



**KALP KASI KANLANMASININ GÖRÜNTÜLENMESİNDE (MİYOKARD
PERFÜZYON SİNTİGRAFİSİ) DOKU ENGELLEMELERİNİN
SINIFLANDIRMA YÖNTEMLERİ İLE GİDERİLMESİ**

Mahmut BÜYÜKBAŞ

**DOKTORA TEZİ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

NİSAN 2021

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Mahmut BÜYÜKBAŞ

02/04/2021

KALP KASI KANLANMASININ GÖRÜNTÜLENMESİNDE (MİYOKARD
PERFÜZYON SİNTİGRAFİSİ) DOKU ENGELLEMELERİNİN SINIFLANDIRMA
YÖNTEMLERİ İLE GİDERİLMESİ

(Doktora Tezi)

Mahmut BÜYÜKBAŞ

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Nisan 2021

ÖZET

Koroner anjiyografi, koroner arter hastalığının neden olduğu miyokard iskemisinin (Mİ) teşhisinde altın standart olarak kabul edilir; fakat bu yöntemin bazı dezavantajları ve ölümle bile sonuçlanabilecek bazı medikal riskleri vardır. Buna karşı, medikal görüntüleme metotlarından biri olan bilgisayarlı tek foton emisyon tomografisi (SPECT) ile kalp kanlanmasının görüntülenmesi, girişimsel bir işlem olmayıp, uygun maliyetli ve uygulanması kolay bir yöntemdir. Fakat bu metot, kadınlarda meme atenuasyonu olan durumlarda yetersiz kalabilir ve yanlış teşhise neden olabilir. Bu çalışmada, bu spesifik durumun yorumlanmasını geliştirmek ve kolaylaştırmak için bilgisayar destekli teşhis temelli modeller geliştirildi. Bu modelleri geliştirebilmek için ilgi bölgeleri belirlendi ve bu bölgelere ait özellikler çıkartıldı. Sonrasında farklı gözetimli sınıflandırma metotları uygulandı. Denenen bütün kombinasyonlar arasında en yüksek doğruluk oranı %91,358, en yüksek eğri altında kalan alan (AUC) 0,904 olarak elde edildi. Aynı zamanda, hastaların vücut kitle indeksleri hesaplandı ve hastalar bu endekslere göre üç gruba ayrıldı. Bu gruplar için daha yüksek doğruluk oranları ve daha büyük eğri altında kalan alanlar elde edildi. Elde edilen bütün bu sonuçlar 10-kat çapraz doğrulama yöntemiyle doğrulandı. Geliştirilen bu yöntem miyokard perfüzyon sintigrafisi (MPS) sonucuna göre Mİ şüphesinin meme atenuasyonu kaynaklı olabileceği değerlendirilen durumlarda koroner anjiyografi istemeden önce klinisyene karar aşamasında yardımcı olabilir.

Bilim Kodu : 90539
Anahtar Kelimeler : Medikal görüntüleme, meme atenuasyonu, doku özellikleri, özellik seçimi, sınıflandırma
Sayfa Adedi : 163
Danışman : Doç. Dr. Süleyman Sungur TEZCAN
İkinci Danışman : Doç. Dr. Seyhan KARAÇAVUŞ

ELIMINATION OF TISSUE ATTENUATION WITH CLASSIFICATION METHODS
ON MYOCARDIAL PERFUSION IMAGING (MYOCARDIAL PERFUSION
SCINTIGRAPHY)

(Ph. D. Thesis)

Mahmut BÜYÜKBAŞ

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

April 2021

ABSTRACT

Coronary angiography is considered as the gold standard for diagnosis of myocardial ischemia (MI) that is caused by coronary artery disease (CAD); but this method has some disadvantages and medical risks that could end up with death. One of the medical imaging ways; imaging myocardial perfusion with SPECT (single photon emission computed tomography) is non-invasive, cost-effective and easy to perform method. However, this method can be insufficient when breast attenuation exists for women and can cause wrong diagnosis. In order to develop and make easier interpretation of this specific instance, new computer-assisted diagnosis based models have been developed. In order to develop these models, regions of interest (ROI) are selected and features belong to these regions are extracted. After that, various supervised classification methods are applied. Among all tried combinations, best classification accuracy has been obtained as 91.358% with 0,904 AUC (Area Under Curve). Also body mass indexes of patients are computed and patients are divided into three groups according to these indexes. For these groups, higher classification rates and larger areas under curve (AUC) are obtained. . All these results have been validated by 10-fold Cross-Validation (CV). This developed model could help clinicians on the step of decision before asking angiography, for patients arriving on suspicion of MI on conditions considered breast attenuation in myocardial perfusion scintigraphy (MPS).

Science Code : 90539

Key Words : Medical imaging, breast attenuation, texture features, feature selection, classification

Page Number : 163

Supervisor : Assoc. Prof. Dr. Süleyman Sungur TEZCAN

Co-Supervisor : Assoc. Prof. Dr. Seyhan KARAÇAVUŞ

TEŞEKKÜR

Tezimi nihai sonuca ulaştırmamda çok büyük emek ve katkıları olan kıymetli hocalarım Doç. Dr. Süleyman Sungur TEZCAN' "Gazi Üniversitesi", Prof. Dr. Özgül SALOR DURNA "Gazi Üniversitesi" ve Doç. Dr. Seyhan KARAÇAVUŞ'a "Sağlık Bilimleri Üniversitesi" sonsuz minnetlerimi sunarım. Bugüne kadar gelmemde çok büyük emekleri olan kıymetli aileme ve eşim Yağmur BÜYÜKBAŞ'a, yılmadan usanmadan emeklerini hiçbir zaman esirgemedikleri ve her zaman yanımda oldukları için teşekkür ederim. Son olarak, tez çalışmam sırasında bilgilerinden yararlandığım çok değerli arkadaşlarım aynı zamanda meslektaşlarım Fatih ALTINDİŞ ve Oğuzhan AYYILDIZ'a teşekkür ederim.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	xii
SİMGELER VE KISALTMALAR.....	xv
1. GİRİŞ.....	1
2. GENEL BİLGİLER	7
2.1. Miyokard İskemisi ve Teşhis Yöntemleri.....	7
2.2. Görüntü ve SPECT Görüntüleme	9
2.2.1. Görüntü.....	9
2.2.2. SPECT görüntüleme	12
2.2.3. Miyokard perfüzyon sintigrafisi (MPS)	17
2.3. Atenüasyon Fenomeni ve Buna Bağlı Problemler.....	23
2.3.1. Atenüasyon düzeltilmesi.....	24
2.3.2. Meme atenüasyonu	28
2.4. Görüntüde Doku Analizi.....	29
2.4.1. Verilerin elde edilmesi	31
2.4.2. Görüntü bölütleme (segmentasyon).....	32
2.4.3. Doku özelliklerinin çıkarılması	37
2.4.4. Özellik seçimi	74
2.4.5. Gözetimli makine öğrenmesi ve sınıflandırma.....	78
2.4.6. Sınıflandırma performansının değerlendirilmesi.....	86

Sayfa

3. YÖNTEM	91
3.1. Sınıflandırma Modelinin Oluşturulması	91
3.1.1. Veri alımı	91
3.1.2. Görüntü bölütleme (Segmentasyon)	92
3.1.3. Özellik çıkarma	94
3.1.4. Özellik seçimi	105
3.1.5. Sınıflandırma	106
3.1.6. Sınıflandırma performansının değerlendirilmesi	108
4. SONUÇ VE ÖNERİLER	113
4.1. Birinci Modelin Sonuçları	113
4.2. İkinci Modelin Sonuçları	120
4.3. Üçüncü Modelin Sonuçları	135
4.4. Dördüncü Modelin Sonuçları	137
4.5. Beşinci Modelin Sonuçları	139
4.6. Vücut Kitle İndeksi Odaklı Yapılan Çalışmalar	144
KAYNAKLAR	153
ÖZGEÇMİŞ	162

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 1.1. Kardiyak katerizasyon ve koroner anjiyografinin riskleri	1
Çizelge 2.1. Miyokard iskemisi ve koroner kan akımı için teşhis yöntemleri.....	8
Çizelge 2.2. K-nn uzaklık metriklerinin formülasyonları	83
Çizelge 2.3. Öğrenme algoritmalarının karşılaştırılması	86
Çizelge 2.4. Farklı doğulama yöntemlerinin avantajları ve dezavantajları	88
Çizelge 3.1. Radiomics ve Pyradiomics modellerinin çıkardıkları özelliklerin sayısal olarak karşılaştırılması	95
Çizelge 3.2. Çalışmamızdaki görüntülerden çıkarılan birinci derece istatistikler	96
Çizelge 3.3. Çalışmamızdaki görüntülerden çıkarılan GLCM özellikleri	98
Çizelge 3.4. Çalışmamızdaki görüntülerden çıkarılan GLRLM özellikleri.....	100
Çizelge 3.5. Çalışmamızdaki görüntülerden çıkarılan GLSZM özellikleri	102
Çizelge 3.6. Çalışmamızdaki görüntülerden çıkarılan GLDM özellikleri	104
Çizelge 3.7. Çalışmamızdaki görüntülerden çıkarılan şekil tabanlı özellikler	104
Çizelge 3.8. Hata matrisi.....	109
Çizelge 3.9. Hata matrisinden elde edilen performans değerlendirme kriterlerinin formülasyonları	110
Çizelge 4.1. k-NN sınıflandırıcı ile farklı parametrelerle elde edilen sonuçlar	114
Çizelge 4.2. %81,48 doğruluk için k-NN ile elde edilen hata matrisi	115
Çizelge 4.3. %81,4815 doğruluk için k-nn ile elde edilen performans değerlendirme kriterleri	115
Çizelge 4.4. Naive Bayes sınıflandırıcısı ile elde edilen performans değerlendirme kriterleri	116
Çizelge 4.5. Naive Bayes sınıflandırıcısı ile elde edilen hata matrisi.....	117
Çizelge 4.6. Yapay sinir ağları ile farklı parametrelerle elde edilen sonuçlar	118
Çizelge 4.7. Yapay Sinir Ağları ile elde edilen performans değerlendirme kriterleri	119
Çizelge 4.8. Yapay Sinir Ağları ile elde edilen hata matrisi.....	119

Çizelge	Sayfa
Çizelge 4.9. k-NN sınıflandırıcı ve WS özellik seçimi yöntemiyle elde edilen doğruluk oranları	120
Çizelge 4.10. %85,19 doğruluk oranı elde edilen yönteme ait hata matrisi	121
Çizelge 4.11. %85,19 doğruluk oranı elde edilen yönteme ait performans değerlendirme kriterleri	121
Çizelge 4.12. Matlab ile normalize edilen verilerin sonuçları	121
Çizelge 4.13. YSA ve Naive Bayes sınıflandırıcı ile elde edilmiş sonuçlar	122
Çizelge 4.14. Görüntülere Wiener 3x3 filtresinin uygulanması sonrası k-NN sınıflandırıcı ve 10-kat çapraz doğrulama kullanılarak elde edilen doğruluk oranları	123
Çizelge 4.15. Görüntülere Wiener 5x5 filtresinin uygulanması sonrası k-NN sınıflandırıcı ve 10-kat çapraz doğrulama kullanılarak elde edilen doğruluk oranları	125
Çizelge 4.16. Wiener netleştirme işlemi sırasında en yüksek başarı oranı elde edilmesinde kullanılan yöntemler ve doğruluk oranları	130
Çizelge 4.17. Histogram eşitleme sonrası sınıflandırma için kullanılan yöntemler ve doğruluk oranları	131
Çizelge 4.18. Karekök sonrası sınıflandırma için kullanılan yöntemler ve doğruluk oranları	132
Çizelge 4.19. Küpkök sonrası sınıflandırma için kullanılan yöntemler ve doğruluk oranları	133
Çizelge 4.20. Kontrast ayarlama sonrası sınıflandırma için kullanılan yöntemler ve doğruluk oranları	134
Çizelge 4.21. k-NN sınıflandırıcı ve SFFS özellik seçimi yöntemi kullanılarak elde edilen doğruluk oranları	136
Çizelge 4.22. Özelliklerin 0-1 arası normalize edilmesiyle k-NN sınıflandırıcı, WS özellik seçimi yöntemleri kullanılarak elde edilen doğruluk oranları	136
Çizelge 4.23. %87,65 doğruluk oranı elde edilen yönteme ait hata matrisi	136
Çizelge 4.24. %87,65 doğruluk oranı elde edilen yönteme ait performans değerlendirme kriterleri	137
Çizelge 4.25. k-NN sınıflandırıcı, WS özellik seçimi yöntemleri kullanılarak elde edilen doğruluk oranları	138
Çizelge 4.26. %91,36 doğruluk oranı elde edilen modele ait hata matrisi	138

Çizelge	Sayfa
Çizelge 4.27. %91,36 başarı oranı elde edilen modele ait performans değerlendirme kriterleri	138
Çizelge 4.28. Filtresiz orijinal özelliklerin ve onun harici diğer tüm özelliklerin kullanılmasına ait sonuçlar	140
Çizelge 4.29. Gauss'un laplası filtresi sonucu elde edilen özellikler ve onun harici diğer tüm özelliklerin kullanılmasına ait sonuçlar	140
Çizelge 4.30. Wavelet filtresi sonucu elde edilen özellikler ve onun harici diğer tüm özelliklerin kullanılmasına ait sonuçlar	140
Çizelge 4.31. Kare filtresi sonucu elde edilen özellikler ve onun harici diğer tüm özelliklerin kullanılmasına ait sonuçlar	141
Çizelge 4.32. Karekök filtresi sonucu elde edilen özellikler ve onun harici diğer tüm özelliklerin kullanılmasına ait sonuçlar	141
Çizelge 4.33. Logaritma filtresi sonucu elde edilen özellikler ve onun harici diğer tüm özelliklerin kullanılmasına ait sonuçlar.....	142
Çizelge 4.34. Eksponansiyel filtresi sonucu elde edilen özellikler ve onun harici diğer tüm özelliklerin kullanılmasına ait sonuçlar	142
Çizelge 4.35. Gradyan filtresi sonucu elde edilen özellikler ve onun harici diğer tüm özelliklerin kullanılmasına ait sonuçlar	142
Çizelge 4.36. LBP filtresi sonucu elde edilen özellikler ve onun harici diğer tüm özelliklerin kullanılmasına ait sonuçlar	143
Çizelge 4.37. %91,36 doğruluk oranı elde edilen modele ait hata matrisi	143
Çizelge 4.38. %91,36 doğruluk oranı elde edilen modele ait performans değerlendirme kriterleri	143
Çizelge 4.39. BMI bilgisi içeren veri setini dağılımı ve BMI ortalamaları	145
Çizelge 4.40. Hastaların vücut kitle endekslerine göre gruplandırılması	145

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Mİ olan bir hastaya ait MPS görüntüsü	3
Şekil 1.2. Mİ olmayıp meme atenüasyonu olan bir hastaya ait MPS görüntüsü	3
Şekil 2.1. (a) Görüntü matrisinin koordinat sistemi güncellemesinden önceki gösterimi (b) görüntü matrisinin koordinat sistemi güncellemesinden sonraki gösterimi	10
Şekil 2.2. (a) İkili görüntü (b) gri seviye görüntü (c) renkli görüntü.....	11
Şekil 2.3. SPECT bölümleri.....	14
Şekil 2.4. Yönlendirici ve ön-yükselteç arası birimler	16
Şekil 2.5. 55 yaşındaki bir erkeğe ait normal bir MPS	20
Şekil 2.6. Üç farklı hastadaki miyokard perfüzyonunun büyüklüğü ya da boyutu.....	21
Şekil 2.7. Üç farklı hastadaki miyokard perfüzyonunun büyüklüğü ya da boyutu.....	21
Şekil 2.8. Üç farklı hastadaki miyokard perfüzyonunun büyüklüğü ya da boyutu.....	22
Şekil 2.9. Tipik göğüs ağrısına sahip 71 yaşındaki bir erkeğe ait perfüzyon bozulmasının şiddeti.....	22
Şekil 2.10. Kadınlarda meme dokusu	28
Şekil 2.11. (a) Aynı siyah ve beyaz dağılımlara sahip üç farklı doku örneği ve (b) histogramı	30
Şekil 2.12. Sınıflandırma modelinin oluşturulmasındaki iş akış şeması	31
Şekil 2.13. Eşikleme teknikleri	33
Şekil 2.14. İstatiksel tabanlı özellikler.....	39
Şekil 2.15. (a) Örnek bir görüntü matrisi (b) Bu matris için oluşturulmuş gri-seviye eş oluşturma matrisi	44
Şekil 2.16. (a) Örnek bir I matrisi (b) I matrisine ait gri seviye koşu uzunluğu matrisi .	52
Şekil 2.17. (a) Örnek bir I matrisi (b) I matrisine ait gri seviye büyüklük alan matrisi .	57
Şekil 2.18. (a) Örnek bir görüntü matrisi ve (b) bu görüntüye ait komşuluk gri ton fark matrisi.....	62
Şekil 2.19. (a) Örnek bir görüntü matrisi ve (b) bu görüntüye ait gri seviye bağlılık matrisi	65

