çeşitli sönümlenmelere ve gürültülere maruz kalırlar. Çalışmanın şimdiki bölümünde bu gürültülerin YSA performansı üzerindeki etkilerinin incelenmesi amaçlanmıştır. Torso potansiyelleri üzerinde 10 dB gürültü eklenmiş hali Şekil 3.25'de verilmiştir.


QRS integrali ve gürültü eklenmiş hali Şekil 3.26'de verilmiştir. QRST integrali ve gürültü eklenmiş hali Şekil 3.27'de verilmiştir.



Şekil 3.25 10dB gürültü eklenmiş örnek bir torso potansiyeli.



Şekil 3.26 Orjinal ve 10dB gürültü eklenmiş QRS integralleri VYP haritaları.



Şekil 3.27 Orjinal ve 10dB gürültü eklenmiş QRST integralleri VYP haritaları.


Özellik seçiminde sonra elde edilen özellik vektörü eğitim ve test seti olarak ikiye ayrılmış; eğitim seti kümeleme algoritmalarının, test seti ise OSA'nın giriş vektörü olarak atanmıştır.

4. SONUÇLAR

Bu bölümde ventriküler fokal aritmi yerinin tespiti için bu çalışmada geliştirilen yeni yaklaşımın, değişik veri setlerine uygulanması sonucu elde edilen sonuçlar verilmiştir. İlk aşamada deneysel veri seti kullanılarak elde edilen sonuçlar açıklanmıştır. Daha sonra benzetim veri setindeki başarımların sonuçları verilmiştir. En son olarak da VYP haritalarından çıkartılan özellik veri seti üzerinde geliştirdiğimiz algoritmanın sonuçları gösterilmiştir.

4.1 Deneysel Veri Üzerindeki Uygulamalar


İlk olarak, kurulan YSA algoritmalarının parametreleri genetik algoritmalar ile optimize edilmiştir. Elle kümeleme ve OSA optimizasyonu için genetik algoritmanın çalıştırılması sonucu yayılım fonksiyonu değerine karşı (1/Başarımlar Yüzdesi) değeri Şekil 4.1 **Error! Reference source not found.**'de gösterilmiştir. Genetik algoritma tarafından yayılım değerinin optimumu 0,6125 olarak verilmektedir.



Şekil 4.1 Deneysel veri üzerinde elle kümeleme ve OSA optimizasyonu.

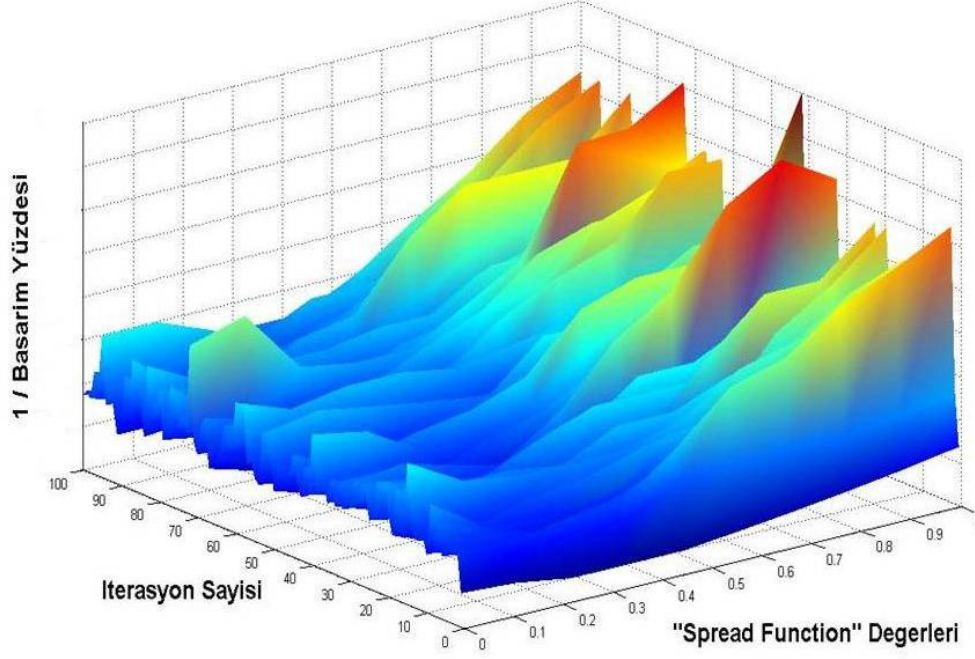
BCO ve OSA optimizasyonu için genetik algoritmanın çalıştırılması sonucu yayılım fonksiyonu ve iterasyon sayısının 1/Başarımlar Yüzdesi değerine karşı değişimi Şekil

4.2'de gösterilmiştir. Genetik algoritma tarafından yayılım değerinin optimumu 0,2566 ve iterasyon sayısı 83 olarak verilmektedir. Bu grafik üç boyutlu bir grafikdir.



Şekil 4.2 Deneysel veri üzerinde BCO ve OSA optimizasyonu.

Kohonen SOM ve OSA optimizasyonu için genetik algoritmanın çalıştırılması sonucu yayılım fonksiyonu ve iterasyon sayısının (1/Başarım Yüzdesi) değerine karşı değişimi Şekil 4.3'de gösterilmiştir. Genetik algoritma tarafından yayılım değerinin optimumu 0,3157 ve iterasyon sayısı 45 olarak verilmiştir. Bu grafik üç boyutludur.



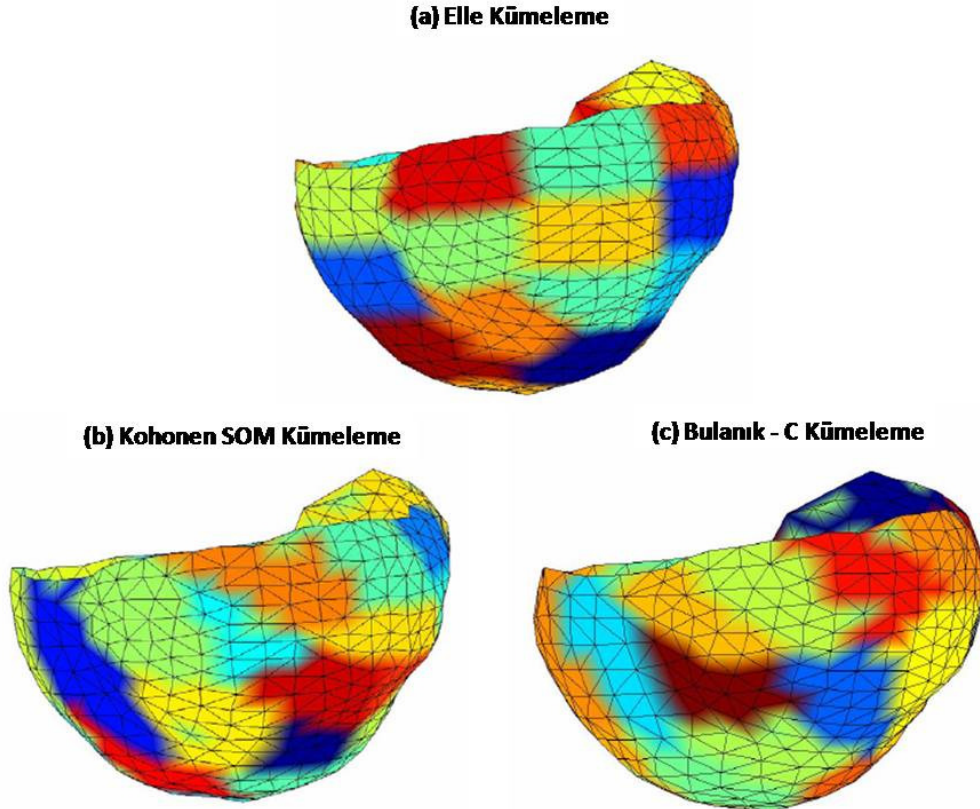
Şekil 4.3 Deneysel veri üzerinde Kohonen SOM ve OSA optimizasyonu.

Sınıflandırma algoritmalarının parameterelerinin bulunmasında ise deneme yanılma yöntemi kullanılmıştır. kNN sınıflandırması 42 elektrotlu kateter verisi için denenmiştir. Uzaklık ölçümü olarak euclidean uzaklığının, sınıflandırma yöntemi rastsal nokta seçimi ile birlikte kullanıldığında en iyi başarıyı verdikleri gözlenmiştir. Diskriminant analiz algoritmasının kuadratik diskriminant fonksiyonu ile optimum başarıyı yakaladığı gözlenmiştir.


Algoritmaların optimize edilmesinden sonra, çalışmanın bu kısmında, deneysel veri üzerinde kümeleme yaklaşımlardan yararlanarak, sonraki analizlerde kullanılmak üzere, epikart üzerinde uyarım noktalarının genel kümelemede gruplandırılması (28 bölge seçimi) yapıldı. Şekil 4.4 (a)'da elle kümeleme, (b)'de Kohonen SOM kümeleme ve (c)'de BCO kümeleme yaklaşımları kullanılarak elde edilen genel kümelerin üç boyutlu ve renkli olarak gösterimi verilmiştir. Her küme veya bölge epikardiyal geometride özel bir renk ile ifade edilmiştir. Her üç kümeleme algoritması da sonuçta genel kümelemede 28 bölge üretmiştir. Elektrot yeri tabanlı elle seçim yöntemi anatomik olarak daha düzenli bölgeler oluşturmuştur. Bölgeler karelere benzemektedir. Diğer taraftan, farklı noktalardan uyarım yapıldıktan sonra elde edilen aktivasyon zamanı değerleri temel alınarak yapılan Kohonen SOM ve BCO kümelemede, kümeler düzensiz şekiller olarak

görülmektedir çünkü bu uygulamalar eğitimsiz, sadece veri tabanlı uygulamalardır. Kademeli odaklanma bu veri setinde kullanılmamıştır ama eğitimsiz kümeleme yöntemleri için küme düzeltme algoritması çalıştırılarak kümeler daha odaksal bir hale getirilmiştir. Şekil 4.5'de genel kümelemedeki küme içi yayılma sayıları gösterilmiştir. Kohonen SOM ve BCO kümelemesinde, küme düzeltmesinin, küme içi yayılma sayılarını ortalama %15 oranında düşürdüğü belirlenmiştir.

Çizelge 4.1'de değişik kümeler için uyarı noktalarının doğru kümelere gönderebilmeleri açısından değişik kümeleme ve sınıflandırma yöntemlerinin performans karşılaştırmaları verilmiştir. Burada ilk yüzde değerleri doğru tahminlerin yüzdesini, parantez içerisindeki değerler birinci yakınlıkta komşu kümeler için yapılan tahminlerin oranını ifade eder. Görüleceği üzere en yüksek başarı oranı, BCO kümeleme ile OSA'nın birarada kullanılması ile elde edilmiştir.



Şekil 4.4 Kümeleme sonuçları.



Şekil 4.5 Kümeleme yöntemlerinin küme içi yayılma sayıları ve karşılaştırmaları.

Çizelge 4.1 Aritmi yerini tespitinde kümeleme ve sınıflandırma yöntemlerinin başarımlarını karşılaştırmaları.

| | | KÜMELEME | | |
|---------------|-----|-------------|--------------|-------------|
| | | ELLE | SOM | BCO |
| SINIFLANDIRMA | OSA | %62 + (%32) | %70 + (%20) | %72 + (%22) |
| | GYA | %50 + (%38) | %46 + (%26) | %54 + (%30) |
| | DA | %58 + %30 | %56 + (%20) | %66 + (%22) |
| | KNN | %56 + %32 | % 54 + (%24) | %66 + (%20) |

Çizelge 4.3'de ve Çizelge 4.4'de OSA ile Kohonen SOM ve OSA ile BCO için karıştırma (confusion) matrisleri verilmiştir. Epikardiyal yüzeydeki noktalar 28 farklı bölgeye ayrılmışlardır. Kümeleme sonucu bu 28 bölgeden biri olmaktadır. Matrisin köşegenleri doğru yapılan kümelemenin sayısını, aynı satırdaki diğer sütundaki numaralar ise yanlış kümeleme sayılarını ifade eder. Her bölge için doğru tahmin yüzdeleri son sütunda verilmiştir.

Çalışmanın bu kısımda deneysel veriler üzerinde elde edilen 42 elektrot kateter seti bilgileri kullanılarak; epikart üzerinde bulunan diğer elektrot setinin aktivasyon zamanı değerleri tahmin edilmeye çalışılmıştır. Yapay Sinir Ağlarının eğitiminden

sonra, test algoritması alıřtırılmıř yapay sinir ađlarının sonuları ile bilinen sonular karřılařtırılmıřtır. Bu karřılařtırmanın sonucu izelge 4.2'de verilmiřtir.

izelge 4.2 Tahmin algoritması sonuları.

| | |
|--|--------|
| Ortalama Korelasyon Katsayısı | 0,912 |
| Standart Sapma | 0,071 |
| Ortalama RMS Hatası | 11,596 |
| Standart Sapma (RMS iin) | 2,637 |
| Dođru Hesaplanan Nokta Yüzdesi (0 mm) | %5 |
| Dođru Hesaplanan Nokta Yüzdesi (4,3 mm) | %70 |
| Dođru Hesaplanan Nokta Yüzdesi (12,9 mm) | %10 |

Çizelge 4.3 Kohonen SOM kümeleme ile OSA kullanılarak elde edilen karıştırma (confusion) matrisi. Satırlar gerçek bölge numaralarını ve sütunlarda tahmini bölge numaralarını göstermektedir. Toplam Doğruluk: 70,3% N/A: Kullanım Dışı (bu bölgelerde test haritaları yoktur).

| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 17 | 18 | 19 | 20 | 21 | 22 | 23 | 24 | 25 | 26 | 27 | 28 | Doğruluk |
|----|---|---|---|---|---|---|---|---|---|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----------|
| 1 | 3 | 0 | 3 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 42,8 |
| 2 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |
| 3 | 0 | 0 | 4 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |
| 4 | 1 | 0 | 0 | 3 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 75 |
| 5 | 0 | 0 | 0 | 0 | 4 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |
| 6 | 0 | 0 | 0 | 0 | 1 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 66 |
| 7 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |
| 8 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 75 |
| 9 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |
| 10 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | N/A |
| 11 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |
| 12 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |
| 13 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 50 |
| 14 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | N/A |
| 15 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 16 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 3 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 75 |
| 17 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 67 |
| 18 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | N/A |
| 19 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 20 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 50 |
| 21 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |
| 22 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | N/A |
| 23 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 0 | 0 | 0 | 0 | 0 | N/A |
| 24 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 3 | 0 | 0 | 0 | 0 | 100 |
| 25 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 0 | 0 | 0 | 100 |
| 26 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 100 |
| 27 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 50 |
| 28 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 100 |

Çizelge 4.4 Bulanık C Tane Ortalama kümeleme ile OSA kullanılarak elde edilen karıştırma matrisi. Satırlar gerçek bölge numaralarını ve sütunlarda tahmini bölge numaralarını göstermektedir. Toplam Doğruluk: 71,8% N/A: Kullanım Dışı (bu bölgelerde test haritaları yoktur).

| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 17 | 18 | 19 | 20 | 21 | 22 | 23 | 24 | 25 | 26 | 27 | 28 | Doğruluk |
|----|---|---|---|---|---|---|---|---|---|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----------|
| 1 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 50 |
| 2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | N/A |
| 3 | 0 | 0 | 3 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 75 |
| 4 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | N/A |
| 5 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |
| 6 | 0 | 0 | 0 | 0 | 0 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |
| 7 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 67 |
| 8 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 3 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |
| 9 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 3 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |
| 10 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 66 |
| 11 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |
| 12 | 0 | 0 | 0 | 0 | 5 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 13 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 0 | 0 |
| 14 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 3 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |
| 15 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |
| 16 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 17 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |
| 18 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 66 |
| 19 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |
| 20 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |
| 21 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 1 | 0 | 0 | 0 | 0 | 50 |
| 22 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 50 |
| 23 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 100 |
| 24 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | N/A |
| 25 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | N/A |
| 26 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | N/A |
| 27 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 0 | 100 |
| 28 | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 2 | 66 |

VYP haritalamasında, QRS ve QRST integralleri kullanılarak yapılan öğreticisiz yapay sinir ağıları kümelemeleri başarısız sonuçlar vermişlerdir. Bunun üzerine veri temelli kümelemeler yerine elle kümeleme kullanılmıştır. GYA ve OSA, elle kümelemenin test aşamasında kullanıldılar. QRS integralleri için veri tabanlı kümeleme algoritmaları bu özellik setinde çok az başarı sağlamıştır. GYA'nın başarı oranı 46% civarındadır. OSA'nın başarı oranı ise 75% civarındadır. QRST integralleri için de veri tabanlı kümeleme algoritmaları bu özellik setinde de çok az başarı sağlamıştır. GYA'nın başarı oranı 9% civarındadır. OSA'nın ise başarı oranı 33% civarındadır. Gürültü eklenmesi QRS ve QRST integralleri üzerinden yapılan özellik seçimi işlemlerinde YSA performansını değiştirmemiştir.

Karhunen-Loeve dönüşümünde yine GYA ve OSA, elle kümelemenin test aşamasında kullanıldılar. GYA'nın başarı oranı 60% civarındadır. OSA'nın başarı yüzdesi ise 80% civarındadır. Öte yandan 10 dB gürültü eklenmesi; KLD üzerinden yapılan özellik seçimi işlemlerinde YSA performansını 4% kadar azaltmıştır. 20 dB ve 25dB gürültü eklenmesi; KLD üzerinden yapılan özellik seçimi işlemlerinde YSA performansını 5% kadar azaltmıştır.

4.2 Benzetim Verisi Üzerindeki Uygulamalar

Öncelikle benzetim verisi kullanılarak aritminin yerinin kalbin dört katmanından hangisine ait olduğunun bulunmuştur. Kalp üzerindeki bu katmanlar şunlardır:

- Sol Endokart (LE)
- Sağ Endokart (RE)
- Miyokart (Miyo)
- Epikart (Epi)

Aritmi kaynağının bu katmanlardan hangisine ait olduğunun hesaplanmasında Şekil 3.1'de verilen yöntemler kullanılmış ve başarımları karşılaştırılmıştır. Öncelikle kümeleme ve sınıflandırma algoritmalarını parametreleri optimize edilerek başarımları en üst düzeye çıkarılmıştır.

kNN algoritması 64 elektrotlu endokart kateter ve 91 elektrotlu venöz kateter verisi için denenmiş ve Çizelge 4.5’de görüldüğü gibi en düşük hata oranına sahip olduğundan uzaklık yöntemi olarak ‘cosine’ ve sınıflandırma yöntemi olarak ‘random’ seçilmiştir.

Çizelge 4.5 kNN ile katman ayırmada farklı uzaklık ve sınıflandırma yöntemleri ile elde edilen hata yüzdeleri.

| kNN İLE KATMAN AYIRMA | | | |
|------------------------------|------------------------------|-------------------------|-------------------------|
| | Sınıflandırma Yöntemi | | |
| Uzaklık Yöntemi | ‘Nearest’ | ‘Random’ | ‘Consensus’ |
| ‘Euclidean’ | %3,9146 (Sol Endokart) | %3,8274 (Sol Endokart) | %4,0932 (Sol Endokart) |
| | %20,4918 (Sağ Endokart) | %20,3116 (Sağ Endokart) | %20,7573 (Sağ Endokart) |
| | %5,0649 (Epikart) | %5,0052 (Epikart) | %5,2347 (Epikart) |
| | %7,7220 (TOPLAM) | %7,6567 (TOPLAM) | %7,9054 (TOPLAM) |
| ‘Cityblock’ | %4,2705 (Sol Endokart) | %4,1590 (Sol Endokart) | %4,3146 (Sol Endokart) |
| | %22,9508 (Sağ Endokart) | %22,8902 (Sağ Endokart) | %22,9998 (Sağ Endokart) |
| | %6,2338 (Epikart) | %6,1256 (Epikart) | %6,3450 (Epikart) |
| | %8,9575 (TOPLAM) | %8,8870 (TOPLAM) | %9,0451 (TOPLAM) |
| ‘Cosine’ | %3,5587 (Sol Endokart) | %3,4753 (Sol Endokart) | %3,6012 (Sol Endokart) |
| | %16,3934 (Sağ Endokart) | %16,2768 (Sağ Endokart) | %16,4125 (Sağ Endokart) |
| | %2,4675 (Epikart) | %2,3421 (Epikart) | %2,5585 (Epikart) |
| | %5,3282 (TOPLAM) | %5,2356 (TOPLAM) | %5,4891 (TOPLAM) |
| ‘Correlation’ | %8,1851 (Sol Endokart) | %8,1017 (Sol Endokart) | %8,2534 (Sol Endokart) |
| | %14,7541 (Sağ Endokart) | %14,6783 (Sağ Endokart) | %14,8678 (Sağ Endokart) |
| | %2,7273 (Epikart) | %2,6174 (Epikart) | %2,8128 (Epikart) |
| | %6,1776 (TOPLAM) | %6,0355 (TOPLAM) | %6,2995 (TOPLAM) |

Diskriminat analiz yöntemi 64 elektrotlu endokart kateter ve 91 elektrotlu venöz kateter verisi için denenmiş ve Çizelge 4.6'da görüldüğü gibi en düşük hata oranına sahip olduğundan diskriminant yöntemi olarak 'Quadratic' seçilmiştir.

Çizelge 4.6 DA ile katman ayırmada farklı diskriminant yöntemleri ile elde edilen hata yüzdeleri.

| DİSKRİMİNANT ANALİZ İLE KATMAN AYIRMA | | | | |
|--|---------------------|---------------------|----------------|---------------|
| | Katman | | | |
| Diskriminant Yöntemi | Sol Endokart | Sağ Endokart | Epikart | TOPLAM |
| 'Linear' | %10,3203 | %9,8361 | %6,2338 | %7,7992 |
| 'DiagLinear' | %4,9822 | %19,2623 | %59,4805 | %40,0772 |
| 'Quadratic' | %1,0676 | %2,0492 | %2,0779 | %1,8533 |
| 'DiagQuadratic' | %6,4057 | %5,3279 | %57,7922 | %36,7568 |
| 'Mahalanobis' | %0 | %9,4262 | %1,5584 | %2,7027 |

DVM'de yapılan denemeler sonucu hem hata yüzdelerinin en az olması hemde hesaplama zamanı açısından 'rbf' fonksiyonun optimum olduğu bulunmuştur. RBF sigma değeri ise her eğitim setine özel olarak deneme yanılma yöntemi ile hesaplanmıştır. Sol ve sağ basket kateter eğitim seti için 1,6, epikart venöz kateter seti için 2,6 alınmıştır. OSA algoritması ise GA kullanılarak optimize edilmiştir. OSA ile katman ayırma uygulamasının GA ile yapılan optimizasyon işleminde yayılma fonksiyonu değeri 0,78 olarak belirlenmiştir.

“%50 eğitim - %50 test” ve “%5 eğitim - %95 test” veri setleriyle yapılan OSA kümeleme işleminin başarımları Çizelge 4.7’de verilmiştir. Bu çizelgede görülen değerler sol endokart, sağ endokart ve epikart kaynaklı aritmi lokalizasyonundan elde edilmiştir. Miyokart katmanı da ayırım işlemine katıldığında yaklaşık olarak %65-70 arası bir başarımları elde edilmiştir.

“%50 eğitim - %50 test” ve “%5 eğitim - %95 test” veri setleriyle yapılan kNN katman sınıflandırması işleminin başarımları Çizelge 4.8’de verilmiştir. Bu çizelgede görülen değerler sol endokart, sağ endokart ve epikart kaynaklı aritmi lokalizasyonundan elde edilmiştir. Miyokart katmanı da ayırım işlemine katıldığında yaklaşık olarak %60-65 arası bir başarımları elde edilmiştir.

“%50 eğitim - %50 test” ve “%5 eğitim - %95 test” veri setleriyle yapılan DA sınıflandırmasının başarımları Çizelge 4.9’de verilmiştir. Bu çizelgede görülen değerler sol endokart, sağ endokart ve epikart kaynaklı aritmi lokalizasyonundan elde edilmiştir. Miyokart katmanı da ayırım işlemine katıldığında yaklaşık olarak %70-75 arası bir başarımları elde edilmiştir.

“%50 eğitim - %50 test” ve “%5 eğitim - %95 test” veri setleriyle yapılan DVM sınıflandırma işleminin başarımları Çizelge 4.10’da verilmiştir. Bu çizelgede görülen değerler sol endokart, sağ endokart ve epikart kaynaklı aritmi lokalizasyonundan elde edilmiştir. Miyokart katmanı da ayırım işlemine katıldığında yaklaşık olarak %65-70 arası bir başarımları elde edilmiştir.