Şekil	Sayfa
Şekil 2.20. Sıralı ileri hareketli seçme algoritmasının akış diyagramı	77
Şekil 2.21. Gözetimli makine öğrenmesinin akış diyagramı	79
Şekil 2.22. Destek vektör makineleri sınıflandırıcısı.....	82
Şekil 2.23. 5-kat çapraz doğrulama örneği	87
Şekil 3.1. Ham görüntüden ilgi alanının (ROI) elde edilmesi: (1) ham görüntü (2) 21x21 boyutlu önceden belirlenen bölge (3) Otsu metodundan sonra (4) morfolojik işlemler sonrası (5) ilgi alanı (ROI).....	92
Şekil 3.2. (a) Bir hastaya ait ham kesit görüntüsü (b) ham görüntüden otomatik olarak elde edilen ROI.....	93
Şekil 3.3. (a) Bir hastaya ait ham kesit görüntüsü (b) ham görüntüdeki ROI'nin işaretlenmesi (c) elde edilen bölgenin ham görüntüdeki pozisyonu.....	93
Şekil 3.4. Merkez voksellle ilişkili 26 komşuluğun gösterimi.....	97
Şekil 3.5. 26 komşuluğun 3 boyutlu gösterimi	97
Şekil 3.6. (a) GLCM örneği (b) GLCM'ye ait simetrik benzerlikler.....	98
Şekil 3.7. (a) Örnek bir doku matrisi (b) bu doku için gri seviye koşu uzunluğu matrisi oluşturulması	99
Şekil 3.8. (a) Örnek bir doku matrisi ve (b) bu dokuya ait gri seviye büyüklük alan matrisi	101
Şekil 3.9. (a) Örnek bir doku matrisi ve (b) bu dokuya ait komşuluk gri ton fark matrisi	103
Şekil 3.10. k=3 komşulukla örneğin sınıfının belirlenmesi	108
Şekil 3.11. k-kat çapraz doğrulama yönteminin uygulanması	109
Şekil 4.1. %81,48 doğruluk için k-NN ile elde edilen ROC eğrisi (AUC=0,813).....	115
Şekil 4.2. Naive Bayes sınıflandırıcısı ile elde edilen ROC eğrisi	116
Şekil 4.3. YSA ile elde edilen ROC eğrisi (AUC=0,714)	119
Şekil 4.4. Filtre işlemleri öncesi bir hastaya ait 32 farklı ham projeksiyon görüntüsü...	122
Şekil 4.5. Wiener 3x3 filtresinin ham görüntüye uygulanması sonrası elde edilen görüntü.....	124
Şekil 4.6. Wiener 5x5 filtresinin ham görüntüye uygulanması sonrası elde edilen görüntü.....	126

Şekil	Sayfa
Şekil 4.7. Wiener 5x45 bir nokta yayma fonksiyonuyla ile ham görüntünün bulanıklaştırılması	127
Şekil 4.8. Wiener ile bulanıklaştırılmış görüntünün netleştirilmiş hâli	128
Şekil 4.9. Wiener 21x11 bir nokta yayma fonksiyonuyla ile ham görüntünün bulanıklaştırılması	129
Şekil 4.10. Wiener ile bulanıklaştırılmış görüntünün netleştirilmiş hâli	130
Şekil 4.11. Histogram eşitleme sonrası elde edilen görüntü	131
Şekil 4.12. Karekök işlemi sonrası elde edilen görüntü	132
Şekil 4.13. Küpkök işlemi sonrası elde edilen görüntü	132
Şekil 4.14. (a) Bir hastaya ait 32 farklı projeksiyonlu ham görüntü (b) ham görüntünün kontrastının ayarlanmış hâli	133
Şekil 4.15. (a) Farklı bir hastaya ait 32 farklı projeksiyonlu ham görüntü (b) ham görüntünün kontrastının ayarlanmış hâli	134
Şekil 4.16. %87,65 doğruluk oranı elde edilen yöntemle ait ROC eğrisi (AUC= 0,864)	137
Şekil 4.17. %91,36 doğruluk oranı elde edilen modele ait ROC eğrisi (AUC= 0,910)..	139
Şekil 4.18. %91,36 doğruluk oranı elde edilen modele ait ROC eğrisi (AUC= 0,904)..	144
Şekil 4.19. Bütün özelliklerin kullanıldığı WS özellik seçim metoduyla seçilen özellikler sonucu elde edilen ROC eğrileri	148
Şekil 4.20. Wavelet filtresi sonucu elde edilen özelliklerin kullanıldığı WS özellik seçim metoduyla seçilen özellikler sonucu elde edilen ROC eğrileri	149
Şekil 4.21. Bütün özelliklerin kullanıldığı SFFS özellik seçim metoduyla seçilen özellikler sonucu elde edilen ROC eğrileri	150
Şekil 4.22. Wavelet filtresi sonucu elde edilen özelliklerin kullanıldığı SFFS özellik seçim metoduyla seçilen özellikler sonucu elde edilen ROC eğrileri	151

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

eV	Elektronvolt
k	Kilo
kg	Kilogram
m	Metre

Açıklamalar

Kısaltmalar

AUC	Area Under Curve
BMI	Body Mass Index
CAD	Coronary Artery Disease
CT	Computed Tomography
CV	Cross Validation
GLCM	Gray Level Co-occurrence Matrix
GLDM	Gray Level Dependence Matrix
GLRLM	Gray Level Run Length Matrix
GLSZM	Gray Level Size Zone Matrix
KAG	Koroner Anjiyografi
k-NN	k-Nearest Neighbour
Mİ	Miyokard İskemisi
MPS	Miyokard Perfüzyon Sintigrafisi
MRI	Magnetic Resonance Imaging
NB	Naive Bayes
NGTDM	Neighbouring Gray Tone Difference Matrix
PET	Positron Emission Tomography
ROI	Region of Interest
SFFS	Sequential Forward Floating Selection
WS	Wolf Search

1. GİRİŞ

Miyokard İskemisi (Mİ), kalp kasına kan akımını sağlayan damarların kısmi ya da tamamen tıkanması sonucunda ortaya çıkan bir kalp hastalığıdır [1]. Bu tıkanma neticesinde kalp kasına giden oksijen miktarı azalacağından kalp kası işlevini tam olarak yerine getiremez ve pompalaması gereken miktarda kan pompalayamaz. Mİ, kalp krizi ve ritim bozukluğu gibi durumlara sebep olabileceğinden tespiti son derece hayati önem arz etmektedir [2].

Mİ'nin teşhisinde koroner anjiyografi altın standart olarak kabul edilmektedir [3]. Bu yöntem kardiyak kateter sayesinde kalbin sol karıncığını besleyen damarlara girişimsel olarak ulaşp, bu damarların tıkanıklık durumunu belirleyen bir yöntemdir. Fakat bu yöntem invaziv yani girişimsel bir yöntem olduğu için, ölüme kadar varabilecek bazı ciddi riskler taşımaktadır. Bu riskler ve gerçekleşme olasılıkları Çizelge 1.1'de verilmiştir [4,5].

Çizelge 1.1. Kardiyak katerizasyon ve koroner anjiyografinin riskleri

	%
Ölüm	0,11
Miyokard enfarktüsü	0,05
Serebrovasküler olay	0,07
Aritmi	0,38
Vasküler komplikasyonlar	0,43
Kontrast reaksiyonlar	0,37
Hemodinamik komplikasyonlar	0,26
Kalp odalarında delinme	0,03
Diğer komplikasyonlar	0,28
Ana komplikasyonların toplamı	1,70

Koroner anjiyografinin taşıdığı medikal risklerinin yanında bazı dezavantajları da bulunmaktadır. Uygulanması zor bir işlem olduğu için her zaman uzman doktor kontrolünde yapılmak zorundadır. Maliyet açısından yüksektir [6]. İşlemin girişimsel olması sebebiyle uygulama sırasında hasta konforunun düşük olmasının yanı sıra işlem sonrası kanama olmaması için hastanın hastaneden hemen ayrılamaması da hasta konforunu ciddi biçimde düşürmektedir [7]. Aynı zamanda, hastanın damarları, X-ışını ile görüntülendiğinden hasta radyasyona maruz kalmaktadır. Ayrıca bu görüntülemenin


yapılabilmesi için bir kontrast maddenin ilgili bölgeye enjekte edilmesi gerekir ki bu maddelerin de çeşitli yan etkileri olabilir [8].

Miyokard iskemisinin teşhisinde koroner anjiyografi her ne kadar altın standart olarak kabul edilse de, sahip olduğu medikal risk ve dezavantajlarından dolayı zorunlu olmadıkça ilk tercih edilen yöntem olmayabilir. Kalp kası kanlanması görünülmesinde birçok yöntem mevcuttur. Bu yöntemlerden en etkili ve en sık tercih edilenlerden bir tanesi de SPECT (single photon emission computed tomography) isimli cihaz yardımıyla gerçekleştirilen miyokard perfüzyon sintigrafisidir (MPS) [9].


SPECT, vücuda verilen çeşitli radyofarmasötiklerin yaydıkları tek foton gama ışınlarının bir gama kamera tarafından algılanıp ilgili bölgenin fizyolojisi hakkında bilgi edinilmesini sağlayan bilgisayar destekli bir tomografi yöntemidir. Bu yöntem, girişimsel bir işlem olmaması, uygulanmasının ve ulaşılabilirliğinin kolay olması ve ilgili bölgenin fizyolojisi hakkında tatmin edici bilgi vermesi sebebiyle tercih edilen bir yöntemdir. MPS ise SPECT ile kalp kası kanlanması görünülmesinin özel adıdır. Bu işlemde, radyofarmasötik olarak genelde ^{99m}Tc -sestamibi kullanılır. Bu madde vücuda enjekte edildikten sonra kalp kasına damarın tıkanıklık durumuyla orantılı olarak ulaşır orada gama ışınları yapar. Bu ışınlar SPECT tarafından algılanıp, kalp kasının kanlanma görüntüsü elde edilir [10]. SPECT MPS, koroner arter hastalığının tanısı, tedavi yaklaşımını belirleme ve prognoz tayininde önemli bir yere sahiptir [1].

Bu yöntemde hastalar düşük de olsa radyasyona maruz kalmaktadır [11]. MPS çoğu insan için güvenlidir, sadece hamilelerde bebeklere zararlı olabileceği için işlem öncesi doktora bilgi verilmesi gerekmektedir. Bunun yanında geleneksel protokolün tamamlanması 3-5 saat kadar sürmektedir [12]. Bu tetkikin sensitivite ve spesifitesini düşüren bazı faktörler (hasta hazırlığı sırasında yapılan hatalar, işleme (processing) sorunları, kameraya bağlı etkenler, hasta hareketi vb.) olmakla birlikte en önemlisi doku atenuasyonudur [13]. MPS, teşhis için genelde iyi sonuçlar vermesine rağmen gama ışınlarının vücuttaki seyri esnasında yağ doku, meme veya diyafram gibi doku engellemelerinin olduğu durumlarda ilgili bölgeden yayılan gama ışınlarının SPECT dedektörüne ulaşmasında azalma olacağı için, kalp kasındaki kanlanmada bir problem olmamasına rağmen sanki hipoperfüzyon yani yetersiz kanlanma görüntüsü elde edileceğinden bazen yanlış teşhis konulmasına ya da

yetersiz kalmasına sebep olmaktadır. Bu durum özellikle kadınlardaki meme dokusundan kaynaklı ortaya çıkmaktadır [14].



Şekil 1.1. Mİ olan bir hastaya ait MPS görüntüsü



Şekil 1.2. Mİ olmayıp meme atenuasyonu olan bir hastaya ait MPS görüntüsü

Şekil 1.1 ve Şekil 1.2’de sırasıyla Mİ ve meme atenüasyonu olan hastalara ait iki ve üç boyutlu görüntülerle birlikte perfüzyon durumunu gösteren spektrum verilmiştir. Görüldüğü gibi görsel olarak yorumlandığında her iki görüntü için de Mİ değerlendirmesi yapılabilir fakat koroner anjiyografi sonrası Şekil 1.2’deki görüntünün aslında doku atenüasyonu olduğu tespit edilmiştir. Bu teşhisin sadece görüntünün yorumlanması sonucu yapılamamasından dolayı bu çalışmanın önemi burada daha belirgin bir şekilde ortaya çıkmaktadır.

Daha önceden bu problemi ortadan kaldırmak için, hasta ve meme pozisyonunu değiştirmek, CT (computed tomography) ile atenüasyonu ortadan kaldırmaya çalışmak gibi çeşitli yöntemler kullanılmıştır [13]. Buna rağmen halen başarı oranı yüksek olan standart bir metot bulunamamıştır [15].

Atenüasyonun fiziksel temelleri, enjekte edilen radyofarmasötiklerden yayılan fotonların vücuttan geçişi sırasında farklı dokularla etkileşimi üzerine dayanmaktadır. Foton enerjisinin bir kısmı absorbe edilir.

Ortaya çıkan bu durumda atenüasyon düzeltilmesi yapılması gerekmektedir. Atenüasyon düzeltilmesinin hangi yöntemle yapılacağı ise bölgenin düzenli (uniform) ya da düzensiz (nonuniform) olmasına göre değişir. Atenüasyon olan bölge genellikle düzenli ise sabit ve uzamsal bir bağımsız olan atenüasyon katsayısı μ_t görüntülenen organ boyunca kullanılabilir [16]. Bu metotta atenüasyon katsayı faktörü, organın içindeki her noktadan farklı projeksiyon açılarıyla dolaşan fotonların ortalama atenüasyonundan hesaplanır.

$$I(t) = I_0 \exp\left(-\int_0^t \mu_t(x,y)dl\right) \quad (1.1)$$

Eş. 1.1’de $I(t)$ soğurucu maddeden çıktıktan sonraki ışın yoğunluğunun zamana bağlı değişimini ifade etmektedir. Burada, I_0 soğurucu maddeye girmeden önceki ışın yoğunluğu, $\mu_t(x,y)$ x ve y koordinatlarındaki atenüasyon katsayısı, dl atenüasyonun gerçekleştiği mesafenin değişimi ve t zamandır [17].

Atenüasyon olan bölge farklı doku tiplerinden oluşabilir. Bu yüzden, organın her bir bölümünün farklı lineer atenüasyon katsayıları vardır ve yüksek oranda uzamsal

bağımlıdır. Dolayısıyla, μ_t , x sabit bir değer olarak düşünülemez ve bu bölge düzensiz olarak nitelendirilir. Bizim çalıştığımız bölge düzensiz bir yapıya sahip olduğundan bu yöntem [14], bizim için uygun değildir. Düzensiz bölgelerin atenüasyon düzeltme haritasını çıkarabilmek için ekstra bir dış radyasyon kaynağına ihtiyaç vardır. Bunun için düzensiz bölgeler için yapılan çalışmalar genellikle, SPECT ile dış kaynak olarak kullanılan CT cihazlarının kombinasyonu olan SPECT/CT ile elde edilen çalışmalar etrafında yoğunlaşmıştır [17]. Bu durumda, atenüasyon düzeltmesi iki taramadan elde edilen görüntülerle yapılır. Boş taramada, bu tarama verisi, dış kaynak kullanılmış hastasız tarayıcıdan elde edilen fotonlar içerir. Transmisyon taramasında ise bu taramanın verisi, dış kaynağın hastanın vücudu boyunca geçmesi sırasında elde edilen fotonları içerir.

Boş tarama görüntüsü (I_{Blank}) ve transmisyon tarama görüntüsü (I_{Trans}) arasındaki her bir pikselin (i, j) sayısının oranı, piksel için atenüasyon düzeltme faktörünü (Attenuation Correction Factor, ACF) verir ve Eş. 1.2'deki şekilde bulunur.

$$\text{ACF}(i, j) = \frac{I_{\text{Blank}}(i, j)}{I_{\text{Trans}}(i, j)} \quad (1.2)$$

Eş. 1.2'de i ve j uzamsal koordinatları ifade eder ve düzeltilmiş görüntü elde etmek için emisyon taramasının piksel verisine uygulanan bir atenüasyon düzeltme haritası verir. SPECT/CT kombinasyonu kullanılarak yapılan ilk çalışmada [18], torso fantomu ve ölü küçük domuzların miyokard dokuları kullanılmıştır. Fantom üzerinde yapılan çalışmada elde edilen atenüasyon haritasının ortalama doğruluk hatası %1'den daha düşük çıkmıştır. Atenüasyon düzeltmesi yapılmayan SPECT görüntüsünde, bölgesel miyokard aktivite hataları göz ardı edilerek, ortalama doğruluk hatası %90 çıkarken, atenüasyon düzeltmesi yapılan görüntüde bu oran %37'ye düşmüştür.

Gerçek hastalar üzerinde yapılan bir çalışmada [19], toplam 30 hastanın SPECT/CT ile elde edilen miyokard perfüzyon görüntülerinin atenüasyonu düzeltilenlerin düzeltilmeyenlere göre toplam tanısal doğruluğunun (sırasıyla atenüasyonu düzeltilen ve düzeltilmeyen görüntülerin; hassasiyet/seçicilik/doğruluk= %76/%93/%89, %67/%86/%81) istatistiksel olarak çok az yükseldiği görülmüştür. 105 hastaya ait görüntülerle elde edilen diğer bir çalışmada ise, SPECT ve CT görüntülerinin birleştirilmesi esnasında oluşan hatalar bir program vasıtasıyla düzeltilmeye çalışılmıştır.