Çizelge 4.7 Benzetim verisi üzerinde OSA ile katman ayırma uygulamasının başarımlarını yansıtan yüzdeleri.

| OPTİMİZASYON SONRASI BAŞARIM DURUMU | | | | | |
|--|-------------------------------|-----------------|-----------------|------------------|---------------------|
| Sol Endokart 64 Basket Kateter Veri Seti | | Le_Doğru | Re_Doğru | Epi_Doğru | Toplam_Doğru |
| | %50 Eğitim ve %50 Test | % 95,9075 | % 92,2131 | % 99,026 | % 97,0657 |
| | %5 Eğitim ve %95 Test | % 50 | % 75,431 | % 87,524 | % 76,5949 |
| Sağ Endokart 64 Basket Kateter Veri Seti | | Le_Doğru | Re_Doğru | Epi_Doğru | Toplam_Doğru |
| | %50 Eğitim ve %50 Test | % 99,2883 | % 90,9836 | % 99,026 | % 97,5676 |
| | %5 Eğitim ve %95 Test | % 77,7154 | % 45,4741 | % 94,3058 | % 81,2678 |
| Sol Endokart Bsket ve Epikart Venöz Veri Setleri | | Le_Doğru | Re_Doğru | Epi_Doğru | Toplam_Doğru |
| | %50 Eğitim ve %50 Test | % 99,4662 | % 95,6721 | % 99,2208 | % 98,8170 |
| | %5 Eğitim ve %95 Test | % 84,2697 | % 73,4914 | % 93,0262 | % 87,1597 |
| Sağ Endokart Basket ve Epikart Venöz Veri Setleri | | Le_Doğru | Re_Doğru | Epi_Doğru | Toplam_Doğru |
| | %50 Eğitim ve %50 Test | % 99,4662 | % 94,877 | % 99,6104 | % 98,6873 |
| | %5 Eğitim ve %95 Test | % 79,0262 | % 72,8448 | % 92,8983 | % 85,8188 |

Çizelge 4.8 Benzetim verisi üzerinde kNN ile katman ayırma uygulamasının başarımlarını gösteren yüzdeleri.

| Sol Endokart 64 Basket Kateter Veri Seti | | Le_Doğru | Re_Doğru | Epi_Doğru | Toplam_Doğru |
|---|------------------------|-----------|-----------|-----------|--------------|
| | %50 Eğitim ve %50 Test | % 96,4413 | % 83,6066 | % 97,5325 | % 94,6718 |
| %5 Eğitim ve %95 Test | % 70,4120 | % 71,9828 | % 92,0665 | % 83,2588 | |
| Sağ Endokart 64 Basket Kateter Veri Seti | | Le_Doğru | Re_Doğru | Epi_Doğru | Toplam_Doğru |
| | %50 Eğitim ve %50 Test | % 97,8648 | % 89,7541 | % 99,2208 | % 97,1429 |
| | %5 Eğitim ve %95 Test | % 75,0936 | % 57,7586 | % 92,7703 | % 82,0398 |
| Sol Endokart Bsket ve Epikart Venöz Veri Setleri | | Le_Doğru | Re_Doğru | Epi_Doğru | Toplam_Doğru |
| | %50 Eğitim ve %50 Test | % 99,2883 | % 90,1639 | % 97,2727 | % 96,3707 |
| | %5 Eğitim ve %95 Test | % 83,8951 | % 74,5690 | % 92,6424 | % 87,0378 |
| Sağ Endokart Basket ve Epikart Venöz Veri Setleri | | Le_Doğru | Re_Doğru | Epi_Doğru | Toplam_Doğru |
| | %50 Eğitim ve %50 Test | % 99,2883 | % 88,9344 | % 98,9610 | % 97,1429 |
| | %5 Eğitim ve %95 Test | % 82,3970 | % 71,3362 | % 92,1945 | % 85,8188 |


Çizelge 4.9 Benzetim verisi üzerinde DA ile katman ayırma uygulamasının başarımlarını gösteren yüzdeleri.

| | | | | | |
|---|------------------------|-----------------|-----------------|------------------|---------------------|
| Sol Endokart 64 Basket Kateter Veri Seti | | Le_Dođru | Re_Dođru | Epi_Dođru | Toplam_Dođru |
| | %50 Eğitim ve %50 Test | % 98,9324 | % 97,9508 | % 97,9221 | % 98,1467 |
| | %5 Eğitim ve %95 Test | % 92,8839 | % 95,9052 | % 55,2783 | % 69,2808 |
| Sađ Endokart 64 Basket Kateter Veri Seti | | Le_Dođru | Re_Dođru | Epi_Dođru | Toplam_Dođru |
| | %50 Eğitim ve %50 Test | % 98,2206 | % 97,1311 | % 99,4805 | % 98,7645 |
| | %5 Eğitim ve %95 Test | % 76,9663 | % 85,7759 | % 37,2361 | % 52,4584 |
| Sol Endokart Bsket ve Epikart Venöz Veri Setleri | | Le_Dođru | Re_Dođru | Epi_Dođru | Toplam_Dođru |
| | %50 Eğitim ve %50 Test | % 98,9324 | % 89,3443 | % 100 | % 97,7606 |
| | %5 Eğitim ve %95 Test | % 90,0749 | % 84,4828 | % 53,7428 | % 65,5425 |
| Sađ Endokart Basket ve Epikart Venöz Veri Setleri | | Le_Dođru | Re_Dođru | Epi_Dođru | Toplam_Dođru |
| | %50 Eğitim ve %50 Test | % 98,5765 | % 94,6721 | % 100 | % 98,6873 |
| | %5 Eğitim ve %95 Test | % 79,0262 | % 82,1121 | % 44,6577 | % 56,9281 |

Çizelge 4.10 Benzetim verisi üzerinde DVM ile katman ayırma uygulamasının başarımlarını gösteren yüzdeleri.


| | | | | | |
|---|------------------------|-------------------|------------------|-----------------------|---------------------|
| Sol Endokart Basket Kateter Veri Seti | | LERE_Doğru | Epi_Doğru | LE ve RE Doğru | Toplam_Doğru |
| | %50 Eğitim ve %50 Test | % 91,8095 | % 98,4416 | % 99,7925 | % 95,7529 |
| | %5 Eğitim ve %95 Test | % 70,4120 | % 71,9828 | % 99,7925 | % 71,4241 |
| Sağ Endokart Basket Kateter Veri Seti | | LERE_Doğru | Epi_Doğru | LE ve RE Doğru | Toplam_Doğru |
| | %50 Eğitim ve %50 Test | 96,7619 | % 99,8701 | % 99,7925 | % 98,6100 |
| | %5 Eğitim ve %95 Test | % 75,0936 | % 57,7586 | % 99,7925 | % 62,0398 |
| Sol Endokart Basket ve Epikart Venöz Veri Setleri | | LERE_Doğru | Epi_Doğru | LE ve RE Doğru | Toplam_Doğru |
| | %50 Eğitim ve %50 Test | % 94,4762 | % 99,6104 | % 99,0665 | % 97,5290 |
| | %5 Eğitim ve %95 Test | % 73,8951 | % 74,5690 | % 99,7925 | % 74,2554 |
| Sağ Endokart Basket ve Epikart Venöz Veri Setleri | | LERE_Doğru | Epi_Doğru | LE ve RE Doğru | Toplam_Doğru |
| | %50 Eğitim ve %50 Test | % 96,7619 | % 100 | % 99,0665 | % 98,6873 |
| | %5 Eğitim ve %95 Test | % 72,3970 | % 71,3362 | % 99,7925 | % 71,7398 |

Katman ayırma sonucunda aritmi kaynağının epikart veya endokart kaynaklı olduğunu belirlenmiştir. Daha sonra belirlenen kalp katmanı üzerinde kademeli odaklanma kullanılmıştır. Gösterim boyutları gerçek boyutlar değildir. Şekil 4.6 (a)'da sol endokart, (b)'de sağ endokart ve (c)'de epikart katmanları üzerindeki BCO kümeleme ile elde edilen genel kümeleme üç boyutlu olarak gösterilmiştir.




Şekil 4.6 Benzetim verisinde üç katman üzerinde yapılan eğitimci bölgelemenin üç boyutlu gösterimi.

Küme düzeltme algoritması çalıştırılmadan önce epikart üzerinde oluşan kümeler ve bir test noktasının (aritmi kaynağı) yeri işlemin göz önünde canlandırılması amacıyla Şekil 4.7'de verilmiştir. Aritmi kaynağı şekilde kırmızı yıldız ile işaretlenmiştir.




Şekil 4.7 Benzetim verisi üzerinde bölge düzeltmesi öncesi epikart üzerindeki genel bölgeleme.

Küme düzeltmeden sonra yeni oluşan kümeler Şekil 4.8'de verilmiştir. Burada gerçek uyarı merkezi kırmızı yıldız ile gösterilmiştir.




Şekil 4.8 Benzetim verisi üzerinde bölge düzeltmesi sonrası epikart üzerindeki genel bölgeleme.

Küme düzeltme işleminden önce ve sonra her bir kümenin küme içi yayılma sayısı hesaplanmıştır. Bu sayede küme düzeltme işleminin kümeleri ne ölçüde daha odaklı bir hale getirdiği incelenmiştir. Bu sayılar kümeleme doğruluğu için bir gösterge olacaktır. Test noktalarının oluşturulan kümeleme içinde hangi kümeye ait olduğunu bulmak için OSA yapısı kullanılmıştır. OSA tarafından atanan kümenin birinci komşu kümeleri hesaplanmıştır. Ortalama 5-6 arasında küme ve ilk kümelemenin yaklaşık %10-20 kadar uyarım noktasını içeren bu bölge daha sonra 12 adet bölgeye ayrılmıştır. Birinci alt kümelemede elde edilen bölgeler Şekil 4.9'da verilmiştir.




Şekil 4.9 Benzetim verisi üzerinde bölge düzeltmesi öncesi epikart üzerindeki birinci alt bölgeleme.

Genel kümelemede olduğu gibi bu aşamada da küme düzeltme algoritması kullanılmış ve elde edilen kalp üzerindeki bölgeleme Şekil 4.10'da gösterilmiştir.




Şekil 4.10 Benzetim verisi üzerinde bölge düzeltmesi sonrası epikart üzerindeki birinci alt bölgeleme.

Birinci alt kümelemenin ardından ikinci bir alt kümeleme yapılmıştır. Yaklaşık 6-7 kümeden oluşan atanan birinci alt küme ve onun birinci komşuluklarından oluşan yapı 10 adet kümeye ayrılmıştır. Bu sayının artırılmasının kümelerin yapısını bozmaya başladığı ve küme içi yayılma sayılarının çok arttığı tespit edilmiştir. Şekil 4.11'de oluşan bu yeni yapı verilmiştir.



Şekil 4.11 Benzetim verisi üzerinde bölge düzeltmesi öncesi epikart üzerindeki ikinci alt bölgeleme.

En son olarak ikinci alt kümelemede oluşan kümelerin düzeltilmesi yapılmıştır. Şekil 4.12'de değiştirilmiş kümeler ve gerçek uyarım noktası verilmiştir.



Şekil 4.12 Benzetim verisi üzerinde bölge düzeltmesi sonrası epikart üzerindeki ikinci alt bölgeleme.

Genel kümelemede atanan grup ve komşuları yaklaşık 390-400 uyarım noktasından oluşur. Atanan grup da yaklaşık 65 uyarım noktası vardır. İkinci alt kümelemeden sonra ise atanan grupta ortalama 16-18 uyarım noktası, birinci komşuluklarla birlikte en fazla 100-120 uyarım noktası bulunmaktadır. İki alt kümele sonrasında uyarım noktaları yaklaşık 3,5 kat azalmıştır. Bunun sonucunda ise aritminin kaynağı olduğu söylenebilecek bölgenin genişliğinin de yaklaşık 3,5 kat azaldığı söylenebilir.

OSA ile kademeli odaklanma çalışmalarının ayrıntılı sonuçları Çizelge 4.11, Çizelge 4.12 ve Çizelge 4.13'de verilmiştir. KNN ile kademeli odaklanma çalışmalarının ayrıntılı sonuçları Çizelge 4.14, Çizelge 4.15 ve Çizelge 4.16'da verilmiştir. Diskriminant Analiz ile kademeli odaklanma çalışmalarının ayrıntılı sonuçları Çizelge 4.17, Çizelge 4.18 ve Çizelge 4.19'da verilmiştir.

Çizelge 4.11 Epikart benzetim verisi üzerinde OSA sınıflandırması kullanılarak yapılan kademeli odaklanma sonuçları.

| Benzetim Verisi – OSA ile Kademeli Odaklanma | |
|--|----------------------|
| Uygulanan Katman | Epikart |
| Genel Kümelemedeki Toplam Küme Sayısı | 20 |
| Birinci Alt Kümelemedeki Toplam Küme Sayısı | 12 |
| İkinci Alt Kümelemedeki Toplam Küme Sayısı | 10 |
| İterasyon Sayısı | 500 |
| Yayılim Fonksiyonu Sayısı | 0,32 |
| Çapraz Sağlama Derecesi | 10 |
| Genel Kümelemedeki Toplam Nokta Sayısı | 1540 |
| Genel Kümelemede Eğitim Seti Boyutu | 1385 |
| Genel Kümelemede Test Seti Boyutu | 155 |
| Genel Kümelemede Test Noktası ile Ortalama Uzaklık | 3,74685 ± 0,50947 mm |
| Genel Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların Genel Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,73285 (24 adet) |
| Genel Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 22,2824 ± 2,2650 |
| Genel Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 22,0620 ± 1,7305 |
| Birinci Alt Kümelemedeki Ortalama Toplam Nokta Sayısı | 425 |
| Birinci Alt Kümelemede Eğitim Setinin Ortalama Boyutu | 382 |
| Birinci Alt Kümelemede Test Setinin Ortalama Boyutu | 43 |
| Birinci Alt Kümelemede Test Noktası ile Ortalama Uzaklık | 3,77549 ± 0,49953 mm |
| Birinci Alt Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların Birinci Alt Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,17647 (5 adet) |
| Birinci Alt Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 17,4598 ± 1,6299 |
| Birinci Alt Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 17,4459 ± 1,6005 |
| İkinci Alt Kümelemedeki Ortalama Toplam Nokta Sayısı | 237 |
| İkinci Alt Kümelemede Eğitim Setinin Ortalama Boyutu | 213 |
| İkinci Alt Kümelemede Test Setinin Ortalama Boyutu | 24 |
| İkinci Alt Kümelemede Test Noktası ile Ortalama Uzaklık | 3,68151 ± 0,46957 mm |
| İkinci Alt Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların İkinci Alt Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %0,843881 (2 adet) |
| İkinci Alt Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 14,7809 ± 1,7730 |
| İkinci Alt Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 14,7723 ± 1,7531 |

Çizelge 4.12 Sol endokart benzetim verisi üzerinde OSA sınıflandırması kullanılarak yapılan kademeli odaklanma sonuçları.

| Benzetim Verisi – OSA ile Kademeli Odaklanma | |
|--|----------------------|
| Uygulanan Katman | Sol Endokart |
| Genel Kümelemedeki Toplam Küme Sayısı | 20 |
| Birinci Alt Kümelemedeki Toplam Küme Sayısı | 12 |
| İkinci Alt Kümelemedeki Toplam Küme Sayısı | 10 |
| İterasyon Sayısı | 350 |
| Yayılim Fonksiyonu Sayısı | 0,78 |
| Çapraz Sağlama Derecesi | 10 |
| Genel Kümelemedeki Toplam Nokta Sayısı | 562 |
| Genel Kümelemede Eğitim Seti Boyutu | 505 |
| Genel Kümelemede Test Seti Boyutu | 57 |
| Genel Kümelemede Test Noktası ile Ortalama Uzaklık | 3,91460 ± 0,54324 mm |
| Genel Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların Genel Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,782178 (9 adet) |
| Genel Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 13,5201 ± 1,3785 |
| Genel Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 13,1889 ± 1,2293 |
| Birinci Alt Kümelemedeki Ortalama Toplam Nokta Sayısı | 150 |
| Birinci Alt Kümelemede Eğitim Setinin Ortalama Boyutu | 135 |
| Birinci Alt Kümelemede Test Setinin Ortalama Boyutu | 15 |
| Birinci Alt Kümelemede Test Noktası ile Ortalama Uzaklık | 3,81519 ± 0,48779 mm |
| Birinci Alt Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların Birinci Alt Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,3333 (2 adet) |
| Birinci Alt Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 9,4863 ± 1,1951 |
| Birinci Alt Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 9,4885 ± 1,1927 |
| İkinci Alt Kümelemedeki Ortalama Toplam Nokta Sayısı | 134 |
| İkinci Alt Kümelemede Eğitim Setinin Ortalama Boyutu | 120 |
| İkinci Alt Kümelemede Test Setinin Ortalama Boyutu | 14 |
| İkinci Alt Kümelemede Test Noktası ile Ortalama Uzaklık | 3,68492 ± 0,53481 mm |
| İkinci Alt Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların İkinci Alt Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %0,7462686 (1 adet) |
| İkinci Alt Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 6,2907 ± 0,9989 |
| İkinci Alt Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 6,2847 ± 1,0011 |

Çizelge 4.13 Sağ endokart benzetim verisi üzerinde OSA sınıflandırması kullanılarak yapılan kademeli odaklanma sonuçları.

| Benzetim Verisi – OSA ile Kademeli Odaklanma | |
|--|----------------------|
| Uygulanan Katman | Sağ Endokart |
| Genel Kümelemedeki Toplam Küme Sayısı | 20 |
| Birinci Alt Kümelemedeki Toplam Küme Sayısı | 12 |
| İkinci Alt Kümelemedeki Toplam Küme Sayısı | 10 |
| İterasyon Sayısı | 350 |
| Yayılim Fonksiyonu Sayısı | 0,83 |
| Çapraz Sağlama Derecesi | 10 |
| Genel Kümelemedeki Toplam Nokta Sayısı | 488 |
| Genel Kümelemede Eğitim Seti Boyutu | 439 |
| Genel Kümelemede Test Seti Boyutu | 49 |
| Genel Kümelemede Test Noktası ile Ortalama Uzaklık | 3,72175 ± 0,69637 mm |
| Genel Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların Genel Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,8223 (8 adet) |
| Genel Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 12,5295 ± 1,4967 |
| Genel Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 12,3270 ± 1,5391 |
| Birinci Alt Kümelemedeki Ortalama Toplam Nokta Sayısı | 116 |
| Birinci Alt Kümelemede Eğitim Setinin Ortalama Boyutu | 104 |
| Birinci Alt Kümelemede Test Setinin Ortalama Boyutu | 8 |
| Birinci Alt Kümelemede Test Noktası ile Ortalama Uzaklık | 3,80376 ± 0,59575 mm |
| Birinci Alt Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların Birinci Alt Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,7241 (2 adet) |
| Birinci Alt Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 8,4877 ± 0,7812 |
| Birinci Alt Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 8,4790 ± 0,7867 |
| İkinci Alt Kümelemedeki Ortalama Toplam Nokta Sayısı | 70 |
| İkinci Alt Kümelemede Eğitim Setinin Ortalama Boyutu | 63 |
| İkinci Alt Kümelemede Test Setinin Ortalama Boyutu | 7 |
| İkinci Alt Kümelemede Test Noktası ile Ortalama Uzaklık | 3,52433 ± 0,56601 mm |
| İkinci Alt Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların İkinci Alt Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,4285 (1 adet) |
| İkinci Alt Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 6,3761 ± 0,7120 |
| İkinci Alt Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 6,2818 ± 0,7680 |

Çizelge 4.14 Epikart benzetim verisi üzerinde kNN sınıflandırması kullanılarak yapılan kademeli odaklanma sonuçları.

| Benzetim Verisi – kNN ile Kademeli Odaklanma | |
|--|---------------------|
| Uygulanan Katman | Epikart |
| Genel Kümelemedeki Toplam Küme Sayısı | 20 |
| Birinci Alt Kümelemedeki Toplam Küme Sayısı | 12 |
| İkinci Alt Kümelemedeki Toplam Küme Sayısı | 10 |
| Uzaklık Yöntemi | 'Euclidean' |
| Kümeleme Yöntemi | 'Random' |
| Derecesi (k) | 7 |
| Çapraz Sağlama Derecesi | 10 |
| Genel Kümelemedeki Toplam Nokta Sayısı | 1540 |
| Genel Kümelemede Eğitim Seti Boyutu | 1385 |
| Genel Kümelemede Test Seti Boyutu | 155 |
| Genel Kümelemede Test Noktası ile Ortalama Uzaklık | 3,8500 ± 0,6165 mm |
| Genel Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların Genel Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,73285 (24 adet) |
| Genel Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 22,4938 ± 2,1645 |
| Genel Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 22,2885 ± 1,7944 |
| Birinci Alt Kümelemedeki Ortalama Toplam Nokta Sayısı | 425 |
| Birinci Alt Kümelemede Eğitim Setinin Ortalama Boyutu | 382 |
| Birinci Alt Kümelemede Test Setinin Ortalama Boyutu | 43 |
| Birinci Alt Kümelemede Test Noktası ile Ortalama Uzaklık | 3,8114 ± 0,5911 mm |
| Birinci Alt Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların Birinci Alt Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,17647 + (5 adet) |
| Birinci Alt Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 16.4760 ± 1.7089 |
| Birinci Alt Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 16,4818 ± 1,7058 |
| İkinci Alt Kümelemedeki Ortalama Toplam Nokta Sayısı | 237 |
| İkinci Alt Kümelemede Eğitim Setinin Ortalama Boyutu | 213 |
| İkinci Alt Kümelemede Test Setinin Ortalama Boyutu | 24 |
| İkinci Alt Kümelemede Test Noktası ile Ortalama Uzaklık | 3,7890 ± 0,6019 mm |
| İkinci Alt Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların İkinci Alt Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %0,843881 (2 adet) |
| İkinci Alt Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 13,9539 ± 1,6252 |
| İkinci Alt Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 13,9870 ± 1,6057 |

Çizelge 4.15 Sol endokart benzetim verisi üzerinde kNN sınıflandırması kullanılarak yapılan kademeli odaklanma sonuçları.

| Benzetim Verisi – kNN ile Kademeli Odaklanma | |
|--|---------------------|
| Uygulanan Katman | Sol Endokart |
| Genel Kümelemedeki Toplam Küme Sayısı | 20 |
| Birinci Alt Kümelemedeki Toplam Küme Sayısı | 12 |
| İkinci Alt Kümelemedeki Toplam Küme Sayısı | 10 |
| Uzaklık Yöntemi | 'Euclidean' |
| Kümeleme Metodu | 'Random' |
| Derecesi (k) | 5 |
| Çapraz Sağlama Derecesi | 10 |
| Genel Kümelemedeki Toplam Nokta Sayısı | 562 |
| Genel Kümelemede Eğitim Seti Boyutu | 505 |
| Genel Kümelemede Test Seti Boyutu | 57 |
| Genel Kümelemede Test Noktası ile Ortalama Uzaklık | 3,4174 ± 0,4874 |
| Genel Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların Genel Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,782178 (9 adet) |
| Genel Kümeleme için Düzeltmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 13,5716 ± 1,6280 |
| Genel Kümeleme için Düzeltmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 13,2680 ± 1,2966 |
| Birinci Alt Kümelemedeki Ortalama Toplam Nokta Sayısı | 150 |
| Birinci Alt Kümelemede Eğitim Setinin Ortalama Boyutu | 135 |
| Birinci Alt Kümelemede Test Setinin Ortalama Boyutu | 15 |
| Birinci Alt Kümelemede Test Noktası ile Ortalama Uzaklık | 3,3536 ± 0,4607 |
| Birinci Alt Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların Birinci Alt Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,3333 (2 adet) |
| Birinci Alt Kümeleme için Düzeltmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 10,7574 ± 0,7490 |
| Birinci Alt Kümeleme için Düzeltmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 10,7806 ± 0,7519 |
| İkinci Alt Kümelemedeki Ortalama Toplam Nokta Sayısı | 134 |
| İkinci Alt Kümelemede Eğitim Setinin Ortalama Boyutu | 120 |
| İkinci Alt Kümelemede Test Setinin Ortalama Boyutu | 14 |
| İkinci Alt Kümelemede Test Noktası ile Ortalama Uzaklık | 3,2954 ± 0,5061 |
| İkinci Alt Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların İkinci Alt Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %0,7462686 (1 adet) |
| İkinci Alt Kümeleme için Düzeltmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 8,7385 ± 1,1133 |
| İkinci Alt Kümeleme için Düzeltmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 8,5387 ± 1,0685 |

Çizelge 4.16 Sağ endokart benzetim verisi üzerinde kNN sınıflandırması kullanılarak yapılan kademeli odaklanma sonuçları.

| Benzetim Verisi – kNN ile Kademeli Odaklanma | |
|--|--------------------|
| Uygulanan Katman | Sağ Endokart |
| Genel Kümelemedeki Toplam Küme Sayısı | 20 |
| Birinci Alt Kümelemedeki Toplam Küme Sayısı | 12 |
| İkinci Alt Kümelemedeki Toplam Küme Sayısı | 10 |
| Uzaklık Yöntemi | 'Euclidean' |
| Kümeleme Yöntemi | 'Random' |
| Derecesi (k) | 5 |
| Çapraz Sağlama Derecesi | 10 |
| Genel Kümelemedeki Toplam Nokta Sayısı | 488 |
| Genel Kümelemede Eğitim Seti Boyutu | 439 |
| Genel Kümelemede Test Seti Boyutu | 49 |
| Genel Kümelemede Test Noktası ile Ortalama Uzaklık | 3,8102 ± 0,4069 mm |
| Genel Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların Genel Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,8223 (8 adet) |
| Genel Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 12,5448 ± 1,6691 |
| Genel Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 12,2936 ± 1,6559 |
| Birinci Alt Kümelemedeki Ortalama Toplam Nokta Sayısı | 116 |
| Birinci Alt Kümelemede Eğitim Setinin Ortalama Boyutu | 104 |
| Birinci Alt Kümelemede Test Setinin Ortalama Boyutu | 8 |
| Birinci Alt Kümelemede Test Noktası ile Ortalama Uzaklık | 3,7951 ± 0,4252 mm |
| Birinci Alt Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların Birinci Alt Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,7241 (2 adet) |
| Birinci Alt Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 9,3640 ± 1,3917 |
| Birinci Alt Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 9,2801 ± 1,0906 |
| İkinci Alt Kümelemedeki Ortalama Toplam Nokta Sayısı | 70 |
| İkinci Alt Kümelemede Eğitim Setinin Ortalama Boyutu | 63 |
| İkinci Alt Kümelemede Test Setinin Ortalama Boyutu | 7 |
| İkinci Alt Kümelemede Test Noktası ile Ortalama Uzaklık | 3,7237 ± 0,4100 mm |
| İkinci Alt Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların İkinci Alt Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,4285 (1 adet) |
| İkinci Alt Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 7,1792 ± 1,0552 |
| İkinci Alt Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 7,1373 ± 1,0426 |