Hatalı birleřtirmenin etkisini hesaplamak için, atenüasyonu düzeltilmiř ve düzeltilmemiř görüntüler birbiriyle, vücut ağırlığı cinsiyet gibi ek klinik deęiřkenler içeren çok deęiřkenli bir analizde hatalı birleřtirmenin derecesiyle birlikte iliřkilendirilmiřtir. Buna raęmen görüntülerin %64'ünde hatalı birleřtirme gözlemlenmiřtir [9]. 258 hasta grubuyla SPECT/CT kullanılarak yapılan bir dięer alıřmada ise, sadece %24'ünde tam anlamıyla doęru birleřtirme gerekleřtirilmiřtir [20]. Bir bařka alıřmada ise, toplam 60 hastaya ait CT ile atenüasyonu düzeltilmiř SPECT görüntüleri t testi ile analiz edilmiř ve ancak %42 oranında olumlu sonu alınmıřtır [21]. Bu alıřmalardan da anlařılacaęı gibi SPECT/CT kombinasyonu, görüntülerin birleřtirilmesi ařamasında oluřan hatalar sebebiyle beklenen sonucu verememektedir.

Atenüasyon düzeltilmesinde SPECT/CT kullanımının bazı dezavantajları vardır. SPECT ve CT görüntülerinin yanlıř birleřtirilmesi ve kanlanma olan yerin hatalı tespit edilmesi gibi sorunlarla karřılařılabilir [22]. Ayrıca ulařılabilirlik yani her merkezde olmaması ve yüksek maliyetli olması sistemin dezavantajlarından bazılarıdır [23]. Bunun yanında hastanın ek radyasyona maruz kalması söz konusudur [24].

SPECT ile gerekleřtirilen geleneksel MPS, Electrocardiogram (EKG) yardımıyla oluřturulan sistolik ve diastolik görüntülerde, kalp kası kanlanmasının yanında kalp duvarındaki kalınlařma ve duvar hareketleri hakkında bilgi veren řekilde Gated-SPECT olarak adlandırılan bir yöntem oluřturulmuřtur [25]. Bu yöntem meme atenüasyonun düzeltilmesi adına yapılan ilk alıřmalardan biri olsa da, meme atenüasyonu düzeltilmesinde çok ciddi bir katkı sunmamıřtır. Ancak řu an kullanılan sistemlerin çoęunluęunda ve bu alıřmada kullanılan SPECT cihazında bu ek donanım mevcuttur. Bu zamana kadar görüntü iřleme yöntemleri ile doku atenüasyonunun mevcudiyetinin arařtırıldıęı bir alıřmaya rastlanmamıřtır. Bu sebeplerden dolayı, bu alıřmada sadece SPECT görüntülerinden faydalanılarak kadın hastaların MPS görüntülerinin yorumlanması amalanmıřtır.

2. GENEL BİLGİLER

Bu tez kapsamında, toplamda 81 farklı kadın hastadan elde edilen SPECT görüntüleri kullanılarak meme atenüasyonunun olup olmadığı konusunda karar verilmesine yardımcı olan bir model geliştirilmiştir.

2.1. Miyokard İskemisi ve Teşhis Yöntemleri

İskemik kalp hastalığı dünya genelinde hastalığa ve ölüme yol açan birinci etkidir. Miyokard iskemisi, miyokard oksijen kaynağı ve talebi arasındaki dengesizlikten kaynaklanmaktadır, bu ise kardiyak yetmezliğe, aritmi, kalp krizi ve ani ölümlere neden olmaktadır. Çeşitli kliniksel iskemik belirtilerin sebebi, epikardiyal ve mikrovasküler koroner arterlerin, koroner darlık, damarda kan pıhtılaşması ve/ve ya spazmları ile koroner kan akımının engellenmesidir [26].

Koroner kan dolaşımı, endotelin önemli rol oynadığı mikro vasküler içindeki vasküler dirençlerin koordine edilmesiyle oluşan miyokardiyal oksijen talebi sonucu, kan akımı ile eşleşir. Endotel aynı zamanda, nitrik oksit, prostasiklin ve endotel türevi hiper polarize faktörü (EDHF) gibi birkaç endotel türevi gevşeme faktörlerinin salınmasıyla önde gelen vasküler düz kasların uyumunu ayarlar. Hücreler aynı zamanda, kesin patolojik durumlarda, endotelin, süper oksit anyonlar (O_2^-) ve tromboksan gibi damar büzücü faktörler salıverirler. Endotel bozukluğu, damar tıkanıklığının sistemik belirtiler gösteren bir kliniksel sendrom olarak kabul edilir, önemli hastalık ve ölümle ilişkilendirilir [27, 28].

Miyokard iskemisi miyokardın oksijen talebiyle beslenmesi arasındaki dengesizlik olarak tanımlanır [29]. İskemik kalp hastalığı olan hastalarda, miyokard iskemisinin varlığı tanı için önemli bir etkidir [30]. Çizelge 2.1’de miyokard iskemisini tespit etmek için günümüzde kullanılan farklı teşhis yöntemleri verilmiştir [26].

Çizelge 2.1. Miyokard iskemisi ve koroner kan akımı için teşhis yöntemleri

Miyokard iskemisi	
ECG	Egzersiz stres testi, Holter ECG
MPS	Talyum-201, Teknesyum-99m
Metabolik İşaretleyiciler	Miyokard laktat üretimi, koroner sinüs O ₂ desatürasyonu, pH azalması, lipid peroksit
31P NMR	Yüksek-enerji fosfat fosfokreatin, adenosin trifosfat
Koroner kan akımı	
PET	Oksijen-15, nitrojen-13, rubidyum-82
MRI	Perfüzyon ve dizfüzyon görüntüleme
Koroner akım rezervi	Termodilüsyon metodu, Doppler metodu (koroner içine, transtorasik)
Koroner anjiyografi	Girişimsel koroner inceleme

Miyokard iskemisi, egzersiz veya farmakolojik stres testindeki değişiklikler, geçici ST segment elektrokardiyogramıyla ve reversibil perfüzyon bozuklukları stres miyokard sintigrafisiyle gösterilebilir. Miyokard laktat üretimi, koroner sinüs oksijen desatürasyonu ve koroner sinüste pH düşüşü gibi metabolik değişimler miyokard iskemisinin olduğuna dair önemli objektif bulgulardır. Koroner dolaşımdaki lipit peroksit maddelerinin miyokard salınımı yüksek hassasiyetle miyokard iskeminin, en kötü ihtimalle hafif miyokard iskeminin bir belirtisidir [31]. Miyokard fosfor-31 nükleer manyetik rezonans (31P NMR) spektroskopisi miyokardiyal yüksek enerjili fosfat fosfokreatin ve adenosin trifosfat ölçümüyle miyokard iskemisini tespit etmek için başka hassas bir metottur. [32]. Bu iskemik metabolitlere ek olarak, iki boyutlu stres ekokardiyografi ile saptanan sol karıncık duvar anormallikleri kullanışlı bir teşhis yöntemidir [33].

Koroner kan akımının ölçümü kullanışlıdır ama sadece miyokard iske miyle alakalı bilgi sağlamaktadır. Pozitron emisyon tomografisi (PET), koroner kan akımının sayısal miktar hesaplamasını yapmaktadır [34]. Damardan enjekte edilen kontrast maddeyle birlikte yapılan manyetik rezonans görüntüleme de miyokardiyal kan akımının miktarının hesaplanmasında kullanılmaktadır [35]. Koroner akım rezervi, maksimum hiperemi (kan toplanması) esnasındaki kan akımının re ste (stressiz) oranıyla ifade edilmektedir. Koroner akım rezervi, invaziv (girişimsel) olarak termodilüsyon veya Doppler tekniğiyle ölçülebilir [36]. 2.0. transtorasik (göğüsten geçen) renginden az olması anormal olarak değerlendirilir, Doppler ekokardiyografi, özellikle sol ön koroner arterin aşağı uzanan kısmındaki koroner akım, hız rezervinin girişimsel olmayarak değerlendirilmesine imkan sağlar [37, 38]. Özellikle anjiyografik olarak normal arterli hastalarda, akım direnci esas olarak

mikrovasküler seviyede hesaplandığı için koroner akım rezervindeki azalma koroner mikrovasküler fonksiyon bozukluğunu yansıtır [34].

Koroner anjiyografi, kalbin kan damarlarının X-ışını kullanılarak incelemek için bir yöntemdir. Koroner anjiyografi, kardiyak katerizasyon olarak da bilinir. Katerizasyon, ince, uzun ve esnek bir tüpün vücuda girişimsel olarak uygulanmasıdır. Kardiyak katerizasyon, teşhis ve tedavi amacıyla uygulanabilir. Anjiyografi esnasında iyot-tabanlı bir iyonik kontrast madde, görüntülenmek istenen damarlara enjekte edilerek, x-ışını sayesinde gerçek zamanlı görüntüleme yapılmaktadır. Bu yöntem, miyokard iskeminin teşhisi için altın standart olarak kabul edilir. Fakat girişimsel bir işlem olduğu için yan etkileri fazladır, hafif yan etkilerinin yanında düşük bir ihtimal bile olsa ölümle sonuçlanabilir.

Bizim tezimizde kullandığımız görüntüler ise diğer bir miyokard iskemisi teşhis yöntemi olan miyokard perfüzyon sintigrafisi (MPS) ile elde edilmiştir. Bu yöntem bir sonraki bölümde daha detaylı ele alınmıştır.

2.2. Görüntü ve SPECT Görüntüleme

Bu bölümde görüntü ve SPECT görüntülemeye ait temeller ve teknik detaylar açıklanmıştır.

2.2.1. Görüntü

Görüntü iki boyutlu bir $f(x,y)$ fonksiyonu olarak tanımlanabilir. Burada, x ve y düzlem koordinatlarıdır. f fonksiyonun herhangi bir (x,y) koordinatındaki genliği, görüntünün o noktadaki yoğunluğu olarak tanımlanır.


Eğer x,y değerleri ve f fonksiyonun genliği sonlu ve ayrık değerlerse, bu görüntü sayısal görüntü olarak adlandırılır. Sayısal bir görüntü piksel denilen sonlu sayıda elemanlardan oluşmaktadır. Her bir pikselin kendine özgü konumu ve değeri vardır.

Sayısal bir görüntüyü tasvir etmek için iki temel yol vardır. Bir $f(x,y)$ görüntüsünün örneklendiğini düşünülürse, M adet satırdan ne N adet sütundan oluşur. (x,y) koordinat

değerleri ayrık değerlerdir. Bu ayrık koordinat değerleri olarak tam sayılar kullanılır. Bu bağlamda görüntü, toplamda $M \times N$ adet pikselden oluşan, bir dikdörtgen matristir. Genel olarak görüntü orijini $(x,y) = (0,0)$ olarak tanımlandığı yerdur. Görüntünün birinci satırı boyunca sıradaki koordinat değerleri $(x,y) = (0,1)$ 'dir. Şunu unutmamak gerekir ki, $(0,1)$ gösterimi birinci sıra boyunca ikinci örneği belirtmek için kullanılır. Bu, bunların fiziksel koordinatlarının gerçek değerleri olduğu anlamına gelmez. Şekil 2.1.a'da gösterildiği gibi x , 0'dan $M-1$ ve y 0'dan $N-1$ aralığında sıralanmaktadır.

Genel matematik sisteminde x koordinatı sağa doğru artış gösterirken y koordinatı yukarı doğru artış gösterir fakat görüntü matrisinde x koordinatı aynı şekilde artarken y koordinatı yukarıda aşağı artış gösterir.

(x,y) gösterimleri yerine, görüntü için (r,c) gösterimlerini kullanırsak, görüntü matrisinin orijini $(r,c) = (1,1)$ olur. Böylece r , 1'den M 'ye kadar değerler alırken, c 1'den N 'ye kadar değerler alır. Bu dönüşüm Şekil 2.1.b'de verilmiştir.




Şekil 2.1. (a) Görüntü matrisinin koordinat sistemi güncellenmesinden önceki gösterimi (b) görüntü matrisinin koordinat sistemi güncellenmesinden sonraki gösterimi

Pikselin yoğunluğu, verilen bir minimum maksimum aralığında ifade edilir. Bu aralıklar görüntünün kaç bit olduğuna ve türüne göre değişiklik gösterir. Bu bağlamda üç tip görüntü vardır. Bunlar; ikili görüntü, gri seviye görüntü ve renkli görüntüdür.

İkili görüntüler iki değerden oluşmaktadır ve genellikle 0 ve 1 değerlerinden oluşur. 0 siyahı 1 beyazı temsil etmektedir. İkili görüntüler, işlenmesi kolay olduğu için farklı uygulamalarda kullanılır fakat görüntü bilgisinin gösteriminde görsel olarak fakir kaldığı için her zaman tercih edilmez. Gri seviye görüntülerde pikseller siyah ve beyaz arasındaki farklı renk tonlarını barındırmaktadır. Siyah ve beyaz arasındaki renk tonları gri seviye renklerdir bu nedenle bu görüntüler gri seviye görüntüler olarak adlandırılır. Diğer bir görüntü türü de renkli görüntülerdir. Bu görüntüler kırmızı yeşil mavinin farklı yoğunluklarda birleşmesinden oluşur. Bu görüntü türleri Şekil 2.2’de verilmiştir.

Gri seviye ve renkli görüntülerde yoğunluk değerleri görüntünün kaç bit olduğuna göre değişiklik gösterir. Yoğunluk aralığının belirlenmesinde 2 bit sayısı formülü kullanılır. Örneğin 1 bitlik bir görüntüde, görüntü yoğunluk iki değer arasında değişebilirken, 8 bitlik bir görüntüde yoğunluk 256 değer arasında değişebilir. Genel olarak kullanılan görüntüler 8 bit için olası yoğunluk değerler alır. Renkli görüntüler ise üç farklı renkten oluştuğu için $3 \times 8 = 24$ bitlik bir yoğunluk aralığı kullanır.

Bir görüntüdeki toplam piksel sayısı o görüntünün boyutu olarak ifade edilebilir. Bunun yanında bir de çözünürlük kavramı vardır. Çözünürlük, görüntüler için bir ölçekleme kavramıdır. Örnek verecek olursak; inç başına (ppi) 400 piksel çözünürlüklü 4000×3200 pikselden oluşan bir görüntüsünü gerçek boyutu 10"x8" büyüklüğünde olacaktır.



Şekil 2.2. (a) İkili görüntü (b) gri seviye görüntü (c) renkli görüntü

2.2.2. SPECT görüntüleme

SPECT (Tekli foton emisyon bilgisayarlı tomografi) hızlı bir şekilde değişen bir alandır ve son yıllarda hem donanım teknolojisinde hem de görüntü işleme algoritmalarında gelişmeler gerçekleşmiştir. SPECT'i oluşturan elemanlar düzeyinde, yarı iletken teknolojisinde yaşanan büyük gelişimler gibi sintilatörlerde ve foton dönüştürücülerinde de ciddi gelişmeler olmuştur. Bu parçalar daha küçük ebatlarda üretim sağlamasına imkan verirken, özel uygulamalar için uyarlanmış daha kompakt sistemler oluşturulmasını sağlamaktadır.

Radyoaktif çekirdek görüntüleme teknolojisinin başlangıcından itibaren, radyofarmasötüklerin vücut içinde dağılımlarının tomografik görüntülerinin üretilmesinde çok ciddi çaba sarf edilmiştir.

SPECT temelleri

Bütün radyoaktif tomografik görüntülemelerin temeli bir maddenin vücut içindeki dağılımını sadece vücut dışından yapılan işlemlerle hesaplamaktır. Bu işlem takip eden süreçlerin gerçekleştirilmesine bağlıdır. Birincisi, ilgili bölgeye ait bütün projeksiyonların elde edilmesi, ikincisi bu projeksiyonlar elde edilirken vücut içindeki dağılım uzaysal ve ya geçici olarak değişmemelidir, üçüncüsü projeksiyonları elde eden detektörler, elde etme süresince düzgün bir tespit hassasiyetine sahip olmalıdır ve son olarak dönme merkezi tam olarak bilinmelidir. Dönme merkezi elde edilen projeksiyonların ortak merkezini tanımlayan koordinattır ve bu koordinatın tam yeri yeniden oluşturma sırasında projeksiyonların doğru dizilimi için gereklidir. Eğer ölçümler bu kriterleri karşılayacak şekilde alınırsa vücut içi dağılımın doğru bir şekilde yeniden oluşturulması gerçekleştirilebilir.

SPECT sistemleri tarafından toplanan bilginin, sadece bir projeksiyonun tanımıyla eşleşmediği unutulmamalıdır. SPECT sistemleri tarafından toplanan gama ışını emisyonları, doku atenüasyonu sebebiyle hastadaki gama ışınları aktivitesiyle doğrusal bir ilişkiye sahip değildir. Sonuç olarak, eğer bu atenüasyona uğramış projeksiyonlar yeniden oluşturulursa oluşturulan tomografik kesitler artefaktlar içerir ve vücut içi dağılımı hassa bir şekilde yansıtmaz. Atenüasyondan başka faktörler de yeniden oluşturulan görüntünün

kalitesini sınırlar. Bunlar, uzaysal çözünürlük, foton saçılması ve istatistiksel dalgalanmalar (görüntü gürültüsü)'dır. SPECT'teki gelişmeler, yeni araçlar ve ya daha iyi doğrultma algoritmalarla elde edilen projeksiyonların hassasiyetinin ve kalitesinin geliştirilmesiyle doğrudan bağlantılıdır.

Belirleme (Deteksiyon) araçları

SPECT için gerekli olan projeksiyon bilgisi, gama ışını detektörleriyle elde edilir ve projeksiyon kalitesinin önemli bir bölümü bu detektörlerin kalitesine bağlıdır. Detektörlerin şu karakteristiklere sahip olması beklenir: yüksek iç verimi, iyi enerji çözünürlüğü ve iyi içi uzaysal çözünürlüğü. Yüksek atom sayılı ve yüksek yoğunluklu malzemeler detektör verimi için önemlidir. Enerji çözünürlüğü ve uzaysal çözünürlüğün her ikisi de her bir tespit edilen durumla üretilen sinyalin boyutuna bağlıdır. Talyum ile aktive edilmiş sodyum iyodür NaI(Tl) kullanan sintilasyon kameraları 200 keV'tan daha düşük enerjili gama ışınları için yüksek iç verime sahiptir ama enerji çözünürlüğü ve iç uzaysal çözünürlüğü orta seviyedir. Sonuç olarak daha iyi detektör konfigürasyonlarının yanında daha iyi detektörler için çalışmalar yapılmaktadır.

SPECT bölümleri


Hastaya enjekte edilen radyofarmasötik maddenin yaydığı gama ışınının anlamlı bir görüntü haline gelmesi için geçen süreçlerin akış diyagramı ve SPECT bölümleri Şekil 2.3'te gösterilmiştir.

İlgili bölgeden gama ışınları kaynaklı yayılan fotonlar yönlendirici sayesinde sintilatör kristali üzerine düşürülür.

Sintilatöre ulaşan fotonlar burada görünür ışığa dönüştürülür. Buradan çıkan fotonlar ışık kılavuzu sayesinde odaklama yapılarak foton çoğaltıcı tüpe (Photomultiplier Tube - PMT) ulaştırılır ve bu süreç sonunda az miktar elektron açığa çıkar. Az miktardaki bu elektronlar foton çoğaltıcı tüp içerisinde bulunan dinodlar vasıtasıyla yüksek gerilimin de sayesinde çoğaltılır.

Elektronlar bu şekilde PMT çıkışındaki anotta toplanır. Böylece organdan yayılan gama fotonları kristal içinde sintilasyon fotonlarına, PMT içinde elektrik sinyallerine dönüştürülmüş olur. PMT'nin katodundan giren elektronlar miktarı artırılmış olarak anodunda toplanmış olur. Böylece en baştaki gama ışını sayesinde elektrik sinyalleri elde edilmiş olur.

Elde edilen bu elektrik sinyalleri x, y ve z ekseninden olmak üzere üç eksenenden alınır. Daha sonrasında bu sinyaller çeşitli elektronik üniteler aracılığıyla anlamlı bir görüntüye dönüştürülür. SPECT bölümleriyle alakalı kapsamlı bilgi, ilgili referanstan bulunabilir [39].



Şekil 2.3. SPECT bölümleri

Yönlendirici

Yönlendiriciler, gama ışını soğurduğu için kurşundan yapılmaktadır ve görüntü kalitesinin sürekliliğini sağlar. Yönlendiricilerin içinde kanallar arsında septa denilen boşluklar bulunmaktadır. Kanalların tasarımına göre paralel-kanallı, tek-kanallı, yakınsak ve ıraksak olmak üzere 4 tür yönlendirici vardır. Yönlendiriciler içinde en çok kullanılanı paralel-kanallılardır.

Sintilatör

Sintilatörün yapımında talyum ile aktive edilmiş sodyum iyodür (NaI Tl) kullanılmaktadır. Kristal olarak da adlandırılan bu yapının görevi görünmez ışığı görünür ışığa çevirmektir. Oluşturulan görünür ışığın miktarı gelen gama ışınları miktarıyla doğru orantılıdır.

Foton çoğaltıcı tüp

Foton çoğaltıcı tüp (PMT) ışığı elektrik sinyallerine çevirir. Fotokatot ışık tarafından uyarıldığında elektron oluşturur. Foton çoğaltıcı tüp, foto katotta üretilen elektronları alıp yükseltir. Foton çoğaltıcı tüp kristalin arkasında bulunur. SPECT, 37-91 tane Foton çoğaltıcı tüp içerir.


Kristalden çok az miktarda ışık çıkar. 7-10 fotonun, fotokatota vurmasından ancak bir elektron elde edilir. Bu elektron dinoda odaklandırılır ve dinod gelen elektronu absorbe edip daha fazla elektron olarak tekrar yayar.(yaklaşık 6-10 katı kadar elektron). Yeni oluşan bu elektronlar diğer dinoda odaklandırılır ve bu işlen dinod dizisi boyunca tekrar edilir.

Foton çoğaltıcı tüpün başındaki anot bütün bu oluşan elektronları toplayıp elektrik sinyaline çevirir.

Ön-yükselteç ve yükselteç

Ön-yükselteç PMT'nin üstüne bağlıdır. PMT'de elektronların çoğaltılmasıyla oluşan sinyal yine de düşüktür. Bu yüzden sinyali yükseltmek için çok hassas yükselteçlere ihtiyaç duyulur. Bu tip yükselteçler genel olarak ön-yükselteç (pre-amplifier) olarak adlandırılır. Ön-yükselteçle sinyal yükseltildikten sonra asıl yükselteçle sinyal ihtiyaç duyulan seviyeye yükseltilir.

Ön-yükselteç fotoçoğaltıcı tüpün üstünde bulunmaktadır. Fotoçoğaltıcı tüpte elektronlar çoğaltılmasına rağmen oluşan sinyal yetersizdir, bu sebeple ön-yükselteçlere ihtiyaç duyulur. Ön-yükselteçle bir miktar şiddetlendirilen sinyal daha sonra esas yükselteçle istenilen seviyeye ulaştırılır.



Şekil 2.4. Yönlendirici ve ön-yükselteç arası birimler

Konumlandırma devresi ve sinyal yükseklik analizörü

Konumlandırma devresi elektrik sinyallerini toplam matris devresindeki tüplerden alır. Bu, konum devrelerinin kristaldeki her bir sintilasyonun nerede gerçekleştiğinin hesaplanmasına imkân verir. Yükselteçlerden çıkan her bir elektrik sinyalinin genliği,

sinyal yükseklik analizörünün elektrik devrelerinde ölçülür. Darbe yükseklik analizörü ve bilgisayar, ışığı kullanılabılır anatomik görüntüye dönüştürür.

2.2.3. Miyokard perfüzyon sintigrafisi (MPS)

MPS, SPECT ile gerçekleştirilen en önemli ve çok sık tercih edilen invaziv olmayan kardiyak görüntüleme testlerinden biridir. MPS kardiyovasküler hastalığın teşhisinde, seyrinde, tedavinin etkinliğinin ve miyokardiyal kapasitenin değerlendirilmesinde anahtar rol oynar. Bu görüntüleme yönteminin başarısı, büyük anlamda, bu alanın büyümesi ve ilerlemesini devam ettiren teknolojiler sayesinde gelişmiştir. Bu, SPECT teknolojilerinin ilerleyen gelişmesini, yeni radyofarmasötikleri ve yeni yazılımları içermektedir [40].

Mevcut durumda, miyokardiyal perfüzyon ve kardiyak fonksiyonun her ikisinin de beraber değerlendirilmesi için stres MPS en çok EKG- kapılı SPECT ile yapılır. Farklı stres teknikleri mevcuttur, ama koroner kan akımındaki yükselişe ek olarak hastalığın seyriyle alakalı faklı önemli bilgiler sağladığı için egzersiz stres testi tercih edilir. Fakat egzersiz testinin hastaya uygun olmaması durumunda, farmakolojik stres alternatifi düşünülmelidir. Talyum-201 ve teknesyum-99m sestamibi ve tetrofosmin şu an kullanılan radyofarmasötiklerdir. Potansiye olarak MPS, yorumlamada taviz verilebilecek bazı dezavantajlar ve farklı artefaktlar barındırmaktadır. SPECT cihazını geliştirenler ve sonuçlarını yorumlayan klinisyenlerin potansiyel hata sebeplerinden haberdar olması ve öncesinde bu hataları gidermek için uygun adımlar atması, nerede olursa olsun sonuçların yorumlanması üzerindeki potansiyel etkilerini tanıması ve ortadan kaldırılamayacak durumlarda bu hataları doğrultmasını yapması gerekir. MPS'nin kullanılmasının ana sebepleri, koroner arter hastalığının (KAH) yani miyokard iskemisinin teşhisi, KAH olduğu bilinen hastalarda risk sınıflandırması, tedavi ve müdahalenin değerlendirilmesi ve peruktan işlem ve baypas operasyonundan önce miyokardiyal aktivitenin değerlendirilmesidir. Bu yüzden, görüntülerin klinisyene sevki ve yorumlanması arasındaki uyum, çalışma için uygun sonuç, hastanın en uygun şekilde hazırlanması ve hasta klinik yönetimindeki test sonuçlarının etkili bir şekilde kullanılmasını sağlamak için temel bir noktadır. Mevcut olarak stres MPS'nin farklı uygun kullanım alanları (endikasyonları) vardır; uygun endikasyonlarla benzerlik testten iyi bir şekilde faydalanmak için çok önemlidir, uygun olmayan alanlarda kullanımından kaçınmak, gereksiz masraf ve radyasyona maruz kalmamak açısından önemlidir [41].

Özetlemek gerekirse MPS uygulanması için 4 ana başlıkta toplanabilir; kardiyak stres, radyofarmasötik enjeksiyonu, görüntüleme protokolleri ve MPS'nin yorumlanması.

Kardiyak stres

Stres MPS, koroner akımdaki heterojenliğin oluşturduğu koroner darlığın fizyolojik önemini değerlendirir [42]. İstirahat (rest) koroner akımı, koroner arter akımının yaklaşık %90 azalmasına kadar sürdürülür. Bununla beraber, koroner akım rezervi olarak da adlandırılan maksimum akımın sürdürülme yeteneği, %50 koroner darlıkla birlikte bozulur. Koroner akımda artış, egzersizle (koşu bandı ve ya bisiklet) birlikte artan oksijen talebiyle, b- adrenerjik agonistle (dobutamin) veya direkt damar genişleticiyle (adenozin, dipiridamol) gerçekleştirilebilir [43].

Radyofarmasötik

Stres MPS'de enjekte edilen radyofarmasötik, kan akımıyla orantılı olarak miyokarda iletilir. Bu madde ajan olarak da adlandırılabilir. Kan akımı düşük bölgelerde düşük ajan tutulumu yüksek kan akımı olan bölgelerde yüksek ajan tutulumu olur. Güncel olarak kullanılan radyoaktif ajanlar; ^{201}Tl -klorit, $^{99\text{mTc}}$ - sestamibi ve $^{99\text{mTc}}$ -tetrofosmindir [43]. $^{99\text{mTc}}$ -işaretleli radyonüklitler ($^{99\text{mTc}}$ - sestamibi ve $^{99\text{mTc}}$ -tetrofosmindir) MPS'de en sık kullanılan radyofarmasötiklerdir [46]. Çıkarma verimi fizyolojik kan akımı aralığında %65, tutulum kan akımıyla orantılı ve ajanın birikimi kan akımıyla lineer olarak atmamakla birlikte yüksek akım değerlerinde seviyesi düşme eğilimi göstermektedir. $^{99\text{mTc}}$ ilgili radyonüklitlerin dağılımı birkaç saatin üstünde nispeten sabit kalmaktadır. Bu, enjeksiyondan sonra birkaç saat gecikmeli olarak bile görüntüleme yapılmasına imkan vermektedir bu nedenle enjeksiyon sonrası akut göğüs ağrısına sahip olan hastaların işini kolaylaştırmaktadır. $^{99\text{mTc}}$ 'nin Hepatobiliyer atılımı karaciğer ya da bağırsak aktiviteleriye sonuçlanıp kalbin sol karıncığının alt (inferiyor) duvarını örtebilir. Diyafram altının yanındaki aktiviteyi görmemek için görüntüleme, stres enjeksiyonundan sonra en az 30, istirahat enjeksiyonundan en az 60 dakika ertelenmelidir. $^{99\text{mTc}}$ tetrofosmin hepatobiliyer atılımı, sestamibiye göre daha azdır ve alt duvar değerlendirmesi daha az problemlidir [43].

Görüntüleme protokolleri


99mTc ajanları için 4 protokol vardır. Orijinal protokol, radyofarmasötüklerin iki farklı günde iki enjeksiyonu şeklindedir. Orijinal protokol, hasta kolaylığı için aynı günde streten sonra istirahat olarak birer adet düşük ve yüksek doz olmak üzere uygulanabilir. Bu protokol en sık kullanılan protokoldür. Üçüncü protokolün ikinci protokolden tek farkı istihattten sonra stresin uygulanmasıdır. Dördüncü protokol ise ikili izotop olarak adlandırılır ve bu protokolda önce 201Tl-klorit görüntüleri istirahat enjeksiyonunu takip edecek şekilde elde edilir ve stres esnasında sonradan 99mTc radyofarmasötüğü enjekte edilir [44]. Bütün bu protokollerin kendi destekçileri vardır. Bu protokollerin hiç birinin birine üstün olduğu yönünde henüz mevcut bir bilimsel kanıt olmamakla birlikte, pratik mantıksal sonuçlar üzerinden seçim yapılmaktadır [45]. Koroner arter hastalığı ve ciddi sol karıncık fonksiyon bozukluğu olduğu tespit edilmiş hastalarda, 99mTc veya 201Tl-klorit ajanlarının normal ya da normale yakın tutulumunu göstermek, haliyle miyokardiyal aktivitesini belirleyebilmek için sadece istirahat görüntüleri elde edilebilir [43].

MPS'nin yorumlanması

MPS Spect görüntülerinin yorumlanması sıradaki adımları içerecek şekilde sistematik ve tutarlı bir şekilde yapılmalıdır: (1) kardiyak dışı ajan aktivitesinin dağılımını ve görüntü artefaktlarının potansiyel kaynaklarının varlığını tespit edebilmek için ham görüntülerin sine modunda değerlendirilmesi; (2) stres ve istirahat görüntülerinin sonrasında uygun sıralanması; (3) görüntülerin, perfüzyon bozukluklarının lokasyon, büyüklük, hasar ve reverzibilite açısından kardiyak odacık büyüklükleri gibi, özellikle Tl-201 için, yükselmiş akciğer tutulumunun varlığı ya da yokluğunun yorumlanması; (4) niceliksel perfüzyon analizi sonuçlarının birleştirilmesi; (5) kapılı görüntülerden alınan fonksiyonel verinin göz önünde bulundurulması ve (6) çalışmanın nihai yorumunu etkileyecek kliniksel faktörlerin göz önünde bulundurulması. Bütün bu faktörler, nihai kliniksel raporun üretimine katkıda bulunur [46].

Normal MPS ve deęişkenler

Rest ve stres görüntülerinin ikisi de, görsel yorumlamadan önce bilinen bütün artefaktlar dikkatlice deęerlendirilmelidir. Normal bir miyokardiyal perfüzyon çalışmasında stres ve rest görüntülerinin her ikisinde de ajan dağılımı Şekil 2.5'teki gibi homojendir.




Şekil 2.5. 55 yaşındaki bir erkeęe ait normal bir MPS

Şekil 2.5'te rest ve stres görüntülerinin ikisi de normal ajan dağılımını göstermektedir. Bazal inferiyor duvarında hafif bir tutulum düşüşü vardır ve septum normaldir [43].


Görsel analiz

Perfüzyon bozulması büyüklüğü nicelik olarak küçük, orta ve büyük olarak tanımlanabilir. Sol karıncık miyokardının , %10'dan az bozuklukları küçük, 10-20% arası bozuklukları orta ve %20'ye eşit veya büyük bozuklukları ise büyük bozukluk olarak tanımlanır (Şekil 2.4, 2.5, 2.6). Buna alternatif olarak bozulma büyüklüğü, anterior duvarının apikal yarısı gibi bir kesit olarak tahmin edilebilir. Bozulma şiddeti görsel olarak hafif, orta ve şiddetli şeklinde ifade edilebilir. Hafif bozulma korunan kalınlıkla bitişik duvardakine kıyasla sayımın düşüşüyle tanımlanır, orta bozulma duvar incilmesi olarak ortaya çıkar, şiddetli bozulma ise görüntüsüyle benzerlik gösterir.




Şekil 2.6. Üç farklı hastadaki miyokard perfüzyonunun büyüklüğü ya da boyutu

Şekil 2.6’da Stres ve restte seçilen kısa eksen görüntüleri (SAX) verilmiştir. Oklar, küçük boyutta revezibil anterolateral duvar perfüzyon bozulmasını işaret etmektedir. [43].