Çizelge 4.17 Epikart benzetim verisi üzerinde DA sınıflandırması kullanılarak yapılan kademeli odaklanma sonuçları.

| Benzetim Verisi – DA ile Kademeli Odaklanma | |
|--|--------------------|
| Uygulanan Katman | Epikart |
| Genel Kümelemedeki Toplam Küme Sayısı | 20 |
| Birinci Alt Kümelemedeki Toplam Küme Sayısı | 12 |
| İkinci Alt Kümelemedeki Toplam Küme Sayısı | 10 |
| Uzaklık Yöntemi | 'Diagquadratic' |
| Çapraz Sağlama Derecesi | 10 |
| Genel Kümelemedeki Toplam Nokta Sayısı | 1540 |
| Genel Kümelemede Eğitim Seti Boyutu | 1385 |
| Genel Kümelemede Test Seti Boyutu | 155 |
| Genel Kümelemede Test Noktası ile Ortalama Uzaklık | 3,8902 ± 0,6754 mm |
| Genel Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların Genel Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,73285 (24 adet) |
| Genel Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 22,7978 ± 2,5147 |
| Genel Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 22,5706 ± 2,1617 |
| Birinci Alt Kümelemedeki Ortalama Toplam Nokta Sayısı | 425 |
| Birinci Alt Kümelemede Eğitim Setinin Ortalama Boyutu | 382 |
| Birinci Alt Kümelemede Test Setinin Ortalama Boyutu | 43 |
| Birinci Alt Kümelemede Test Noktası ile Ortalama Uzaklık | 3,7733 ± 0,6555 mm |
| Birinci Alt Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların Birinci Alt Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,17647 (5 adet) |
| Birinci Alt Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 16,1920 ± 2,2659 |
| Birinci Alt Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 16,1066 ± 2,2485 |
| İkinci Alt Kümelemedeki Ortalama Toplam Nokta Sayısı | 237 |
| İkinci Alt Kümelemede Eğitim Setinin Ortalama Boyutu | 213 |
| İkinci Alt Kümelemede Test Setinin Ortalama Boyutu | 24 |
| İkinci Alt Kümelemede Test Noktası ile Ortalama Uzaklık | 3,7151 ± 0,6404 mm |
| İkinci Alt Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların İkinci Alt Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %0,843881 (2 adet) |
| İkinci Alt Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 15,6475 ± 2,1087 |
| İkinci Alt Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 15,5717 ± 2,0597 |

Çizelge 4.18 Sol endokart benzetim verisi üzerinde DA sınıflandırması kullanılarak yapılan kademeli odaklanma sonuçları.


| Benzetim Verisi – DA ile Kademeli Odaklanma | |
|--|--------------------|
| Uygulanan Katman | Sol Endokart |
| Genel Kümelemedeki Toplam Küme Sayısı | 20 |
| Birinci Alt Kümelemedeki Toplam Küme Sayısı | 12 |
| İkinci Alt Kümelemedeki Toplam Küme Sayısı | 10 |
| Uzaklık Yöntemi | 'Diagquadratic' |
| Çapraz Sağlama Derecesi | 10 |
| Genel Kümelemedeki Toplam Nokta Sayısı | 562 |
| Genel Kümelemede Eğitim Seti Boyutu | 505 |
| Genel Kümelemede Test Seti Boyutu | 57 |
| Genel Kümelemede Test Noktası ile Ortalama Uzaklık | 3,8592 ± 0,5012 mm |
| Genel Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların Genel Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,782178 (9 adet) |
| Genel Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 13,5129 ± 1,6153 |
| Genel Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 13,2679 ± 1,5971 |
| Birinci Alt Kümelemedeki Ortalama Toplam Nokta Sayısı | 150 |
| Birinci Alt Kümelemede Eğitim Setinin Ortalama Boyutu | 135 |
| Birinci Alt Kümelemede Test Setinin Ortalama Boyutu | 15 |
| Birinci Alt Kümelemede Test Noktası ile Ortalama Uzaklık | 3,8645 ± 0,5132 mm |
| Birinci Alt Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların Birinci Alt Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,3333 (2 adet) |
| Birinci Alt Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 9,3860 ± 0,8156 |
| Birinci Alt Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 9,3854 ± 0,8146 |
| İkinci Alt Kümelemedeki Ortalama Toplam Nokta Sayısı | 134 |
| İkinci Alt Kümelemede Eğitim Setinin Ortalama Boyutu | 120 |
| İkinci Alt Kümelemede Test Setinin Ortalama Boyutu | 14 |
| İkinci Alt Kümelemede Test Noktası ile Ortalama Uzaklık | 3,5691 ± 0,4665 mm |
| İkinci Alt Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların İkinci Alt Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %0,7462 (1 adet) |
| İkinci Alt Kümeleme için Düzeltilmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 7,8476 ± 0,6824 |
| İkinci Alt Kümeleme için Düzeltilmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 7,8374 ± 0,6773 |

Çizelge 4.19 Sağ endokart benzetim verisi üzerinde DA sınıflandırması kullanılarak yapılan kademeli odaklanma sonuçları.

| Benzetim Verisi – DA ile Kademeli Odaklanma | |
|--|--------------------|
| Uygulanan Katman | Sağ Endokart |
| Genel Kümelemedeki Toplam Küme Sayısı | 20 |
| Birinci Alt Kümelemedeki Toplam Küme Sayısı | 12 |
| İkinci Alt Kümelemedeki Toplam Küme Sayısı | 10 |
| Uzaklık Yöntemi | 'Diagquadratic' |
| Çapraz Sağlama Derecesi | 10 |
| Genel Kümelemedeki Toplam Nokta Sayısı | 488 |
| Genel Kümelemede Eğitim Seti Boyutu | 439 |
| Genel Kümelemede Test Seti Boyutu | 49 |
| Genel Kümelemede Test Noktası ile Ortalama Uzaklık | 3,8774 ± 0,5585 mm |
| Genel Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların Genel Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,8223 (8 adet) |
| Genel Kümeleme için Düzeltmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 12,4893 ± 1,4677 |
| Genel Kümeleme için Düzeltmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 12,3583 ± 1,4446 |
| Birinci Alt Kümelemedeki Ortalama Toplam Nokta Sayısı | 116 |
| Birinci Alt Kümelemede Eğitim Setinin Ortalama Boyutu | 104 |
| Birinci Alt Kümelemede Test Setinin Ortalama Boyutu | 8 |
| Birinci Alt Kümelemede Test Noktası ile Ortalama Uzaklık | 3,8285 ± 0,5413 mm |
| Birinci Alt Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların Birinci Alt Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,7241 (2 adet) |
| Birinci Alt Kümeleme için Düzeltmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 9,7502 ± 1,3725 |
| Birinci Alt Kümeleme için Düzeltmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 9,7440 ± 1,3684 |
| İkinci Alt Kümelemedeki Ortalama Toplam Nokta Sayısı | 70 |
| İkinci Alt Kümelemede Eğitim Setinin Ortalama Boyutu | 63 |
| İkinci Alt Kümelemede Test Setinin Ortalama Boyutu | 7 |
| İkinci Alt Kümelemede Test Noktası ile Ortalama Uzaklık | 3,7456 ± 0,5300 mm |
| İkinci Alt Kümelemede Kümesi Değiştirilen (Düzeltilen) Noktaların İkinci Alt Kümelemedeki Eğitim Setine Ortalama Yüzdesi | %1,4285 (1 adet) |
| İkinci Alt Kümeleme için Düzeltmeden Önceki Ortalama Küme İçi Yayılma Sayısı | 7,0029 ± 1,1803 |
| İkinci Alt Kümeleme için Düzeltmeden Sonraki Ortalama Küme İçi Yayılma Sayısı | 6,9741 ± 1,1758 |


4.3 VYPH Verisi Üzerindeki Uygulamalar

QRS integralleri için elle kümeleme ve OSA altında GA optimizasyonu yapılmıştır. Yayılım fonksiyonu değerine karşı (1/Başarım Yüzdesi) değeri Şekil 4.13'de gösterilmiştir. GA, OSA yayılım değerinin optimumu 0.2758 olarak vermiştir.



Şekil 4.13 QRS integralleri üzerinde elle kümeleme ve OSA optimizasyonu.

QRST integralleri için elle kümeleme ve OSA altında da GA optimizasyonu yapılmıştır. Yayılım fonksiyonu değerine karşı (1/Başarım Yüzdesi) değeri Şekil 4.14'de gösterilmiştir. GA, OSA yayılım değerinin optimumu 0,9154 olarak vermiştir.




Şekil 4.14 QRST integralleri üzerinde elle kümeleme ve OSA optimizasyonu

Şekil 4.15 ve Şekil 4.16'da görüldüğü üzere KLD, QRS ve QRST integralleri kullanılarak yapılan kümeleme işlemi, epikart üzerinde odaklı bölgeler yaratamamıştır. Bölgeler çok dağınık ve birbirlerinden tam olarak ayrılmamıştır yani öğreticisiz yapay sinir ağları başarısız sonuçlar vermişlerdir. Bunun üzerine veri temelli kümelemeler yerine elle kümeleme kullanılmıştır.


Kümelemenin başarısız olması üzerine sadece sınıflandırma algoritmalarının başarımları test edilebilmiştir. GYA ve OSA, elle kümelemenin test aşamasında kullanıldılar. GYA'nın elle kümelenmiş gruplar üzerinde başarımları KLD kullanıldığında 60%, QRS integralleri kullanıldığında 9% ve QRST integralleri kullanıldığında 33% civarındadır. OSA'nın başarımları ise KLD kullanıldığında 80%, QRS integralleri kullanıldığında 46% ve QRST integralleri kullanıldığında ise 56% civarındadır.

Gürültü eklenmesi QRS ve QRST integralleri üzerinden yapılan özellik seçimi işlemlerinde az önce verilen YSA performanslarını değiştirmemiştir. Öte yandan 10 dB gürültü eklenmesi; KLVT üzerinden yapılan özellik seçimi işlemlerinde YSA performansını 4% kadar azaltmıştır. 20 dB ve 25 dB gürültü eklenmesi; KLVT

üzerinden yapılan özellik seçimi işlemlerinde YSA performansını 10% kadar azaltmıştır.



Şekil 4.19 VYP haritasından geriçatılarak elde edilen SOM kümelemesi.



Şekil 4.15 VYP haritasından geriçatılarak elde edilen bulanık C ortalamalı kümeleme.

5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, fokal aritmi kaynağı lokalizasyonuna yönelik alternatif yaklaşımlar geliştirilmiştir. Bu yaklaşımlar, çeşitli kalp haritalama yöntemlerinin sahip olduğu dezavantajları gidermeyi hedeflemektedir. Bu dezavantajların ilki, Carto ve Ensite 3000 gibi kateterlere dayalı elektro-anatomik haritalama yöntemlerinin pahalı ve özel ekipman gerekliliği, ilk yatırım maliyetinin yüksekliğidir. Bunu gidermek üzere klinikte standart olarak kullanılan ya da kolayca elde edilebilecek kateterlerin kullanılabileceği bir metodoloji tercih edilmiştir. Ayrıca, elektrofizyoloji laboratuvarlarında mevcut bulunan floroskopi sistemiyle kateterlerin kalp yüzeyi üzerinde veya damar içindeki yerlerinin bulunması mümkündür. Karmaşık, pahalı veri alma sistemleri ve iş istasyonları yerine, kateter elektrotlarından alınan işaretler biyopotansiyel yükselteç ve süzgeçlerden ve analog-sayısal çeviricilerden faydalanarak analiz için gerekli, standart bir kişisel bilgisayara aktarılması işlemi de kolay ve ucuz bir alternatif teşkil etmektedir. Katetere dayalı bazı haritalama yöntemlerinin diğer bir dezavantajı da, haritalama süresinin uzunluğu ve bu yüzden de bazı aritmi tiplerinin haritalanmasında yaşanan güçlüklerdir. Burada önerilen yaklaşımla, bir tek kalp atımından, koroner damar içi kateter ve kalbin iç yüzeylerine temas eden sepet kateter ölçümlerinden yararlanarak aritminin yerelleştirilmesi mümkün olabilmektedir. Bu noktada şunu hatırlatmak lazımdır ki, şu anda kullanılan yöntem ile damarlardan sadece birkaç milimetre uzaklıktaki kaynakların bulunabilmesi mümkün olmaktadır [26;27]. Bu tez çalışmasında ise kalbin her yüzeyinden kaynaklanan aritmilerin makul hatalarla tespit edilebileceği gösterilmiştir. Deneysel veri setinde, aritmik atımların %94'ünün kaynağının yeri yaklaşık 3,5 cm²'lik bir alan içinde, benzetim veri setindeki bütün atımlar ise yaklaşık 2 cm²'lik bir alan içinde belirlenebilmiştir. Halihazırda kullanılan katetere dayalı haritalama yöntemlerinin klinikte uygulanması esnasında yaşanan bir diğer problem de epikardiyal kaynakların yanlışlıkla endokardiyal olarak belirlenerek ablasyon tedavisinin içeriden yapılmasıdır. Bu tedavi, aritmileri tam anlamıyla durduramamakta ve tekrarlanma riskini arttırmaktadır. Bu tez çalışmasında, endokardiyal ve epikardiyal kaynakların birbirinden ayrılmasında ortalama %98 gibi yüksek bir başarı seviyesine ulaşılabilmektedir.