Şekil 2.7. Üç farklı hastadaki miyokard perfüzyonunun büyüklüğü ya da boyutu

Şekil 2.7’de stres ve restte seçilen kısa eksen görüntüleri (SAX) gösterilmiştir. Oklar, inferyor ve inferolaterali içeren orta boyutta revezibil perfüzyon bozulmasını işaret etmektedir. [43].



Şekil 2.8. Üç farklı hastadaki miyokard perfüzyonunun büyüklüğü ya da boyutu

Şekil 2.8’de Stres ve restte seçilen kısa eksen görüntüleri (SAX) verilmiştir. Oklar, neredeyse bütün sol anterior inen koroner arterdeki dağılımı içeren sol karıncık miyokardının büyük boyutlu bozukluğu [43].



Şekil 2.9. Tipik göğüs ağrısına sahip 71 yaşındaki bir erkeğe ait perfüzyon bozulmasının şiddeti

Şekil 2.9’da Apikal lateral duvardaki perfüzyon bozulması hafif (beyaz ok), orta lateral duvarda hafif (kırmızı ok) ve bazal lateral duvarda şiddetli (sarı ok) olarak ifade edilmiştir [43].

Perfüzyon bozulmasının reverzibilitesinin derecesi, rest veya tekrar dağılım görüntülerinde çoğalan veya kaybolan, düşmüş radyofarmasötik aktivitenin stres sonrası görüntülerinde bir alan olarak tanımlanır. Reverzibil olmayan (düzeltilmiş) bozulma, stres sonrası ya da rest görüntüleri arasında aktivitede önemli değişiklik göstermez.

2.3. Atenüasyon Fenomeni ve Buna Bağlı Problemler

Atenüasyonun fiziksel temelleri, enjekte edilen radyofarmasötiklerden yayılan fotonların vücuttan geçişi sırasında farklı dokularla etkileşimi üzerine dayanmaktadır. Bu etkileşimlerin bir sonucu olarak çok sayıda foton absorbe edilebilir veya detektörlerin algılamadığı bölgelere saçılabilir ve böylece algılanmaz ya da bu saçılmaların sonucu olarak algılanması gereken detektörler yerine farklı detektörlerden algılanması sonucu görüntü oluşturulması sırasında karışıklığa sebep olabilir [47]. Bu yüzden atenüasyon, artefaktlar, hatalar ve tabi ki yeniden oluşturulan görüntülerde kontrast düşüklüğüne sebep olabilir. Bunlar özellikle miyokard perfüzyonu görüntülenmesinde önemlidir çünkü göğüs (thorax) bölgesi, dokularında(kemik dokuları, yumuşak dokular ve akciğerler) yüksek oranda nonuniform bir dağılım içermektedir. Dolayısıyla bu bölgede hassas atenüasyon düzeltilmesi kullanılması en önemli husustur [48]. Bizim tezimizin motivasyon noktası özellikle kadınlarda meme dokusundan kaynaklı gerçekleşen atenüasyondur.

Atenüasyon, bir fotonun absorbe eden bir dokudan geçerken maruz kaldığı farklı etkileşimlerden kaynaklanır. Bu etkileşimler arasında, nükleer tıpta kullanılan iki etkileşim en önemlileri 68-80 keV ^{201}Tl ile 511 keV pozitron emitörü arasındadır. Birinci fotondaki fotoelektrik etkisi, ve foton hareketi yönündeki Compton saçılması ve enerji değişimi tamamen absorbe edilir. u etkileşimi için toplam olasılık, bu iki etkileşimin olasılıklarının toplamına eşit olan toplam lineer atenüasyon katsayısı olarak adlandırılır [49].

$$I(t) = I_0 \exp\left(-\int_0^t \mu_t(x, y) dl\right) \quad (2.1)$$

Eş. 2.1'de I_0 soğurucu maddeye girmeden önceki ışın yoğunluğudur ve $\mu_t(x, y)dl$ diferansiyel uzaklığındaki toplam atenüasyon katsayısıdır [47, 50].

SPECT görüntülemesindeki atenüasyondan kaynaklanan esas problemlerden biri, görüntülenen organın daha derin yapılarındaki radyofarmasötiklerden yayılan fotonların detektöre ulaşabilmesi için daha fazla doku geçmek zorunda olduğudur. Bu yüzden bu fotonlar, kenarlara yakın yerlerden yayılanlardan daha fazla atenüasyona maruz kalırlar. Bu sebeple organların oluşturulan görüntülerinde, merkezi yapılar dış taraflardan yapay olarak daha az radyoaktif görünür yani daha karanlık görünürler [51].

Medikal görüntülemelerde, atenüasyon sebebiyle oluşan artefaktlar gerçek lezyonlarla karıştırılabilir. Bu yüzden atenüasyon düzeltilmesi metotlarının kullanılması, görüntü kalitesini artırması ve teşhis doğruluğunu geliştirmesi açısından gereklidir.

2.3.1. Atenüasyon düzeltilmesi

Klinik uygulamalarda atenüasyon haritasının hesaplanması için iki sınıf metot geliştirilmiştir: hesaplanan (calculated) ve ölçülen(measured) atenüasyon düzeltilmesi metotları. Birinci sınıf metotlar hastadaki atenüasyonun uniform varsayıldığı durumlar içindir. Bu sınıf metotlar beyin çalışmaları için uygundur. Fakat göğüs gibi atenüasyonun homojen olmadığı bölgeler için bu metotlar telafi edici olamaz [52]. Ölçülen atenüasyon düzeltilmesi metotları, çeşitli transmisyon tarama sistemleri ve eksternal kaynakların kullanılmasıyla elde edilen atenüasyon haritaları kullanarak bu problemin üstesinden gelir. Bu bölümde, atenüasyon düzeltilmesi metotlarının fiziksel temelleri tanımlanmış ve kardiyak SPECT görüntülemesindeki transmisyon data kullanılarak atenüasyon düzeltilmesi haritasını oluşturmak için geliştirilen son protokoller özetlenmiştir. Ayrıca bu iki metot dışında aynı anda transmisyon ve emisyon taraması yapan SPECT/CT'nin farklı geometrik konfigürasyonları kullanılarak atenüasyonun en iyi düzeltildiği konfigürasyon gösterilmiştir.

Atenüasyon düzeltilmesi için sıkça kullanılan genel iki metot vardır ve bunlar zıt iki durum odaklıdır [53-55].

Atenüasyon olan bölge genel olarak uniform düşünülebilir. Bu yüzden, sabit ve uzamsal bir bağımsız olan μ_t görüntülenen organ boyunca kullanılabilir. Atenüasyon olan bölge farklı doku tiplerinden oluşabilir. Bu yüzden, organın her bir bölümünün farklı lineer atenüasyon katsayıları vardır ve yüksek oranda uzamsal bağımlıdır. Dolayısıyla, $\mu_t(I)$, sabit bir değer olarak düşünülemez.

Birinci durumda atenüasyon düzeltilmesi için kullanılan metot Chang metodu olarak bilinir, ikincisi ise transmisyon taraması veya transmisyon kaynak metodu olarak bilinir.

Chang metodu (Hesaplanan atenüasyon düzeltilmesi)

Chang algoritması [16], sabit atenüasyon katsayılı ve bilinen bir şeklin içine yerleştirilmiş bir nokta kaynağın FBP yeniden oluşturma odaklıdır. Bu metotta atenüasyon katsayı faktörü, organın içindeki her noktadan farklı projeksiyon açılarıyla dolaşan fotonların ortalama atenüasyonundan hesaplanır [53].

Düzeltilme faktörü hesaplanırken kaynak derinliği ve doku atenüasyon katsayısı hesaba katılır [56].

Chang metodunda, organ sınırının doğru belirlenmesi en önemli noktadır. Bu amaç için, yeniden oluşturulan bir görüntü, görüntülenen organdan düzeltilme olmaksızın taslağı ve dolayısıyla organ içindeki fotonların dolaşma uzaklığını kestirebilir [57]. Ardından düzeltilme faktörü haritası, organ sınırı kestirim odaklı ve sabit bir μ_t üretilir ve yeniden oluşturulan transvers dilimlerine uygulanır [54, 55].

Bu haritanın kullanılarak, ortada yüksek ölçeklendirme faktörü ve köşelere daha düşük ölçeklendirme faktörü emisyon görüntüsüne uygulanır ve böylece görüntünün ortasındaki atenüasyon kaynaklı karanlık ortadan kaldırılır. Ama bu düzeltilme faktörü sadece, μ_t 'nin nerdeyse sabit olduğu beyin ve abdomen gibi organlarda doğru bir şekilde çalışır [51, 53].

Transmisyon kaynak metodu (Ölçülen atenüasyon düzeltilmesi)

Atenüasyona uğrayan doku nonuniform ise (kardiyak çalışmalar gibi), hastadaki pikselin uzamsal lokasyonuna bağlı değişken atenüasyon katsayısı kullanan başka bir atenüasyon düzeltilme metodu gereklidir [54]. Bu durumda, atenüasyon düzeltilmesi iki taramadan elde edilen görüntülerle yapılır.

Boş tarama görüntüsü (I_{Blank}) ve transmisyon tarama görüntüsü (I_{Trans}) arasındaki her bir pikselin (i, j) sayısının oranı, piksel için atenüasyon düzeltilme faktörünü (ACF) verir ve Eş. 2.2'deki şekilde bulunur.

$$\text{ACF}(i, j) = \frac{I_{\text{Blank}}(i, j)}{I_{\text{Trans}}(i, j)} \quad (2.2)$$

Bu Eş. düzeltilmiş görüntü elde etme için emisyon taramasının piksel datasında uygulanan bir atenüasyon düzeltmesi haritası verir.

Bu düzeltme metodunda, boş taramadan elde edilen data gün içindeki bütün hastalar için kullanılabilir. Fakat, her bir hasta için ayrı çekilmesi gereken transmisyon ve emisyon taraması dataları üç yoldan elde edilebilir [58]. Sırasıyla elde etmede; her bir emisyon ve transmisyon tarama için ayrı tomografik tarama elde edilir. Eşzamanlı elde etmede; emisyon ve transmisyon görüntüleri her projeksiyon açısında ve bir tomografik rotasyonda aynı anda elde edilir. Eşzamanlı sırasıyla elde etmede; emisyon ve transmisyon görüntüleri birlikte, her bir projeksiyon açısı için sırasıyla ve bir tomografik rotasyonda elde edilir.

Atenüasyon düzeltmesi için kullanılan eşzamanlı transmisyon-emisyon taramasının önemli noktalarından biri, transmisyon kaynağı olarak uygun bir izotopun seçilmesidir. Bu izotop transmisyon ve emisyon pencereleri arasındaki karışmayı minimize etmek için seçilmelidir. Saçılan fotonlar yüksek enerji izotopundan düşük enerji izotopunun enerji penceresine düştüğünde karışma meydana gelir. Kardiyak SPECT için genellikle radyofarmasötik olarak ^{201}Tl ve $^{99\text{m}}\text{Tc}$ izotopları kullanıldığı için emisyon datasındaki karışmayı minimize etmek için, transmisyon izotopunun foton enerjisi genellikle bu iki emisyon izotopunun foton enerjisinden daha düşük seçilir. Transmisyon kaynaklarının yeniden doldurma ve yer değiştirmesini ortadan kaldırmak için, bu izotoplar genellikle uzun yarılanma ömürlüdür.

Şöyle bir sonuç çıkarılabilir: Sırasıyla elde etme modu eşzamanlı modan daha uygundur, çünkü bu metotta bu elde etme metodunda transmisyon taraması emisyon taramasından önce yapılır bu yüzden transmisyon ve emisyon verisinin kirlilik problemi ortadan kaldırılır. Ama şu da unutulmamalıdır ki, sırasıyla elde etme metodu görüntüleme zamanını artırır, bu sebeple iki tarama arası hastanın hareket etme ihtimalini yükseltir. Hastanın hareketi iki tarama verilerinin uzamsal birbirine eklenmesinde sorun oluşturabilir bu da atenüasyonu düzeltilmiş görüntüler hatalara yol açabilir [52, 59].

Transmisyon foton enerjisi enjekte edilen radyofarmasötiklerden yayılan fotonların enerjisinden farklı olduğu için, transmisyon kaynak enerjisinin atenüasyon katsayısını enjekte edilen radyofarmasötiğe dönüştürmek için bir ölçeklendirme faktörü uygulanmalıdır. Genel olarak kullanılan bir metoda göre μ_t , emisyon enerjisi E_e ve

transmisyon enerjisi E_t arasında lineer olarak değişmektedir ve böylece ölçülen transmisyon atenüasyon katsayıları $\mu_t(E_t)$, aşağıdaki Eş. 2.3 kullanılarak emisyon atenüasyon katsayılarıyla, $\mu_t(E_e)$ ilişkilendirilebilir.

$$\mu_t(E_e) = \frac{\mu_t^{tis}(E_e)}{\mu_t^{tis}(E_t)} \mu_t(E_t) \quad (2.3)$$

$\mu_t^{tis}(E_e)$ ve $\mu_t^{tis}(E_t)$ sırasıyla emisyon ve transmisyon izotopları için dokuların lineer atenüasyon katsayılarıdır [50].

Transmisyon kaynak metodu kullanılarak yapılan atenüasyon düzeltmesinin doğruluğu, kullanılan transmisyon kaynağının tipine, hastanın hareketsizliğine ve atenüasyon düzeltmesi için kullanılan geometriye bağlıdır. Kardiyak SPECT için tekli, ikili ya da üç başlı kamera kullanımının ve transmisyon kaynakları, detektör ve yönlendiricilerin farklı konfigürasyonlarının atenüasyon düzeltmesi üzerine etkileri üzerine çalışmalar da yapılmıştır. Her bir konfigürasyonun avantajları dezavantajları mevcuttur fakat ikinci konfigürasyon olan iki taramalı line kaynaklı 90° iki başlı SPECT sistemi, klinik transmisyon elde edimimleri için en uygun ve en sık kullanılan konfigürasyondur [60].

Bu bölüme kadar günümüzde atenüasyon düzeltmesi için en sık kullanılan yöntemlerden bahsedilmiştir. Chang metodu bizim tezimiz için uygun bir metot değildir çünkü bizim ilgilendiğimiz kalp bölgesi non-uniform yani düzgün olmayan bir yapıya sahiptir. Düzgün dağılıma sahip olmayan bölgeler için atenüasyon düzeltme haritası çıkarabilmek için bir eksternal kaynağa ihtiyaç vardır.

SPECT ve CT yöntemlerinin birleştirilmesiyle oluşturulan entegre SPECT/CT sistemi bu anlamda mevcut olarak kullanılmaktadır. Bu teknikte CT, sadece anatomik lokalizasyon ve atenüasyon düzeltmesi için kullanılır. SPECT görüntüsü, fonksiyonel ve moleküler düzeyde bilgi verir, CT ise bu bilginin hangi organ veya dokuya ait olduğunu gösterir. Bu iki görüntü sayesinde atenüasyonu düzeltilmiş görüntü elde edilebilir. Bu yöntemle 3 boyutlu görüntü elde edilebilir.


Fakat bu sistemin bazı dezavantajları mevcuttur. Hasta bu yöntemde, SPECT'teki radyasyona ek olarak CT kaynaklı x ışınına maruz kalmaktadır ki bu durum x ışınının

zararları göz önüne alınırsa istenilen bir durum değildir ve ek radyasyon anlamına gelmektedir. Zorunlu kalınmadıkça görüntüleme tekniklerinde tek işlem tercih edilir fakat bu yöntemde hastaya çift işlem uygulanmaktadır. Ayrıca bu sistem maliyet açısından yüksektir ve ulaşımı zordur. Bütün bunların yanında, teknik anlamda başarılı görülse bile, klinik tecrübesi beklenildiği kadar başarılı değildir.

Bizim amacımız ise, SPECT ile elde edilen görüntü haricinde, ek bir işleme gerek duyulmadan doğru teşhisi koyabilmektir. Bu şekilde yapılabilecek bir işlem sonrası hasta hem SPECT/CT için bahsedilen dezavantajları yaşamamış hem de anjiyografi gibi girişimsel bir işleme ihtiyaç duyulmadan doğru teşhis konulmasına yardımcı olabilecektir.

2.3.2. Meme atenüasyonu

SPECT ile gerçekleştirilen MPS’de karşılaşılan en büyük sorunlardan biri kadınlarda meme atenüasyonudur. Kadınlardaki farklı doku tiplerinden kaynaklı atenüasyon oluşmaktadır. Bu doku tipleri Şekil 2.10’da gösterilmiştir.