Bu tez çalışmasında ele aldığımız ikinci konu, vücut yüzeyi potansiyel haritalamada mevcut bulunan problemlerin çözümüne yönelik yeni yaklaşımlar geliştirmektir. Modre ve arkadaşları [11] ve Oster ve arkadaşları [14] VYPH yöntemiyle 8-10 mm maksimum doğruluk ile epikardiyal aritmilerin tespit edilebileceğini göstermişlerdir. Cheng ve arkadaşları [12] floroskopik görüntülerden tekrar oluşturulan uyarı elektrotlarının gerçek yeri ile geri problem çözümünün verdiği uyarı yeri arasında yaklaşık 17,3 mm mesafe olduğunu söylemiştir. Tilg ve arkadaşları ise 6 ila 12 mm doğruluğa ulaştıklarını ifade etmiştir [13]. Fakat, bu yöntemin dezavantajları olarak her bir hasta için özel bir ileri matris hesaplama zorunluluğu, ileri problemde bulunan geometrik hatalar, geri problem yaklaşımlarının yumuşatıcı etkileri gibi sebepler sıralanabilir. Bu problemleri aşmak üzere, vücut ve kalp yüzeyleri arasında daha önce elde edilmiş verilerden yola çıkarak bir bağlantı tesis edilmektedir. Bağlantı oluşturulduktan sonra yeni gelen hastadan sadece vücut yüzeyi potansiyelleri ölçülerek artiminin kalbin hangi bölgesinde olduğu bilgisine ulaşılabilmektedir. Bizim analizlerimiz sonucunda, aritmik atımların kaynakları birkaç santimetre karelik bir bölgede %80'e varan başarı ile belirlenmiştir. Bu yaklaşım literatürde ilk defa bizim tarafımızdan uygulanmıştır ve geliştirilmeye açık bir alan olarak görülmektedir. Benzer bir şekilde kalbin yalnız dışından değil içinden kaynaklanan aritmilere de uygulama genişletilebilir.

Yukarıda bahsi geçen haritalama yöntemlerinde sonuçlar potansiyel veya aktivasyon zamanı dağılım haritaları olarak verilmektedir. Haritalar renk kodlu ve kalp geometrisi üzerine oturtulmuş olarak gösterilmektedir. Bu görüntüyü yorumlayan hekim, aritmi kaynağını belirlemekte ve ablasyon kateterini problemlili bölgeye yönlendirmektedir. Bu tez çalışmasında önerilen yöntemlerde ise, aritmi kaynağının yeri bir nokta olarak verilmekten ziyade, kalbin üzerinde aritminin bulunabileceği bir bölge tahmin edilmesi hedeflenmiştir.

Tez çalışmasında iki farklı veri kümesi üzerinde beş farklı sınıflandırma ve üç farklı kümeleme algoritması ile fokal aritmi kaynağının yerinin tayini gerçekleştirilmiştir. Kümeleme yöntemleri olarak elle kümeleme, Kohonen SOM (SOM) ve bulanık C ortalamalı (BCO) kümeleme kullanılmıştır. Sınıflandırma için olasılıksal sinir ağları (OSA), geri yayılım ağları (GYA), diskriminant analizi (DA), k en yakın komşu (kNN) ve destek vektör makineleri (DVM) yöntemleri uygulanmıştır. Bu yöntemler, aritmi

kaynaklarının yerinin belirlenmesinde burada ilk defa kullanılmıştır. Ancak, bu yöntemler aritmilerin varlığını ve hangi tipte olduğunu belirlemek amacıyla daha önce denenmiştir. 2002 ve 2003'de Simelius ve arkadaşları, Kohonen SOM yaklaşımını ventriküler taşikardi tiplerini ayırmada kullanmıştır [137;138]. Ayırma işleminin temelini vücut yüzeyi potansiyel haritalarından elde edilen QRS kompleksinden çıkarılan özellikler oluşturmaktadır. 2008'de Tanawut ve arkadaşları magnetokardiografik haritalar üzerinde geri yayılım ve SOM yöntemleriyle iskemik kalp hastalığının varlığını belirlemeye çalışmışlar ve 80%'e varan başarı sağlanmışlardır [139]. 2006'da Özbay ve arkadaşları EKG sinyallerini yapay sinir ağları ile sınıflandırmışlar, 10 farklı aritmi çeşidini geri yayılım, çok-katmanlı YSA ve bulanık kümeleme ile ayırmışlar ve en iyi sonucun BCO ile 85% oranında elde edildiğini belirtmişlerdir [140]. Muhammad Arif ve arkadaşları 2010 yılında 12 kanal EKG verisi üzerinden kNN ile miyokart damar tıkanıklığı tespiti yapmıştır [141]. Yun-Chi Yeh ve arkadaşları 2009'da EKG verisi ile aritmi teşhisinde DA kullanmışlar ve teşhis algoritmalarının 90%'ünün üzerinde başarıya sahip olduğunu belirtmişlerdir [142]. Song ve arkadaşları ise farklı aritmi tiplerinin sınıflandırmasında DVM kullanmışlar ve 98%'in üzerinde doğruluk sağlamışlardır [143].

İleriye yönelik çalışmalarda ilk olarak, geliştirilen yöntemlerin hayvanlarda ve klinik vakalarda denenebilmesine yönelik çalışmalar öne çıkmaktadır. Bu çalışmada kullanılan deneysel ve benzetim veri kümelerinde, kateter elektrot yerleri tutarlı ve klinik uygulamadaki duruma benzer olarak model kalp geometrileri üzerinden seçilmiştir. İlerideki çalışmalarda, floroskopi ve bilgisayarlı tomografi (BT) kullanılarak kalbin geometrisinin çıkarılması ve elektrotların yerlerinin o geometriye oturtulması sağlanacaktır. Ardından, kateterlerden gelen verilere uygulanacak sınıflandırma yöntemleriyle aritminin bulunduğu bölge kalp geometrisi üzerinde işaretlenerek ablasyon kateterinin yönlendirilmesinde hekime yardımcı olunacaktır. Bu amaçla bir proje hazırlığı yapılmaktadır. Bu projede, kateterler ve VYPH verileri alınarak, floroskopi ve BT yardımıyla geometri ve elektrotların yerleri belirlenerek, hayvanlar üzerinde aritmi kaynağının yerinin bulunmasına yönelik geliştirdiğimiz yaklaşımların denenmesi ve uygulanabilir hale getirilmesi hedeflenmektedir.

Geleceğe yönelik diğer çalışmalar, kullanılan yöntemlerin geliştirilmesi, yenilerinin denenmesi ve performans analizleri olarak sayılabilir. Örneğin, bu çalışmalarda

kullanılan kümeleme ve sınıflandırma yöntemleri çeşitlendirilebilir. YSA uygulamalarına yenileri eklenebilir.

VYPH çalışmamızda yalnızca 72 adet aritmik atımın bulunması önemli bir dezavantajdır. Atım sayısı arttırılarak kalbin farklı bölgelerinden ve yüzeylerinden başlatılacak aritmilerin vücut yüzeyine yansımaları analiz edilerek çeşitli özellik çıkarma ve sınıflandırma uygulamaları daha doğru olarak denenebilecektir.

KAYNAKLAR LİSTESİ

- [1] KALTENBRUNNER W., Cardinal R., Dubuc M., et al, Epicardial and Endocardial Mapping of Ventricular Tachyarrhythmia in Patients with Myocardial Infarction. Is the Origin of the Tachycardia Always Subendocardially Localized? *Circulation*, vol. 84, 1058–1071, 1991.
- [2] LITTMANN L., Svenson R. H., Gallagher J. J., Selle J. G., Zimmern S. H., Fedor J. M., and Colavita P. G., Functional role of the epicardium in postinfarction ventricular tachycardia, *Circulation*, vol. 83, 1577–1591, 1991.
- [3] SIPPENS Groenewegen A., Lesh M. D., Roithinger F. X., et al, Body surface mapping of counterclockwise and clockwise typical atrial flutter: A comparative analysis with endocardial activation sequence mapping, *J. Am. Coll. Cardiol.*, vol. 35, 1276-1287, 2000.
- [4] PINTER A., Molin F., Savard P, et al, Body surface mapping of retrograde P waves in the intact dog by simulation of accessory pathway re-entry. *Can. J. Cardiol.*, vol.16, 175-182, 2000.
- [5] STROINK G., Meeder R. J., Eliot P., et al, Arrhythmia vulnerability assessment using magnetic field maps and body surface potential maps, *Pacing. Clin. Electrophysiol*, vol. 22, 1718-1718, 1999
- [6] MEEDER R. J., Stroink G., Ritcey S. P., et al, Low-frequency component of body surface potential maps identifies patients at risk for ventricular tachycardia, *Eur. Heart J.*, vol. 20, 1126-1134,1999.
- [7] VAN DESSEL P. F., Van Hemel N. M., de Bakker J. M., et al., Relation between body surface mapping and endocardial spread of ventricular activation in postinfarction heart, *J. Cardiovasc. Electrophysiol.*, vol. 12, 1232-1241, 2001.
- [8] LIEBMAN J., The body surface potential map in congenital heart disease, in Schalij M. J., Janse M. J., van Oosterom A., et al (eds), *Eindhoven 2002 100 years of Electocardiography*. Leiden, The Eindhoven Foundation, 215-220, 2002.

- [9] OSTER H., Taccardi B., Lux R., Ershler P., and Rudy Y., Noninvasive electrocardiographic imaging: Reconstruction of epicardial potentials, electrograms, and isochrones and localization of single and multiple electrocardiac events, *Circulation*, vol. 96, 1012–1024, 1997.
- [10] CHENG L. K., Sands G. B., French R. L., Withy S. J., Wong S. P., Legget M. E., Smith W. M., and Pullan A. J., Rapid construction of a patient-specific torso model from 3D ultrasound for non-invasive imaging of cardiac electrophysiology, *Med. Biol. Eng. Comput.*, vol. 43, 1–6, 2005.
- [11] HAN C, Liu Z, Zhang X, Pogwizd S, He B, Noninvasive Three- dimensional Cardiac Activation Imaging from Body Surface Potential Maps: A Computational and Experimental Study on a Rabbit Model, *IEEE Transactions on Medical Imaging*, vol. 27, 1622-1630, 2008.
- [12] LIU C, Skadsberg ND, Ahlberg SA, Swingen CM, laizzo, PA, He B, Estimation of global ventricular activation sequences by noninvasive 3-dimensional electrical imaging: validation studies in a swine model during pacing, *Journal of Cardiovascular Electrophysiology*, vol. 19, 535-540, 2008.
- [13] TILG B., Fischer G., Modre R., Messnarz B., and Roithinger F. X., Electrocardiographic imaging of atrial and ventricular electrical activation, *Med. Image Anal.*, vol. 7, 391–398, 2003.
- [14] MODRE R., Tilg B., Fischer G., and Wach P., Noninvasive myocardial activation time imaging: A novel inverse algorithm applied to clinical ECG mapping data, *IEEE Trans. Biomed. Eng.*, vol. 49, 1153–1161, Oct. 2002.
- [15] DAVIS L. M., Cooper M., Johnson D. C., Uther J. B., Richards D. A. , Ross D. L., Simultaneous 60-electrode mapping of ventricular tachycardia using percutaneous catheters, *J Am Coll Cardiol*, 24-709, 1994.
- [16] GEPSTEIN L., Hayam G., Ben-Haim S. A., A novel method for nonfluoroscopic catheter based electroanatomical mapping of the heart, In vitro and in vivo accuracy results., *Circ.*, 95-1611, 1997.

- [17] WITTKAMPF F. H. M., Wever E. F. D., Derksen R., et al. Localiza: New technique for real-time 3-dimensional localization of regular intracardiac electrodes. *Circ*, 99-1312, 1999.
- [18] BEATTY G. E. , Remole S. C., Johnston M. K., Holte J. E., Benditt D. G., Noncontact electrical extrapolation technique to reconstruct endocardial potentials, *Circ.*, 17-765, 1994.
- [19] SCHALIJ M. J., van Ruyge FP, Siezenga M, van der Velde E. T., Endocardial activation mapping ventricular tachycardia in patients: first application of a 32-site bipolar mapping electrode catheter, *Circ.*, 98-2168, 1998.
- [20] MARKIDES V., Segal O. R., Todato F., and Peters N. S., Mapping, in *Cardiac Electrophysiology From Cell to Bedside*, Zipes D., and Jalife J., (Eds.), W. B: Saunders Co., 858-865, 2004.
- [21] GORNICK C. C., Adler S. W., Pederson B., et al, Validation of a new noncontact catheter system for electro anatomic mapping of left ventricular endocardium, *Circulation*, vol. 99, 829-835, 1999.
- [22] KADISH A., Hauck J., Pederson B, et al, Mapping of atrial activation with a noncontact, multielectrode catheter in dogs, *Circulation*, vol. 99, 1906-1913, 1999.
- [23] SOSA E., Scanavacca M., D'Avila A., Pilleggi F., A new technique to perform epicardial mapping in the electrophysiology laboratory, *J. Cardiovasc. Electrophysiol*, vol. 7, 531-536, 1996.
- [24] SOSA E., Scanavacca M., D'Avila A., et al, Endocardial and epicardial ablation guided by nonsurgical transthoracic epicardial mapping to treat recurrent ventricular tachycardia, *J. Cardiovasc. Electrophysiol.*, vol. 9, 229-239, 1998.
- [25] SCHILING R. J., Peters N. S., Davies D. W., Simultaneous endocardial mapping in the human left ventricle using a noncontact catheter: Comparison of contact and reconstructed electrograms during sinus rhythm, *Circulation*, vol. 98, 887-898, 1998.