Şekil 2.10. Kadınlarda meme dokusu

Şekil 2.10’da görüldüğü gibi kadınlarda meme, farklı doku tipleri içermektedir. Bu dokular cinsine ve yoğunluğuna göre, gama ışımalarının SPECT’e ulaşmasını kısmen ya da tamamen engelleyebileceğinden atenüasyona neden olabilmektedir. Bu atenüasyonun hesaba

katılabilmesi için meme dokusuna ait atenüasyon katsayısının hesaplanması gerekir. Meme yapısının uniformitesi meme dokusu fantomları kullanılarak hesaplanmaktadır. Yapılan bir çalışmada 0 ve 100% glandüler doku bileşimli örnekler oluşturulmuş ve ölçülmüştür. Dahası, %50 glandüler doku bileşimli farklı örnekler oluşturulmuş ve simüle edilmiştir. %50 glandüler %50 yağ dokusu olan CIRS (Computerized Imaging Reference Systems) fantomu aynı metotla değerlendirilmiştir. Bu çalışmada elde edilen sonuçlar ile Hammerstein tarafından yayımlanan farklı insan göğüs dokularının karşılaştırılması yapılmıştır [61]. Yine başka bir çalışmada farklı kompozisyonlarla oluşturulan meme fantomları ile atenüasyon katsayıları hesaplanmış ve karşılaştırılmıştır [62]. Bu çalışmaların hepsinde farklı doku oranları kullanılarak meme dokusunu taklit eden fantomlar oluşturulmaya çalışılmıştır. Fakat meme dokusu her insanda farklılık gösterdiğinden, belli oranlarla oluşturulmuş fantomlardan elde edilen atenüasyon katsayıları ile gerçek bir atenüasyon düzeltmesi yapılamamaktadır.


Atenüasyon düzeltmesi gereken durumlar, kişilerin vücut kitle (Body Mass Index - BMI) indeksleriyle orantılı bir şekilde artmaktadır. Çalışmamızda kullanılan hastaların vücut kitle indeksleri ortalaması 32,33'tür.

Vücut kitle indeksi özellikle 30 ve daha yüksek olan hastalar için SPECT/MPS' lerinde atenüasyon düzeltmesi gerekmektedir. Hastanın vücut kitle indeksi arttıkça koroner anjiyografi sırasında maruz kaldığı radyasyon dozu artmaktadır. Yani BMI ve doz arasında doğru orantı vardır. Ayrıca, vücut kitle indeksi 40 veya üstü hastalar için yapılan çalışmada, SPECT ile miyokard görüntülemenin bu hasta grubu için, vücut kitle indeksi düşük olanlardan daha az uygun olduğu tespit edilmiştir [61, 63, 64] .

2.4. Görüntüde Doku Analizi

Doku, yumuşaklık, kabalık, derinlik ve düzenlilik gibi farklı görüntü özellikleriyle sezgisel olarak ilişkilendirilebilmesine rağmen, herkesin kabul ettiği tek bir tanıma sahip değildir [65]. Birçok araştırmacı farklı tanımlar kullanmışlardır. Genel olarak, görüntü boyunca küçük bir komşulukta pikselden piksele yerel parlaklık değişiklikleri olarak tanımlanabilir [66]. Alternatif bir şekilde, görüntünün bir bölgesindeki piksellerin gri seviyelerinin uzaysal dizilimlerini ifade eden bir özellik olarak da tanımlanabilir [67]. Şekil 2.11.'de

farklı doku görüntüleri verilmiştir. Bu görüntüler aynı siyah ve beyaz dağılımlara sahip olmasına rağmen farklı doku örnekleridir.



Şekil 2.11. (a) Aynı siyah ve beyaz dağılımlara sahip üç farklı doku örneği ve (b) histogramı

Doku analizi, medikal görüntüleme, uzaktan algılama ve endüstriyel denetleme gibi esas görevleri sınıflandırma, bölütleme ve birleştirme olan birçok alanda önemli rol oynamaktadır.

Doku analizi için çalışmalar çok çeşitlidir ve doku özelliklerinin çıkarılması için kullanılan metotlarla birbirinden ayrılmaktadır. Bu metotlar dört kategoride sıralanabilir: istatistiksel metotlar, yapısal metotlar, model tabanlı metotlar ve dönüşüm tabanlı metotlar. Doku analizi ile birlikte sınıflandırma modeli oluşturmak için çeşitli süreçler bulunmaktadır. Bu adımlar Şekil 2.12’de verilmiştir.



Şekil 2.12. Sınıflandırma modelinin oluşturulmasındaki iş akış şeması

2.4.1. Verilerin elde edilmesi

Başarılı bir sınıflandırma modelinin oluşturulabilmesi için ilk ve en önemli adımlardan biri verilerin elde edilmesidir. SPECT için elde edilmesi gereken veriler görüntülerdir. Bu görüntüler donanıma odaklı bir kaynak kullanılarak oluşturulur. Bu görüntülerin nasıl elde edildiği, SPECT görüntüleme bölümünde detaylı olarak açıklanmıştır. Doğru bir

sınıflandırma algoritması yaratabilmek için veri setinin yeterli sayıda görüntü içermesi gerekmektedir. Hangi sayıda verinin yeterli olacağı konusunda kesin bir kural yoktur. Her çalışma kendi özelinde farklı sayıda verilerden oluşabilir.


2.4.2. Görüntü bölütleme (segmentasyon)

Modern görüntüleme yöntemleriyle elde edilen görüntüler, teşhis daha sonrasında tedaviye yardımcı önemli detaylar içermektedir. Bu görüntülerin işlenmesinde ilk adım, istenilen organ ya da yapının ayrılmasıdır. Bir diğer ifadeyle ilgi bölgesinin (Region of Interest) çıkarılmasıdır. Bu aşama bölütleme olarak adlandırılır. Genellikle, bölütlemenin manuel olarak gerçekleştirilmesi her dilim için sınırların ayrı ayrı çizilmesinden dolayı çok fazla zaman alıcı bir işlemdir. Ayrıca bu işlem, yapan kişiye göre değişiklik göstereceğinden hatalı bölütleme olabilir. Bu bağlamda bilgisayar destekli bölütleme yapmak için çok sayıda algoritma teklif edilmiştir. Modern matematik ve fizik tekniklerinin birleştirilmesiyle, bölütleme sonuçlarının hassasiyetlerinde büyük gelişmeler olmuştur [68].

Ortak görüntülerin algoritmalarıyla karşılaştırıldığında, medikal uygulamalar için olan görüntülerin daha fazla arka plan kaldırılmasına ihtiyacı vardır. Medikal görüntü işlemede kullanılan görüntüler sadece vücut dışı görüntüler değil, aynı zamanda SPECT gibi değerlendirmesi uzmanlık gerektiren sistemlerden gelen görüntüler olduğundan, bölütleme yapılırken uzman doktorlarla birlikte hareket edilmesi gerekir.

Segmentasyon algoritmaları temel tekniklerine göre üç ana başlıkta sınıflandırılabilir, bunlar eşikleme tabanlı, kümeleme teknikleri tabanlı ve değişebilen model tabanlı algoritmalarıdır. Her bir algoritmanın kendine göre avantajları dezavantajları vardır. Mutlak en iyi algoritma yoktur. Örneğin bir görüntü seti için çok iyi bölütleme yapan bir algoritma farklı bir görüntü seti için başarısız bir bölütleme yapabilir.

Bazı bilim insanları, maksimum entropi değişmez moment, bulanık kümeleme ve Otsu gibi popüler eşikleme algoritmaları çalışmaktadır. Otsu algoritması, görüntü bölütlemede daha tatmin edici performans sergilemektedir, bu da sonucu güvence altına almaktadır [69]. Bu nedenle tez çalışmamızda yöntem olarak eşikleme tabanlı bir algoritma olan Otsu metodu tercih edilmiştir. Eşikleme yöntemleri Şekil 2.13'te gösterildiği gibi sınıflara ayrılabilir.



Şekil 2.13. Eşikleme teknikleri

Otsu metodu

Eşikleme görüntü segmentasyonu için önemli bir tekniktir. Bir çok araştırmacı mantıklı eşiklerin nasıl seçilmesi gerektiği üzerine farklı metotlar üzerine ciddi çalışmalar yapmaktadır. Çoğu eşikleme metodu, gri bir görüntüdeki nesnelerin gri seviyeler tarafından karakterize edildiği için, arka plandan nesneleri gri seviyelerin bir boyutlu histogramının ve gri seviyelerin iki boyutlu histogramının istatistikleri tabanlı çıkarmaktadır. Sıkça kullanılan bir yöntem olan Otsu metodu, sınıf arası varyansı maksimize ederek, global optimum eşiği seçmektedir. İki seviyeli eşiklemede gri seviyesi eşikten düşük olan pikseller arka plan, yüksek olanlar ön plan olarak belirlenir. Gri seviyelerin bir boyutlu histogramları sadece gri seviyeleri göz önünde bulundurur. Bu yüzden aynı histogramlı farklı görüntüler aynı eşik değerine sahip olacaktır. Abutaleb, bir boyutlu görüntü histogramını iki boyutlu görüntü histogramına uzatmıştır [70]. Bu sadece gri seviyeleri ve yerel ortalamayı ele almaktadır. Bir başka çalışmada ise iki boyutlu Otsu metodu aracılığıyla bir otomatik eşikleme önerilmiştir [71]. Bu metot gürültüleri gidermede iyidir fakat aman alıcıdır. Gong ve diğerleri, iki boyutlu eşikleme için hızlı tekrarlamalı bir algoritma teklif etmişlerdir [72]. Bölütlemenin etkisini daha da geliştirmek

için iki boyutlu eşikleme, üç boyutlu eşiklemeye genişletilmiştir [73]. Bu genişletilmiş yöntem, Fan ve diğerlerinin çalışmasında daha da geliştirilmiştir [74].

Bu bölümde Otsu metodunun matematiksel alt yapısından bahsedilmiştir.

Verilen bir görüntüdeki pikseller L ile ifade edilsin $[0, 1, \dots, L-1]$. i seviyesindeki piksellerin sayısı n_i ile ve piksellerin toplam sayısı Eş. 2.4.a ile gri seviye olasılığı p_i ise Eş. 2.4.b ile ifade edilir.

$$N = \sum_{i=1}^L n_i \quad (2.4.a)$$

$$p_i = \frac{n_i}{N}$$

$$p_i \geq 0, p_i = \frac{n_i}{N} \quad (2.4.b)$$

$$\sum_{i=1}^L p_i = 1$$

İki seviyeli eşikleme metodunda, görüntünün pikselleri t eşiklemsiyle $[0, 1, \dots, t]$ gri seviyeli C_1 ve $[t+1, \dots, L-1]$ gri seviyeli C_2 olmak üzere iki sınıfa bölünmüştür. İki sınıf için gri seviye olasılık dağılımları sırasıyla Eş. 2.5.a ve Eş. 2.5.b ile ifade edilir.

$$w_1 = \Pr(C_1) = \sum_{i=0}^t p_i \quad (2.5.a)$$

$$w_2 = \Pr(C_2) = \sum_{i=t+1}^{L-1} p_i \quad (2.5.b)$$

C_1 ve C_2 sınıflarının ortalaması sırasıyla Eş. 2.6.a ve 2.6.b ile gösterilmiştir

$$u_1 = \sum_{i=0}^t \frac{ip_i}{w_1} \quad (2.6.a)$$

$$u_2 = \sum_{i=t+1}^{L-1} \frac{ip_i}{w_2} \quad (2.6.b)$$

Gri seviyelerin toplam ortalaması u_t ile ifade edilir ve Eş. 2.7 ile bulunur.

$$u_T = w_1 u_1 + w_2 u_2 \quad (2.7)$$

Sınıf varyansları Eş. 2.8.a ve Eş.2.8.b ile elde edilir.

$$\sigma_1^2 \sum_{i=0}^t \frac{(i-u_1)^2 p_i}{w_1} \quad (2.8.a)$$

$$\sigma_1^2 \sum_{i=t+1}^{L-1} \frac{(i-u_2)^2 p_i}{w_2} \quad (2.8.b)$$

Sınıf içi varyans, sınıf arası varyans ve gri seviyelerin toplam varyansı sırasıyla Eş. 2.9.a, Eş. 2.9.b ve Eş. 2.9.c ile elde edilir.

$$\sigma_W^2 \sum_{k=1}^M w_k \sigma_k^2 \quad (2.9.a)$$

$$\sigma_B^2 = w_1 (u_1 - u_2)^2 + w_2 (u_2 - u_T)^2 \quad (2.9.b)$$

$$\sigma_Y^2 = \sigma_W^2 + \sigma_B^2 \quad (2.9.c)$$

Otsu metodu, toplam varyans (sınıf içi varyans ve sınıf arası varyans toplamı) farklı bölümlerde sabit olduğu için, sınıf arası varyansı maksimize ederek ki bu sınıf içi varyansı minimize etmekle aynıdır, optimum eşik değeri t 'yi Eş. 2.10 vasıtasıyla seçer.

$$t = \arg\{(0 \leq t \leq L - 1^{\max}) \{\sigma_B^2(t)\} = \arg\{(0 \leq t \leq L - 1^{\min}) \{\sigma_W^2(t)\} \quad (2.10)$$

Otsu metodu çok kademeli eşikleme metoduna genişletilebilir. Görüntüdeki pikselleri M sınıfa $\{C_1, C_2, \dots, C_M\}$ bölen $M-1$ eşik değeri vardır.

$$\{t_1, t_2, \dots, t_{M-1}\} = \arg\{(0 \leq t \leq L - 1^{\max}) \{\sigma_B^2(t_1, t_2, \dots, t_{M-1})\} \quad (2.11.a)$$

$$= \arg\{(0 \leq t \leq L - 1^{\min}) \{\sigma_W^2(t_1, t_2, \dots, t_{M-1})\} \quad (2.11.b)$$

$$w_j = \sum_{i=t_{j-1}+1}^{t_j} p_i \quad (2.11.c)$$

$$u_j = \sum_{i=t_{j-1}+1}^{t_j} \frac{ip_i}{w_j} \quad (2.11.d)$$

$$\sigma_j^2 = \sum_{i=t_{j-1}+1}^{t_j} \frac{(i-u_j)^2 p_i}{w_j} \quad (2.11.e)$$

$$\sigma_B^2 = \sum_{j=1}^M w_j (u_j - u_T)^2 \quad (2.11.f)$$

$$\sigma_W^2 = \sum_{j=1}^M w_j \sigma_j^2 \quad (2.11.g)$$

K-ortalamalar metodu

K-ortalamalar metodu, sınıf içi varyansın minimize edilmesiyle veri kümesinin parçalara ayrılmasıdır [73]. K-ortalamalar metodu, karelerin toplamı kriterini (sınıf içi varyans) minimize ederek k ayrık altkümelere ($C_1, C_2, \dots, C_k$) Eş. 2.12’de verildiği gibi bölmektedir.

$$J = \sum_{j=1}^k \sum_{n \in C_j} (x_n - U_j)^2 \quad (2.12)$$

x_n , n’inci veri noktasını ifade eden bir vektörü, j sınıfların indeksi ($1 < j < k$), U_j N_j veri noktalarını içeren C_j ’deki veri noktalarının ağırlık merkezidir.

Bu metodun amacı da Otsu metoduyla aynıdır ve eşikleme yaparak bölütleme yapılmasına imkân vermektedir. Görüntünün, $m \times n$ piksellli $[0, 1, \dots, L-1]$ arası gri seviyeli olduğu kabul edilecek olursa, (x, y) pozisyonundaki pikselin gri seviyesi $f(x, y)$ ile ifade edilir. Daha sonrasında, görüntü Eş. 2.13’teki veri matrisiyle gösterilebilir.

$$[F(x, y)]_N = [f(x, y)] \quad (2.13)$$

Burada, $N = m \times n$ ’dir. K- ortalamalar metodu, $[F(x, y)]_N$ veri matrisindeki noktaları ilk ağırlık merkezleri $[ic_1, ic_1, \dots, ic_k]$ ve son ağırlık merkezleri $[cc, cc_1, \dots, cc_k]$ ile k sınıfa böler.

Eşik seçme yöntemi olarak, K-ortalamaların prosedürü aşağıdaki adımlarla ifade dileyebilir.

1. İlk sınıf ağırlık merkezleri olarak k noktaları seçilir.
2. Her bir nesne merkezi kendisine en yakın olan sınıfa atanır.
3. Her nesne atandığında, k ağırlık merkezlerinin pozisyonları yeniden hesaplanır.

4. Ağırlık merkezlerinin pozisyonları artık değişmeyecek seviyeye gelinceye kadar 2 ve 3 adımları tekrarlanır.
5. En son bölümlerden eşikler bulunur.

İki seviyeli eşikleme metodunda, $k=2$, görüntüdeki en küçük ve en büyük gri seviyeleri ilk ağırlık merkezleri olarak seçilir. t eşik seviyesi son ağırlık merkezlerinin ortalaması hesaplanarak alınır. K-ortalamlar eşikleme metodu, $M-1$ tane eşik olduğu yerde, $k=M$ ayarlanarak çok seviyeli eşiklemeye uzatılabilir. Bu metotta, ilk ağırlık merkezlerini alışılmış olduğu gibi rasgele seçilmez. İlk ağırlık merkezi ic_1 ve ic_k , görüntüdeki en küçük ve en büyük gri seviyedir. i 'ninci ağırlık merkezi Eş. 2.14 ile ifade edilir.

$$ic_i = ic_1 + \frac{ic_k - ic_1}{k-1} \times (i - 1), 1 < i < k \quad (2.14)$$

j 'ninci eşik seviyesi t_j Eş. 2.15 ile seçilir.

$$t_j = 0,5(cc_j + cc_{j+1}), 1 \leq j \leq k - 1 \quad (2.15)$$

Şu noktaya dikkat çekilmelidir ki; k-ortalamları bölütleme sonuçları tek boyutlu veri seti açısından ilk ağırlık merkezlerinin düzenini korur. Bu yüzden, $1 \leq j \leq k-1$ için eşik değeri $t_j < t_{j+1}$ olur.