- [26] ASIRVATHAM S., Packer D., L., Validation of non-contact mapping to localize the site of simulated pulmonary vein ectopic foci, *Circulation*, vol. 102, 1431-441, 2000.
- [27] PAOLA de A. A., Melo W. D., Tavora M. Z., Martinez E. E., Angiographic and electrophysiological substrates for ventricular tachycardia mapping through the coronary veins, *Heart*, vol. 79, 59-63, 1998.
- [28] MELO W. D., Prudencio L. A., Kusnir C. E., et al, Angiography of the coronary venous system. Use in clinical electrophysiology, *Arq. Bras. Cardiol.* vol. 70, 409-413, 1998.
- [29] STELLBRINK C., Diem B., Schauerte P., et al, Transcoronary venous radiofrequency catheter ablation of ventricular tachycardia, *J. Cardiovasc. Electrophysiol.*, vol. 8, 916-921, 1997.
- [30] WONG T., Chow A. W. C., Markides V., et al, Human ventricular tachycardia ablation guided by intra coronary artery guide-wire mapping [abstract], *Pacing Clin. Electrophysiol.*, vol. 2, 520-524, 2002.
- [31] YILMAZ B, MacLeod RS, Punkse BB, Taccardi B, Brooks DH. Venous catheter based mapping of ectopic epicardial activation: training data set selection for statistical estimation, *IEEE Trans. Biomed Eng.*, vol. 52, 1823-1831, 2005.
- [32] YILMAZ B, MacLeod RS. Selection of the number and location of leads for catheter based epicardial mapping, *BEM/NFSI Conference*, Minneapolis, Minnesota, USA, 2005.
- [33] YILMAZ B. Epicardial potential distribution reconstruction from recordings of intravenous and transthoracic mapping catheters: a feasibility study. *Med Eng Phys*, 29-937, 2007.
- [34] SOSA E., Scanavacca M., d'avilla A., et al, Nonsurgical thoracic epicardial catheter ablation to treat recurrent ventricular tachycardia occurring late after myocardial infarction, *J. Am. Coll. Cardiol.*, vol. 35, 1442-1449, 2000.

- [35] ARRUDA M., Chandrasekaran K., and Reynolds D., Idiopathic epicardial outflow tract ventricular tachycardia: Implications for RF catheter ablation [abstract], *Pacing Clin. Electrophysiol.*, vol. 19, 611-615, 1996.
- [36] SOSA E., Scanavacca M., d'avilla A., et al, Radiofrequency catheter ablation of ventricular tachycardia guided by nonsurgical epicardial mapping in chronic Chagasic heart disease, *Pacing Clin. Electrophysiol.*, vol. 222, 128-130, 1999.
- [37] SCHWEIKERT R., Saliba W. I., Tomassoni G., Marrouche N. F., Cole C. R., Dresing T. J., Tchou P. J., Bash D., Beheiry S., Lam C., Kanagaratnam L., and Natale A., Percutaneous pericardial instrumentation for endoepicardial mapping of previously failed ablations, *Circulation*, vol. 108, 1329–1335, 2003.
- [38] YILMAZ B., Venous Catheter based mapping of epicardial ectopic activation using statistical estimation, Bioengineering Department of Utah University, PhD Thesis, 119p, Utah, 2004.
- [39] YILMAZ B. Cünedioğlu U., Source Localization of Focal Ventricular Arrhythmias using Linear Estimation, Correlation, and Back Propagation Networks, *Computers in Biology and Medicine*, vol.37, 1437– 1445, 2007.
- [40] BAYSOY E., Cunedioğlu U., Yilmaz B., Simultaneous mapping of endocardium and epicardium from multielectrode intrachamber and intravenous catheters: a computer simulation-based validation, *Journal of Electrocardiology*, vol. 43, 56–62, 2010.
- [41] YILMAZ B., Cunedioğlu U., Baysoy E., Usage of Spline Interpolation in Catheter-Based Cardiac Mapping, *Türk. Journal of Electrical Engineering and Computer Sciences*, 2010.
- [42] HATİBOĞLU M. T., *Anatomi ve Fizyoloji*, 7. Basım, Hatiboğlu Yayınevi, 1989.
- [43] GEISSER, Seymour, *Predictive Inference*. New York: Chapman and Hall. ISBN 0412034719, 1993.
- [44] NARDI S. M. D., Atrial Fibrilasyonun Kateter Ablasyonu: Yöntemler ve Sonuçlar, *Türk Aritmi Pacemaker ve Elektrofizyoloji Dergisi*, Cilt:2, Sayı:3, 2005.

- [45] Polychronis E D., P Dalgası ve Atriyal Aritmiler, Türk Aritmi Pacemaker ve Elektrofizyoloji Dergisi, Cilt:4, Sayı:3, 2006.
- [46] CAN İlknur, Ali O., Kardiyak Aritmiler ve EKG Değişiklikleri, Pacemaker ve Elektrofizyoloji Dergisi, Cilt:2, Sayı:3 Ekim 2004.
- [47] GULRAJANI R., Bioelectricity and Biomagnetism, 1st ed., New York: Wiley & Sons, 1998.
- [48] PEHLİVAN F., Biyofizik, Ankara, Hacettepe-Taş Kitapçılık, 2. Baskı, 1997.
- [49] BERBARI E. J., High-Resolution Electrocardiography, in Cardiac Electrophysiology From Cell to Bedside, Zipes D., and Jalife J., (Eds.), W. B: Saunders Co., 793-802, 2004.
- [50] BERBARI E. J., High-Resolution Electrocardiography, in Cardiac Electrophysiology From Cell to Bedside, Zipes D., and Jalife J., (Eds.), W. B: Saunders Co., 793-802, 2004.
- [51] BERBARI E. J., Scherlang B. J., Hope R. R., Lazzara R., Recording from body surface of arrhythmogenic ventricular activity during the ST segment, Am. J. Cardiol., vol. 41, 697-702, 1978.
- [52] SIMSON M. B., Use of Signals in the terminal QRS complex to identify patients with ventricular tachycardia after myocardial infarction, Circulation, vol. 64, 220-235,1981.
- [53] BREITHARDT G., Schwarzmaier J., Boggrefe M, et al, Prognosis significance of late ventricular potentials after acute myocardial infarction, Eur. Heart J. , vol. 4, 487-495,1983.
- [54] STAFFORD P. J., Turner I., Vincent R., Quantitative analysis of signal averaged P waves in idiopathic paroxysmal atrial fibrillation, Am. J. Cardiol. Vol. 68, 751-755, 1991.
- [55] GUIDERA S. A., Steinberg J. S., The signal averaged P wave duration: A rapid noninvasive marker of risk for atrial fibrillation, J. Am. Coll. Cardiol., vol. 21, 1645-1651,1993.

- [56] LANDER P., Gomis P., Goyal R., et al, Analysis of intra-QRS late potentials: Improved predictive value for arrhythmic events using the signal-averaged electrocardiogram, *Circulation*, vol. 95, 1386-1393, 1997.
- [57] GOMIS P., Jones DL., Caminal P., et al, Analysis of abnormal signals within the QRS complex of the high-Resolution ECG, *IEEE Trans. Biomed. Eng.*, vol. 44, 681-695, 1997.
- [58] SCHREIECK J., Ndrepepa G., Zrenner B., et al, Radiofrequency ablation of cardiac arrhythmias using a three-dimensional real-time position management, and mapping system, *Pacing. Clin. Electrophsiol.*, vol. 25, 1699-1707, 2002.
- [59] KHOURY D. S., Taccardi B., Lux R. L., et al, Reconstruction of endocardial potentials and activation sequences from intracavitary probe measurements: Localization of pacing sites and effects of myocardial structure, *Circulation*, vol. 91, 845-863, 1995.
- [60] HOEKAMA R., Uijen G. J., Stilli D., et al, Lead system transformation of body surface map data, *J. Electrocardiol.*, vol. 31, 71-82, 1998.
- [61] HOEKEMA R., Uijen G. J., Van Oosterom A., On selecting a body surface mapping procedure, *J. Electrocardiol.*, vol. 32, 93-101, 1999.
- [62] TACCARDI B., Punske B., Body Surface Potential Mapping, in *Cardiac Electrophysiology From Cell to Bedside*, Zipes D., and Jalife J., (Eds.), W. B: Saunders Co., 803-811, 2004.
- [63] TILG B., Fischer G., Modre R., et al, Model-based imaging of cardiac electrical activation in humans, *IEEE Trans. Med. Imaging.*, vol. 21, 1031-1039, 2003.
- [64] VIAS M, Segal O. R, Tondato F. and Peters N. S., Mapping, s 858-868.
- [65] JOHNSON J. R., MacLoad R. S., Ershler P. R., A Computer Model for the Study of Electrical Current Flow in the Human Thorax, *Comp. In Biology and Medicine*, vol. 22, 305-323, 1992.

- [66] SCHMIDT J.A., Johnson C.R., Eason J.A., ve MacLeod R.S.. Applications of Automatic Mesh Generation and Adaptive Methods in Computational Medicine., In J. Flaherty and I. Babuska, editors, Modeling, Mesh Generation, and Adaptive Methods for Partial Differential Equations, 367-394. Springer Verlag, 1994.
- [67] RUDY Y. ve Plonsey R., The Effects of Variations in Conductivity and Geometrical Parameters on the Electrocardiogram, Using an Eccentric Spheres Model, Circ. Res., vol 44, no.1, 104-111, 1979.
- [68] MACLEOD R.S., Taccardi B ve Lux R.L., The Influence of Torso Inhomogeneities on Epicardial Potentials, IEEE Computers in Cardiology, 793-796, 1994.
- [69] RUDY Y. and Plonsey R., The Effects of Variations in Conductivity and Geometrical Parameters on the Electrocardiogram, Using an Eccentric Spheres Model, Circ. Res., vol. 44, 104-111, 1979.
- [70] RUDY Y. and Messinger-Rapport B.J., The Inverse Solution in Electrocardiography: Solutions in Terms of Epicardial Potentials, CRC Crit. Rev. Biomed. Eng, vol. 16, 215-268, 1988.
- [71] STANLEY P.C., Pilkington T.C., ve Morrow M.N., The Effects of Thoracic Inhomogeneities on the Relationship Between Epicardial and Torso Potentials, IEEE Trans Biomed. Eng., vol. 33, 273-284, 1986.
- [72] PULLAN A., A High-Order Coupled Finite Element Torso Model, IEEE Trans Biomed. Eng., vol. 43, 292-298, 1996.
- [73] HAYKIN Simon, Neural Networks: A Comprehensive Foundation, second edition, Prentice Hall, 1999.
- [74] BROOKS D. H. ve MacLeod R. S., Electrical Imaging of the Heart, IEEE Signal Processing Magazine, 24-42, January, 1997.
- [75] BEZDEK, James C. (1981), Pattern Recognition with Fuzzy Objective Function Algorithms, ISBN 0306406713.

- [76] BASAK S.C., Magnuson V.R., Niemi C.J., Regal R.R. "Determining Structural Similarity of Chemicals Using Graph Theoretic Indices". *Discr. Appl. Math.*, vol. 19, 17-44, 1988.
- [77] GURNEY K., *An Introduction to Neural Networks*, CRC Press, Boca Raton, FL., 1997.
- [78] BATHEN, T. F., Engan, T., Krane, J., and Axelson, D., Analysis and classification of proton NMR spectra of lipoprotein fractions from healthy volunteers and patients with cancer or CHD. *ANTICANCER RESEARCH*, vol. 20, 2393–2408, 2000.
- [79] CHIOU, Y. S., Lure, Y. M. F., Ligomenides, P. A., Freedman, M. T. M. D., and Fritz, S. L., Shape feature analysis using artificial neural networks for improvements of hybrid lung nodule detection system. *Proc. SPIE—The International Society for Optical Engineering, Society of photo-optical instrumentation engineers*, vol. 18, 609–617, 1993.
- [80] BAREA, R., Boquete, L., Garcia, R., Mazo, M., Lopez, E., M., E., and J., R. F., ECG identification using self-organising maps, *Proceedings of NC 1998. International ICSC/IFAC Symposium on Neural Computation*, CSC Academic Press, Zurich, Switzerland, 378–83, 1998.
- [81] BRACCINI, G., Edenbrandt, L., Lagerholm, M., Peterson, C., Rauer, O., Rittner, R., and Sornmo, L., Self-organizing maps and Hermite functions for classification of ECG complexes, *Computers in Cardiology*, 425–8, 1997.
- [82] CAZUGUEL, G., Cziho, A., Solaiman, B., and Roux, C., Medical image compression and characterization using vector quantization: an application of self-organizing maps and quadtree decomposition, *IEEE International Conference on Information Technology Applications in Biomedicine*, 127–32, 1998.
- [83] FENG, M., Shaowei, X., Zesheng, T., Wenping, W., and Tsang, W. W., Probabilistic classification of medical images using a hybrid neural network, *Joint Conference on Intelligent Systems*, vol. 4, 222–5, 1999.

- [84] GOLZ, M., Sommer, D., Lembcke, T., and Kurella, B., Classification of pre-stimulus EEG of k-complexes using competitive learning networks, 6th European Congress on Intelligent Techniques and Soft Computing, vol. 3, 1767–71, 1998.
- [85] GROZINGER, M., Uhl, T., and Roschke, J., Kohonen feature maps in the online detection of REM sleep from single channel sleep EEG data, World Congress on Neural Networks, International Neural Network Society Annual Meeting, page 885, 1996.
- [86] FRANCESCO M. and Andrea S., A fuzzy clustering based segmentation system as support to diagnosis in medical imaging, Artificial Intelligence in Medicine vol. 16, 129-147, 1999.
- [87] DAO-QIANG Z. B. and Song-Can C., A novel kernelized fuzzy C-means algorithm with application in medical image segmentation, Artificial Intelligence in Medicine vol. 32, 37-50, 2004.
- [88] KEH-SHIH C., Hong-Long T., Sharon C., Jay W. and Tzong-Jer C., Fuzzy c-means clustering with spatial information for image segmentation, Computerized Medical Imaging and Graphic, vol. 30, 9-15, 2006.
- [89] OMIDVAR O. and L. Elliot, Neural Systems for Control, 1997.
- [90] LIN C., Lee G., Neural Fuzzy Systems, Prentice Hall, 1997.
- [91] MARCONI L., Scalia, F., Ridella S., Arrigo, P., Mansi C., Mela, G.S., An application of backpropagation to medical diagnosis, International Joint Conference on Neural Networks, IJCNN., 1127 – 113, 1989.
- [92] KORDYLEWSKI H., Graupe D., Kai Liu, A novel large-memory neural network as an aid in medical diagnosis applications, IEEE Transactions on Information Technology in Biomedicine, vol. 5, 202 – 209, 2001.
- [93] PIRAINO D., Kotsas P., Richmond, B., Recht, M., Kormos, D., Three dimensional image registration using artificial neural networks, IEEE International Conference on Computational Intelligence, vol. 6, 4017 – 4021, 1994.

- [94] WILSON D.W., Tsui B.M.W., Noise properties of filtered-backprojection and ML-EM reconstructed emission tomographic images, IEEE Transactions on Nuclear Science, 1198 – 1203, 1993.
- [95] DOĞAN M., babanlı A. ve Telçeken S., Yapay Sinir Ağları Yöntemleri ile Başağrısı Hastalıklarının Sınıflandırması, ELECO 2004, Bursa, vol. 1, 424-427, 2004.
- [96] HIRAIWA A., Shimohara K., Tokunaga Y., EEG topography recognition by neural networks, IEEE Engineering in Medicine and Biology Magazine, vol. 9, 1990.
- [97] ABDI H., In: "N.J. Salkind (Ed.): Encyclopedia of Measurement and Statistics, Thousand Oaks (CA): Sage. 270-275, 2007.
- [98] PERRIERE G. & J. Thioulouse, Use of Correspondence Discriminant Analysis to predict the subcellular location of bacterial proteins, Computer Methods and Programs in Biomedicine, vol. 70, 99-105, 2003.
- [99] RONALD Fisher, The Use of Multiple Measurements in Taxonomic Problems, Annals of Eugenics, vol. 7, 179-188, 1937.
- [100] MCLACHLAN, G. J., Discriminant Analysis and Statistical Pattern Recognition. Wiley Interscience. MR1190469. ISBN 0471691151, 2004.
- [101] MITSUO Gen, Runwei Cheng, Genetic Algorithms & Engineering Design, John Wiley & Sons, Inc., 1997.
- [102] GUANGRONG Li, Xiaohua Hu, Xiajiong Shen, Xin Chen, Zhoujun Li, A novel unsupervised feature selection method for bioinformatics data sets through feature clustering, IEEE International Conference on Granular Computing, vol. 41-47, 2008.
- [103] LIU H, Dougherty E.R, Dy, J.G, Torkkola K, Evolving feature selection, IEEE Intelligent Systems, 64-76, 2005 .
- [104] HUANG K, Aviyente S, Wavelet Feature Selection for Image Classification, IEEE Transactions on Image Processing, vol. 17, 1709-1720, 2008.

- [105] KIERNAN L, Kambhampati C, Mitchell R.J., Using self organising feature maps for feature selection in supervised neural networks, Fourth International Conference on Artificial Neural Networks, 195-200, 1995.
- [106] HUI-HUANG H., Ming-Da L., Feature Selection for Cancer Classification on Microarray Expression Data, Eighth International Conference on Intelligent Systems Design and Applications, 2008, vol. 3, 153-158, 2008.
- [107] CHANGJING Shang, Aiding neural network based image classification with fuzzy-rough feature selection, IEEE International Conference on Fuzzy Systems, 976-982, 2008.
- [108] LUX R.L., Karhunen-Loeve Representation of ECG Data, J. Electrocardiol., vol. 25, 190-195, 1992.
- [109] LUX R.L., Evans K., Burgess M.J., Wyatt R.F., ve Abildskov J.A., Redundancy Reduction for Improved Display and Analysis of Body Surface Potential Maps: I. Spatial Compression, Circ. Res., vol. 49, 186-196, 1981.
- [110] EVANS K., Lux R.L., Burgess M.J., Wyatt R.F., ve Abildskov J.A., Redundancy Reduction for Improved Display and Analysis of Body Surface Potential Maps: 11. Temporal Compression, Circ. Res., vol. 49, 197-203, 1981.
- [111] GREEN L.S., Lux R.L., ve Haws C.W., Detection and Localization of Coronary Artery Disease with Body Surface Mapping in Patients with Normal Electrocardiograms, Circ., vol. 76, 1290-1297, 1987.
- [112] HUBLEY-KOZEY C.L., Mitchell B., Gardner M.J., Warren J.W., Penney C.J., Spatial Features in Body Surface Potentials Maps Can Identify Patients with a History of Sustained Ventricular Tachycardia, Circ., vol. 92, 1825-1838, 1995.
- [113] KOMREICH F., Montague T.J., ve Rautaharju P.M., Body Surface Potential Mapping of ST Segment Changes in Acute Myocardial Infarction: Implications for ECG Enrollment Criteria for Thrombolytic Therapy, Circ.. vol. 87, no.3, 773, 1993.
- [114] KOSAMBI D. D., "Statistics in Function Space", Journal of the Indian Mathematical Society, vol 7, 76-88, 1987.

- [115] GUIKHMANN I., A. Skorokhod, Introduction a la Théorie des Processus Aléatoires Éditions MIR, 1977.
- [116] SIMON B., Functional Integration and Quantum Physics, Academic Press.
- [117] KARHUNEN K., Kari, Über lineare Methoden in der Wahrscheinlichkeitsrechnung, Ann. Acad. Sci. Fennicae. Ser. A. I. Math.-Phys., No. 37, 1–79, 1947.
- [118] GASTPAR M., P. L. Dragotti and M. Vetterli, The Distributed Karhunen-Loeve Transform, IEEE Trans. Inform. Theory, vol. 5, 150-152, 2003.
- [119] KOHAVI, Ron, Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence, vol. 2, 1137–1143.(Morgan Kaufmann, San Mateo), 1995.
- [120] DEVIJVER, P. A., and J. Kittler, Pattern Recognition: A Statistical Approach, Prentice-Hall, London, 1982
- [121] MOSTELLER, Frederick, A k-sample slippage test for an extreme population, Annals of Mathematical Statistics, vol. 9, 55-58, 1998.
- [122] MCLACHLAN GJ.; K.A. Do, C. Ambrose, Analyzing microarray gene expression data, Wiley, 2004.
- [123] KOHAVI R., A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection, International Joint Conference on Artificial Intelligence, 179-185, 1995.
- [124] DAVIES D.L. and D.W. Bouldin, A cluster separation measure, IEEE Trans. Pattern Anal. Machine Intell., vol. 1, 224-227, 1979.
- [125] DUNN J.C., A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters, J. Cybern., vol. 3, 32-57, 1973.
- [126] BEZDEK J.C. and N.R. Pal, Some new indexes of cluster validity, IEEE Trans. Syst. Man. Cybern., vol. 28, 301-315, 1998.

- [127] MILLIGAN G.W., Clustering validation: Results and implications for applied analyses, In P. Arabie, L.J. Hubert and G. De Soete (Eds.), Clustering and Classification, Singapore: World Scientific, 341-375, 1996.
- [128] MILLIGAN G.W. and M.C. Cooper, An examination of procedures for determining the number of clusters in a data set, Psychometrika, vol. 50, 159-179, 1985.
- [129] COOPER M.C. and G.W. Milligan, The effect of measurement error on determining the number of clusters in cluster analysis, In W. Gaul and M. Schader (Eds.), Data, Expert Knowledge and Decisions, Berlin: Springer-Verlag, 319-328, 1988.
- [130] PAL N.R. and J.C. Bezdek, On cluster validity for the fuzzy c-means model, IEEE Trans. Fuzzy Systems, vol. 3, 370-379, 1995.
- [131] RAY S. and R.H. Turi, Determination of Number of Clusters in K-Means Clustering and Application in Colour Image Segmentation, Proceedings of the 4th International Conference on Advances in Pattern Recognition and Digital Techniques, ISBN: 81-7319-347-9, 137-143, 1995.
- [132] YILMAZ B., MacLeod R. S., Punske B. B., Brooks D. H., Venous Catheter Based mapping of Ectopic Epikardial Activation: Training Data Set Selection for Statistical Estimation, IEEE Transactions on Biomedical Engineering, vol.52, no.11, 1823-1831, 2005.
- [133] ERSHLER p. R., B. W. Steadman, K. B. Moore, and R. L. Lux., Systems for measuring and tracking electrophysiologic distributions: Current tools for clinical and experimental cardiac mapping, IEEE Transactions on Biomedical Engineering, vol. 17, 56–61, 1998.
- [134] ALIEV R.R., Panfilov A.V., A simple two-variable model of cardiac excitation, Chaos, Solutions and Fractals, vol: 7, 293-301, 1996.
- [135] YILMAZ B., Tubitak Raporu, 2009.

- [136] NIELSON P. M. F., LeGrice I. J. , Smail B. H. , P. J. Hunter, A Mathematical model of the geometry and fibrous structure of the heart, *Am. J. Physiol.* Vol. 260, 1365 – 1378, 1991.
- [137] SIMELIUS K., Reinhardt L., Jokiniemi T., Nenonen J., Tierala I., Toivonen L., and Katila T, Classification of body surface potential map sequences during ventricular activation using Kohonen Networks, *Proceedings of the 20th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, vol. 20, 1344–1347, 1998.
- [138] SIMELIUS K., Reinhardt L., Nenonen J., Tierala I., Mäkijärvi M., Toivonen L., and Katila T, Source localization of ventricular arrhythmias using self-organizing neural networks. *Computers in Cardiology*, vol. 26, 331–334, 1999.
- [139] TANAWUT T., Thanokorn N., Chartchalerm I. N., Mark J. E., Virapong PP, Identification of ischemic heart disease via machine learning analysis on magnetocardiograms, *Computers in Biology and Medicine*, vol. 38, 817-825, 2008.
- [140] OZBAY Y., Ceylan R., Karlik B., A fuzzy clustering neural network architecture for classification of ECG arrhythmias, *Computers in Biology and Medicine*, vol.36, 376-388, 2006,
- [141] MUHAMMAD A., Akram M., U., Amir F., Pruned fuzzy K-nearest neighbor classifier for beat classification, *Journal of Biomedical Science and Engineering (JBiSE)*, vol. 13, 331-340, 2010.
- [142] YUN-CHI Y., Wen-June Wang, Che Wun Chiou, Cardiac arrhythmia diagnosis method using linear discriminant analysis on ECG signals, *Journal of measurements*, vol. 42, 778-789, 2009.
- [143] SONG M., H., , Jeon L., Sung P. C., Kyoung J., Sun K., Y., Support Vector Machine Based Arrhythmia Classification Using Reduced Features, *International Journal of Control, Automation, and Systems*, vol. 3, 571-579, 2005.