2.4.3. Doku özelliklerinin çıkarılması

Bir özellik, gözlenen işlemin bağımsız ölçülebilen bir niteliğidir. Geçen yıllar içerisinde makine öğrenmesi ve makine öğrenmesi uygulamalarında, özelliklerin tanım kümesi bu uygulamalarda kullanılan yüzlerce özellik ve değişkenlere kadar genişlemiştir. Zorlu işlemlerde sorun olan ilişkisiz ve gereksiz değişkenlerin azaltılması problemini irdelemek için birçok teknik geliştirilmiştir. Doku analizi yaklaşımları çok çeşitlidir ve özelliklerin çıkarılma yöntemleri yönünden birbirinden ayrılmaktadır. Doku analizi yöntemleri 4 kategoride sınıflandırılabilir; istatistiksel metotlar, yapısal metotlar, model-tabanlı metotlar ve dönüşüm-tabanlı metotlardır. İstatistiksel doku analizi, görüntüdeki bölgelerin dokusunu gri seviye histogramlarının yüksek-derece momentleri aracılığıyla tanımlar [75]. Yapısal doku analizi tekniği, düzenli yerleştirilmiş paralel satırlar gibi iyi tanımlanmış

doku elemanlarının birleşimi olarak bir dokuyu tanımlar. Doku elemanlarının yerleştirme kuralları ve özellikleri görüntü dokusunu tanımlar. Yapı elemanlarının farklı şekillerinin kullanılmasından ideal dokuların bozulmuş versyonları olarak tasarlanan gerçek dokulara kadar bir alanda çeşitli yapısal doku analizi yaklaşımları teklif edilmiştir [76, 77]. Model-tabanlı doku analiz teknikleri kendi komşuluğundaki piksel yoğunluklarının ağırlıkları ortalaması tabanlı olarak, görüntüdeki her bir pikselin deneysel modelini oluşturur. Görüntü modellerinin tahmini parametreleri doku özelliklerinin tanımlayıcıları olarak kullanılır. Dönüşüm-tabanlı doku analizi teknikleri piksel yoğunluk varyasyonlarının uzaysal frekans özelliklerini kullanarak görüntüyü yeni bir forma dönüştürür. Bu yöntemin başarısı, görüntüden doku karakteristiklerini çıkarmak için kullanılan dönüşüm türüne dayanmaktadır.


Doku özelliklerinin istatistiksel tabanlı çıkarılması

Doku analizi kullanılarak bir görüntüyü incelemek için, görüntü üç-boyutlu (3D) doku yüzeyi gibi düşünülebilir. İstatistiksel doku analizi yöntemleri üç sınıfa ayrılır. Bunlar; birinci-derece, ikinci-derece ve yüksek-derece doku analizi yöntemleridir. Birinci-derece istatistiksel doku analizinde dokudaki bilgi görüntü yoğunluğu histogramından çıkarılır. Bu yaklaşım rasgele bir görüntü pozisyonundaki belirli bir gri seviye değerinin frekansını ölçer ama pikseller arası korelasyonları veya eş-oluşumları hesaba katmaz. İkinci-derece istatistiksel doku analizinde, dokudaki bilgi rasgele uzaklıklardaki gri seviye çiftlerinin bulunma olasılığı ve görüntünün tamamındaki yönelimler tabanlıdır. Yüksek-seviye istatistiklere genişletilmesi çalışılan verilerin sayılarının artırılmasını içerir.

Doku çalışması için kullanılan birçok geleneksel yaklaşım görüntü dokularıyla ilişkili özellikleri hesaplamak için 2D metotları kullanılası üzerine odaklanmıştır. Şekil 2.14'te gösterilmiştir. Bu geleneksel yaklaşım özgün özelliklerle farklı görüntü dokularını geniş bir biçimde tanımlamak için kullanılır ve çok farklı alanlarda uygulamaları mevcuttur. Fakat gelişen teknolojiyle birlikte özellikle de medikal alanda 3 boyutlu görüntüler daha detaylı bilgi sağladığı için, 3 boyutlu özellik çıkarma daha popüler hale gelmiştir.

İzotropik kaliteye yakın 3D medikal görüntü datasının yaygınlaşmasıyla, patolojileri ayırt etmek için sayısal ölçümler türetebilen yapay zeka metotlarına artan bir talep olmaktadır.

Bu bölümdeki özelliklerin ifade edilmesinde, eşitliklerin belirtilmesinde ve örnek matrislerin gösterilmesinde Pyradiomics modelinden faydalanılmıştır [78].



Şekil 2.14. İstatistiksel tabanlı özellikler

Birinci derece istatistiksel doku analizi

Birinci derece istatistikler, sıkça kullanılan maske ve temel metrikler tarafından tanımlanan görüntü bölgesi içindeki vöksel yoğunluklarının yoğunluklarını tanımlar. X , ROI'deki N_p vöksellerinin bir dizisidir. $P(i)$, N_g 'nin, 0'dan başlayarak eşit aralıklı tanımlanan bir değer aralıklı parametreyle elde edilmesiyle oluşturulan sıfır olmayan değer aralıkları sayısıdır. $p(i)$, normalize edilmiş birinci derece histogramdır ve $\frac{P(i)}{N_p}$ denkleminde eşittir. Birinci derece istatistiksel doku analizi bu Eşitlikler kullanılarak dokunun özellikleri çıkarılır.

Enerji

Eş. 2.16'daki gibi ifade edilir. Burada c , X 'teki negatif değerlerden korunmak için yoğunlukları değiştiren isteğe bağlı bir değerdir. Bu işlem, enerjiye az katkı sağlasa da, 0'a en yakın gri seviye yoğunluklu vöksellerin yerine en düşük gri seviyeli vöksellerin bulunmasını sağlar. Enerji, bir görüntüdeki vöksel değerlerinin büyüklüğünün bir ölçümüdür. Daha büyük değerler, bu değerlerin karelerinin toplamının daha büyük olması anlamına gelir.

$$\text{enerji} = \sum_{i=1}^{N_p} (X(i) + c)^2 \quad (2.16)$$

Toplam enerji

Eş. 2.17'deki gibi ifade edilir. Burada yine c , X 'teki negatif değerlerden korunmak için yoğunlukları değiştiren isteğe bağlı bir değerdir. Bu denklem, enerjiye az katkı sağlasa da, 0'a en yakın gri seviye yoğunluklu voksellerin yerine en düşük gri seviyeli voksellerin bulunmasını garanti eder. Toplam enerji, kübik mm'de vokselin hacmi tarafından ölçeklendirilmiş enerji özelliği değeridir.

$$\text{Toplam enerji} = V_{\text{voksel}} \sum_{i=1}^{N_p} (X(i) + c)^2 \quad (2.17)$$

Entropi

Eş. 2.18'deki gibi ifade edilir. Burada ϵ , rasgele belirlenmiş pozitif küçük bir değerdir. Entropi, görüntü değerlerindeki belirsizlik ve rastlantısallığı belirtir. Bu, görüntü değerlerini şifrelemek için gerekli bilginin ortalama miktarını ölçer.

$$\text{entropi} = - \sum_{i=1}^{N_g} p(i) \log_2(p(i) + \epsilon) \quad (2.18)$$

Minimum

X 'in minimum değeridir.

10'uncu yüzdellik

X 'in 10'uncu yüzdeliğidir.

90'ıncı yüzdellik

X 'in 90'ıncı yüzdeliğidir.

Maksimum

X 'in maksimum değeridir.

Ortalama

ROI'deki ortalama gri seviye yoğunluğudur. Eş. 2.19'daki gibi bulunur.

$$\text{Ortalama} = \frac{1}{N_p} \sum_{i=1}^{N_p} X(i) \quad (2.19)$$

Medyan

ROI'deki medyan gri seviye yoğunluğudur.

Çeyrekler arası aralık

P_{25} ve P_{75} görüntü dizisinin sırasıyla 25'inci ve 75'inci yüzdelikleridir. Eş. 2.20'deki gibi bulunur.

$$\text{çeyrekler arası aralık} = P_{75} - P_{25} \quad (2.20)$$

P_{25} ve P_{75} görüntü dizisinin sırasıyla 25'inci ve 75'inci yüzdelikleridir.

Alan

ROI'deki gri değerlerin aralığıdır. Eş. 2.21'deki gibi bulunur.

$$\text{alan} = \max(X) - \min(X) \quad (2.21)$$

Ortalama mutlak sapma (MAD)

Ortalama mutlak sapma, görüntü dizisinin ortalama değerden bütün yoğunluk değerlerinin ortalama uzaklığıdır. Eş. 2.22'deki gibi bulunur.

$$\text{MAD} = \frac{1}{N_p} \sum_{i=1}^{N_p} |X(i) - \bar{X}| \quad (2.22)$$

Dayanıklı ortalama mutlak sapma (rMAD)

Dayanıklı ortalama mutlak sapma, 10'uncu 90'ıncı yüzdeliklere eşit veya arasında gri seviyelerle görüntü kümesinin alt kümesinde, bütün yoğunluk değerlerinin ortalama değerden uzaklığının ortalamasıdır. Eş. 2.23'teki gibi ifade edilir.

$$rMAD = \frac{1}{N_{10-90}} \sum_{i=1}^{N_{10-90}} |X_{10-90}(i) - \bar{X}_{10-90}| \quad (2.23)$$

Karekök ortalama (RMS)

Eş. 2.24'teki gibi ifade edilir. Burada c , X 'teki negatif değerlerden korunmak için yoğunlukları değiştiren isteğe bağlı bir değerdir. Bu, enerjiye az katkı sağlasa da, 0'a en yakın gri seviye yoğunluklu voksellerin yerine en düşük gri seviyeli voksellerin bulunmasını garanti eder. RMS, bütün karesi alınmış değerlerin ortalamalarının kareköküdür. Bu, görüntü değerlerinin büyüklüğünün farklı türlü bir ölçümüdür. Bu özellik hacim etki karışımıdır ve daha büyük c değeri hacim etki karışımının etkisini artırmaktadır.

$$RMS = \sqrt{\frac{1}{N_p} \sum_{i=1}^{N_p} (X(i) + c)^2} \quad (2.24)$$

Standart sapma

Standart sapma, varyasyon miktarını ya da ortalama değerden dağılımını ölçer. Eş. 2.25'teki gibi ifade edilir.

$$\text{standart sapma} = \sqrt{\frac{1}{N_p} \sum_{i=1}^{N_p} (X(i) - \bar{X})^2} = \sqrt{\text{varyans}} \quad (2.25)$$

Çarpıklık

μ_3 3'üncü merkezi momenttir. Çarpıklık, ortalama değerle ilgili değerlerin dağılımının asimetrisini ölçer. Bu değer, dizinin nereye uzatıldığına ve kütle dağılımının nerede yoğunlaştığına göre pozitif veya negative olabilir. Eş. 2.26'daki gibi elde edilir.

$$\text{çarpıklık} = \frac{\mu_3}{\sigma^3} = \frac{\frac{1}{N_p} \sum_{i=1}^{N_p} (X(i) - \bar{X})^3}{\left(\frac{1}{N_p} \sum_{i=1}^{N_p} (X(i) - \bar{X})^2 \right)^{3/2}} \quad (2.26)$$

Basıklık

Eş. 2.27'deki gibi elde edilir.

$$\text{basıklık} = \frac{\mu_4}{\sigma^4} = \frac{\frac{1}{N_p} \sum_{i=1}^{N_p} (X(i) - \bar{X})^4}{\left(\frac{1}{N_p} \sum_{i=1}^{N_p} (X(i) - \bar{X})^2 \right)^2} \quad (2.27)$$

Varyans

Varyans, ortalama değerden her bir yoğunluk değerinin uzaklıklarının karelerinin ortalamasıdır. Bu ortalama ile ilgili dağılım yayılmasının bir ölçümüdür. Varyans, σ^2 ile tanımlanır ve Eş. 2.28 ile hesaplanır.

$$\text{varyans} = \frac{1}{N_p} \sum_{i=1}^{N_p} (X(i) - \bar{X})^2 \quad (2.28)$$

Tekdüzelik

Tekdüzelik, her bir yoğunluk değerinin karelerinin toplamının bir ölçümüdür. Bu, daha büyük tekdüzeliğin daha büyük homojenite veya daha küçük aralıklı ayırık yoğunluk değerleri anlamına geldiği yerde görüntü dizisinin homojenitesinin bir ölçümüdür. Nasıl elde edildiği Eş. 2.29'da gösterilmiştir.

$$\text{tekdüzelik} = \sum_{i=1}^{N_g} p(i)^2 \quad (2.29)$$

İkinci derece istatistiksel doku analizi

Bu analiz yönteminde, görüntünü matrisinin iki gri seviye değerinin birbiriyle olan ilişkileri araştırılır. $N_g * N_g$ büyüklüğündeki bir gri-seviye eş oluşum matrisi (Gray Level Co-occurrence Matrix, GLCM), mask tarafından sınırlandırılan bir görüntü bölgesinin

ikinci derece bileşik olasılığını ifade eder ve $P(i,j|\delta,\theta)$ ile tanımlanır. Bu matrisin (i,j) 'inci elementi, görüntüdeki iki pikselde i ve j seviyelerinin kombinasyonunun bulunma sayısını belirtir. Bu seviye değerleri, piksellerin θ açısı boyunca δ uzaklığı ile ayrılmıştır. Merkez vokselten δ uzaklığı sonsuz norma göre uzaklık olarak tanımlanır. $\delta=1$ için, 3 boyutta 13 açının her biri için 2 komşuluktaki 26 bağlantı ve $\delta=2$ için 98- bağlantı (49 özgün açı) sonuçlarıdır.

İki boyutlu bir örnek olarak, I matrisi 5 farklı gri seviye içeren 5×5 'lik bir görüntüdür. Şekil 2.15'de verilmiştir.

$\delta=1$ uzaklığı (her bir pikselin birbirinden uzaklığının 1 piksel olduğu göz önünde bulundurularak) ve $\theta=0^\circ$ açısı için (yatay eksen, merkez voksellerin solundaki ve sağındaki vokseller), Şekil 2.15'deki simetrik GLCM elde edilir.

$$I = \begin{bmatrix} 1 & 2 & 5 & 2 & 3 \\ 3 & 2 & 1 & 3 & 1 \\ 1 & 3 & 5 & 5 & 2 \\ 1 & 1 & 1 & 1 & 2 \\ 1 & 2 & 4 & 3 & 5 \end{bmatrix} \quad P = \begin{bmatrix} 6 & 4 & 3 & 0 & 0 \\ 4 & 0 & 2 & 1 & 3 \\ 3 & 2 & 0 & 1 & 2 \\ 0 & 1 & 1 & 0 & 0 \\ 0 & 3 & 2 & 0 & 2 \end{bmatrix}$$

(a) (b)

Şekil 2.15. (a) Örnek bir görüntü matrisi (b) Bu matris için oluşturulmuş gri-seviye eş oluşum matrisi

Pyradiomics modelinde GLCM'ye ait özelliklerin çıkarılması gerekli parametreler ve Eş. ler aşağıdaki şekilde tanımlanmıştır:

ε rasgele seçilmiş bir pozitif sayıdır. $P(i,j)$ herhangi bir δ ve θ için eş-oluşum matrisidir. $p(i,j)$ normalize edilmiş eş-oluşum matrisidir ve Eş. 2.30.a'ya eşittir. N_g farklı yoğunluk seviyelerinin sayısıdır. Marjinal satır olasılıkları, Eş. 2.30.b, marjinal sütun olasılıkları Eş. 2.30.c'deki gibi ifade edilir. μ_x , p_x 'in ortalama gri seviye yoğunluğudur ve Eş. 2.30.d ile, μ_y , p_y 'in ortalama gri seviye yoğunluğudur ve Eş. 2.30.e ile tanımlanır, p_x 'in standart sapması, σ_y , p_y 'in standart sapmasıdır.

$$\frac{P(i,j)}{\sum P(i,j)} \quad (2.30.a)$$

$$p_x(i) = \sum_{j=1}^{N_g} P(i,j) \quad (2.30.b)$$

$$p_y(j) = \sum_{i=1}^{N_g} P(i,j) \quad (2.30.c)$$

$$\mu_x = \sum_{i=1}^{N_g} p_x(i)i \quad (2.30.d)$$

$$\mu_y = \sum_{j=1}^{N_g} p_y(j)j \quad (2.30.e)$$

$$p_{x+y}(k) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i,j) \text{ eğer } i+j = k \text{ ve } k = 2,3 \dots, 2N_g \quad (2.30.f)$$

$$p_{x-y}(k) = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i,j) \text{ eğer; } |i-j| = k \text{ ve } k = 0,1, \dots, N_g - 1 \quad (2.30.g)$$

$$HX = -\sum_{i=1}^{N_g} p_x(i) \log_2 p_x(i) + \epsilon \quad (2.30.h)$$

$$HY = -\sum_{j=1}^{N_g} p_y(j) \log_2 p_y(j) + \epsilon \quad (2.30.i)$$

$$p(i,j)\text{'nin entropisi: } HXY = -\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i,j) \log_2(p(i,j) + \epsilon) \quad (2.30.j)$$

$$HXY1 = -\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i,j) \log_2(p_x(i)p_y(j) + \epsilon) \quad (2.30.k)$$

$$HXY2 = -\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p_x(i)p_y(j) \log_2(p_x(i)p_y(j) + \epsilon) \quad (2.30.l)$$

$$W = e^{-\|d\|^2} \quad (2.30.m)$$

Başlangıç ayarı olarak, bu değerlerin ortalaması geri döndükten sonra, özelliğin değeri GLCM’de her bir açı için ayrı ayrı heasplanır.Eğer uzaklık ağırlıklandırılmasına izin verilirse, gri seviye eş oluşturma matrisleri W ağırlıklandırma fakörüyle ağırlıklandırılır,daha

sonrasında toplanır ve normalize edilir. Özellikler daha sonrasında sonuç matrisinde hesaplanır. W, komşuluk vokselleri arasındaki uzaklık için Eş. 2.30.m ile hesaplanır. Burada d, ilişkili açısı için uzaklıktır.

Otokorelasyon

Otokorelasyon, dokunun hassasiyetinin ve kabalığının büyüklüğünü ölçer ve Eş. 2.31 ile ifade edilir.

$$\text{otokorelasyon} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i,j)ij \quad (2.31)$$

Birleşik ortalama

i dağılımının gri seviye yoğunluğunun ortalamasını verir. Eş. 2.32 ile ifade edilir.

$$\text{birleşik ortalama} = \mu_x = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i,j)i \quad (2.32)$$

Küme uzantısı

Küme uzantısı , GLCM'nin çarpıklık ve asimetrisinin bir ölçümüdür. Daha yüksek bir değer, daha düşük bir değer ortalama değere yakın bir tepe değeri gösteriyorken ortalama ile ilgili daha fazla asimetrisi ifade eder. Aynı zamanda ortalama ile ilgili da düşük varyasyon anlamına gelir. Eş. 2.33 ile ifade edilir.

$$\text{Küme uzantısı} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i + j - \mu_x - \mu_y)^4 p(i,j) \quad (2.33)$$

Küme eğilimi

Küme eğilimi, benzer gri seviye değeli voksellerin gruplanması ölçümüdür. Eş. 2.34 ile ifade edilir.

$$\text{küme eğilimi} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i + j - \mu_x - \mu_y)^2 p(i,j) \quad (2.34)$$

Zıtlık

Zıtlık, yerel yoğunluk varyasyonlarının bir ölçümüdür. Daha büyük değerler, komşu vokseller boyunca yoğunluk değerlerindeki daha büyük farklılıklarla koreledir. Eş. 2.35 ile ifade edilir.

$$\text{zıtlık} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - j)^2 p(i, j) \quad (2.35)$$

Korelasyon

Korelasyon, GLCM'deki sıralı voksellerine göre gri seviye değerlerinin lineer bağımlılığını 0 (korele değil) ve 1 (tam korele) arasında gösteren bir değerdir. Eş. 2.36 ile ifade edilir.

$$\text{korelasyon} = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) ij - \mu_x \mu_y}{\sigma_x(i) \sigma_y(j)} \quad (2.36)$$

Fark ortalaması

Ortalama fark, farklı yoğunluk değerli oluşum çiftlerinin ve aynı yoğunluklu oluşum çiftleri arasındaki ilişkiyi ölçer. Eş. 2.37 ile ifade edilir.

$$\text{fark ortalaması} = \sum_{k=0}^{N_g-1} k p_{x-y}(k) \quad (2.37)$$

Fark entropisi

Fark entropisi, komşuluk yoğunluk değerleri farklarındaki rastgelelik ve değişkenliğin bir ölçümüdür. Eş. 2.38 ile ifade edilir.

$$\text{fark entropisi} = \sum_{k=0}^{N_g-1} p_{x-y}(k) \log_2(p_{x-y}(k) + \epsilon) \quad (2.38)$$

Fark varyansı

Fark varyansı, ortalamadan sapan farklı yoğunluk seviye çiftlerinde bulunan yüksek ağırlıkların heterojenliğinin bir ölçümüdür. Eş. 2.39 ile ifade edilir.

$$\text{fark varyansı} = \sum_{k=0}^{N_g-1} (k - DA)^2 p_{x-y}(k) \quad (2.39)$$

Benzeşmezlik

Benzeşmezlik Eş. 2.40 ile elde edilir.

$$\text{benzeşmezlik} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} |i - j| p(i, j) \quad (2.40)$$

Enerji

Enerji, görüntüdeki homojen örüntülerin bir ölçümüdür. Daha büyük enerji, yüksek frekanslarda birbirine komşu olan görüntüdeki yoğunluk değer çiftlerinin daha fazla örneklerinin olduğu anlamına gelir. Eş. 2.41 ile ifade edilir.

$$\text{enerji} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (p(i, j))^2 \quad (2.41)$$

Entropi

Entropi, komşuluk yoğunluk değerleri farklarındaki rasgelelik ve değişkenliğin bir ölçümüdür. Eş. 2.42 ile ifade edilir.

$$\text{entropi} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \log_2(p(i, j) + \epsilon) \quad (2.42)$$

Homojenlik

Homojenlik Eş. 2.43 ile elde edilir.

$$\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{p(i, j)}{1 + |i - j|} \quad (2.43)$$

Korelasyon düzensiz ölçümü 1 (IMC 1)

IMC 1 $I(x,y)$ ortak bilgisini kullanarak i ve j arasındaki olasılık dağılımlarının korelasyonunun değerlendirir. Eş. 2.44.a ile ifade edilir.

$$IMC\ 1 = \frac{HXY - HXY1}{\max\{HX, HY\}} \quad (2.44.a)$$

$$\begin{aligned} I(i, j) &= \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \log_2 \left(\frac{p(i, j)}{p_x(i)p_y(j)} \right) \\ &= \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \left(\log_2(p(i, j)) - \log_2(p_x(i)p_y(j)) \right) \\ &= \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \log_2(p(i, j)) - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \log_2(p_x(i)p_y(j)) \\ &= -HXY + HXY1 \end{aligned} \quad (2.44.b)$$

Korelasyon düzensiz ölçümü 2 (Informal Measure of Correlation - IMC 2)

IMC 2 $I(x,y)$ i ve j arasındaki olasılık dağılımlarının korelasyonunun değerlendirir. Eş. 2.45 ile ifade edilir.

$$IMC\ 2 = \sqrt{1 - e^{-2((HXY2 - HXY))}} \quad (2.45)$$

Ters fark momenti (IDM)

Ters fark momenti görüntünün yerel homojenliğini ölçer. Ters fark momentinin ağırlıkları zıtlık ağırlıklarının tersidir. Eş. 2.46 ile ifade edilir.

$$IDM = \sum_{k=0}^{N_g-1} \frac{p_{x-y}(k)}{1+k^2} \quad (2.46)$$

Normalize ters fark momenti (IDMN)

Ters fark momenti görüntünün yerel homojenliğini ölçer. Ters fark momentinin ağırlıkları zıtlık ağırlıklarının tersidir (GCLM'deki diyagonalden ($i=j$) üstelliği azaltarak). Eş. 2.47 ile ifade edilir.

$$IDMN = \sum_{k=0}^{N_g-1} \frac{p_{x-y}(k)}{1 + \left(\frac{k^2}{N_g^2}\right)} \quad (2.47)$$

Ters fark (ID)

Ters fark, bir görüntünün yerel homojenliğinin bir diğer ölçümüdür. Daha fazla tekdüze gri seviyelerle, payda düşük kalacağı için ve genel olarak yüksek bir değer elde edilir. Eş. 2.48 ile ifade edilir.

$$ID = \sum_{k=0}^{N_g-1} \frac{p_{x-y}(k)}{1+k} \quad (2.48)$$

Normalize ters fark (IDN)

Normalize ters fark, bir görüntüye ait yerel homojenliği ölçen bir parametredir. IDN, komşu yoğunluk değerleri arasındaki farkları, farklı yoğunluk değerlerinin toplam miktarına bölerek normalize eder. Eş. 2.49 ile ifade edilir.

$$IDN = \sum_{k=0}^{N_g-1} \frac{p_{x-y}(k)}{1 + \left(\frac{k}{N_g}\right)} \quad (2.49)$$

Ters varyans

k=0 olduğu durumlar hariç ters varyans bulunabilir. Eş. 2.50 ile ifade edilir.

$$\text{ters varyans} = \sum_{k=0}^{N_g-1} \frac{p_{x-y}(k)}{k^2} \quad (2.50)$$

Maksimum olasılık

Maksimum olasılık komşu yoğunluk değerlerinin en baskın olanının oluşum sayısıdır. Eş. 2.51 ile ifade edilir.

$$\text{maksimum olasılık} = \max(p(i, j)) \quad (2.51)$$

Toplam ortalama

Toplam ortalama, yüksek yoğunluk değerli çiftlerin oluşumu ve düşük yoğunluk değerli çiftlerinin oluşumu arasındaki ilişkiyi ölçer. Eş. 2.52 ile ifade edilir.

$$\text{toplam ortalama} = \sum_{k=2}^{2N_g} p_{x+y}(k)k \quad (2.52)$$

Toplam entropi

Toplam entropi, komşu yoğunluk değerlerinin farklarının toplamıdır. Eş. 2.53 ile ifade edilir.

$$\text{toplam entropi} = \sum_{k=2}^{2N_g} p_{x+y}(k) \log_2(p_{x+y}(k) + \epsilon) \quad (2.53)$$

Karelerin toplamı

Karelerin toplamı, GLCM'deki ortalama yoğunluk seviyesiyle ilgili komşu yoğunluk seviyelerinin dağılımındaki bir ölçümdür. Eş. 2.54 ile ifade edilir.

$$\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - \mu_x)^2 p(i, j) \quad (2.54)$$

Yüksek derece istatistiksel doku analizi

Yüksek derece istatistiksel özellikler için doku görüntülerindeki üç ve ya daha fazla pikseller arasındaki ilişkiler değerlendirilir. Bu özelliklerin çıkarılması için çeşitli matrisler oluşturulur.

Gri seviye koşu uzunluğu matrisi (Gray level run length matrix - GLRLM)

Bir gri seviye koşu uzunluğu matrisi, aynı gri seviye değerlerine sahip ardışık piksellerin sayısının uzunluğu olarak tanımlana gri seviye koşularının sayısını ölçer. $P(i, j | \theta)$ gri seviye koşu uzunluğu matrisindeki, (i, j) 'inci eleman ilgili bölgedeki (ROI) θ açısı boyunca

i gri seviyeli ve j uzunluklu koşuların sayısını ifade eder. 5 farklı gri seviyeli, iki boyutlu 5×5 bir örnek I matrisi Şekil 2.16. a’da verilmiştir.

$$\mathbf{I} = \begin{bmatrix} 5 & 2 & 5 & 4 & 4 \\ 3 & 3 & 3 & 1 & 3 \\ 2 & 1 & 1 & 1 & 3 \\ 4 & 2 & 2 & 2 & 3 \\ 3 & 5 & 3 & 3 & 2 \end{bmatrix} \quad \mathbf{P} = \begin{bmatrix} 1 & 0 & 1 & 0 & 0 \\ 3 & 0 & 1 & 0 & 0 \\ 4 & 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 & 0 \\ 3 & 0 & 0 & 0 & 0 \end{bmatrix}$$

(a) (b)

Şekil 2.16. (a) Örnek bir I matrisi (b) I matrisine ait gri seviye koşu uzunluğu matrisi

0 derecenin yatay yönlü olduğu durumda, $\theta=0$ için GLRLM şekil 2.16. (b)’deki gibi olur.

N_g görünüşteki farklı yoğunluk değerlerinin sayısı, N_r görüntüdeki farklı koşu uzunluklarının sayısı, N_p görüntüdeki voksellerin sayısı, $N_r(\theta)$ θ açısı boyunca görüntüdeki koşuların sayısıdır ve Eş. 2.55 ile ifade edilir.

$$\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} P(i, j | \theta), 1 \leq N_r(\theta) \leq N_p \quad (2.55)$$

$P(i, j | \theta)$ rasgele bir θ yönü için bir koşu uzunluğu matrisi olsun. $P(i, j | \theta)$, Eş. 2.56’daki gibi tanımlanan normalize koşu uzunluğu matrisidir.

$$P(i, j | \theta) = \frac{P(i, j | \theta)}{N_r(\theta)} \quad (2.56)$$

Varsayılan ayar olarak, ayrı ayrı her bir açı için GLRLM’de hesaplanan özellik değeri daha sonrasında bu değerlerin ortalaması olarak geri döner. Uzaklık ağırlıklandırma sağlanırsa, koşu uzunluğu matrisleri komşu vokseller arasında uzaklıklarla ağırlıklandırılır daha sonrasında toplanır ve normalize edilir. Sonrasında özellikler sonuç matrisinde hesaplanır. Her açı için komşu vokseller arası uzaklık hesaplanır.

Kısa koşu vurgusu (SRE)

SRE, kısa koşu uzunluklarının daha büyük değer göstergeleriyle ve daha hassas dokularla kısa koşu uzunluklarının dağılımının bir ölçümüdür. Eş. 2.57'deki gibi ifade edilir.

$$SRE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} \frac{P(i, j|\theta)}{j^2}}{N_r(\theta)} \quad (2.57)$$

Uzun koşu vurgusu (LRE)

LRE, uzun koşu uzunluklarının daha büyük değer göstergeleriyle ve daha kaba yapısal dokularla uzun koşu uzunluklarının dağılımının bir ölçümüdür. Eş. 2.58'deki gibi ifade edilir.

$$LRE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} P(i, j|\theta) j^2}{N_r(\theta)} \quad (2.58)$$

Gri seviye değişebilirliği (GLN)

GLN, düşük gri seviye değişebilirliği değerlerinin yoğunluk değerlerinde büyük benzerlik içerisinde olduğu durumda görüntüdeki gri seviye yoğunluk değerlerinin benzerliğini ölçer. Eş. 2.59 ile ifade edilir.

$$GLN = \frac{\sum_{i=1}^{N_g} \left(\sum_{j=1}^{N_r} P(i, j|\theta) \right)^2}{N_r(\theta)} \quad (2.59)$$

Normalize gri seviye düzensizliği (GLNN)

GLNN, GLN ile aynı benzerliği ölçer fakat GLN'nin normalize edilmiş halidir. Eş. 2.60 ile ifade edilir.

$$GLNN = \frac{\sum_{i=1}^{N_g} \left(\sum_{j=1}^{N_r} P(i, j|\theta) \right)^2}{N_r(\theta)^2} \quad (2.60)$$

Koşu uzunluğu değişebilirliği (RLN)

RLN, görüntüdeki koşu uzunlukları boyunca daha fazla homojenliği gösteren düşük değerlerle birlikte görüntü boyunca koşu uzunluklarının benzerliğini ölçer. Eş. 2.61 ile ifade edilir.

$$RLN = \frac{\sum_{j=1}^{N_r} \left(\sum_{i=1}^{N_g} p(i, j | \theta) \right)^2}{N_r(\theta)} \quad (2.61)$$

Normalize koşu uzunluğu düzensizliği (RLNN)

Bu parametre, RLN'nin normalize edilmiş halidir. Eş. 2.62 ile ifade edilir.

$$RLNN = \frac{\sum_{j=1}^{N_r} \left(\sum_{i=1}^{N_g} p(i, j | \theta) \right)^2}{N_r(\theta)^2} \quad (2.62)$$

Koşu yüzdesi (RP)

Koşu yüzdesi, ROI'deki voksellerin ve koşuların sayısının oranlarının sayısını alarak dokunun kabalığını ölçer. $1/N_p \leq RP \leq 1$ aralığındaki değerler, ROI'nin büyük bir bölümünü içeren yüksek değerlerle kısa koşulardan oluşur. Eş. 2.63'teki gibi ifade edilir.

$$RP = \frac{N_r(\theta)}{N_p} \quad (2.63)$$

Gri seviye varyansı (GLV)

GLV, koşular için gri seviye yoğunluğundaki varyansı ölçer. Eş. 2.64.b ile ifade edilir.

$$\mu = \sum_{i=1}^{N_g} \sum_{j=1}^{N_r} p(i, j | \theta) i \quad (2.64.a)$$

$$GLV = \sum_{i=1}^{N_g} \sum_{j=1}^{N_r} p(i, j | \theta) (i - \mu)^2 \quad (2.64.b)$$

Koşu uzunluğu varyansı (RLV)

RLV, koşu uzunlukları için koşulardaki varyansı ölçer. Eş. 2.65.b ile ifade edilir.

$$\mu = \sum_{i=i}^{N_g} \sum_{j=1}^{N_r} p(i, j|\theta)j \quad (2.65.a)$$

$$RLV = \sum_{i=i}^{N_g} \sum_{j=1}^{N_r} p(i, j|\theta)(j - \mu)^2 \quad (2.65.b)$$

Koşu entropisi (RE)

ϵ rasgele seçilmiş küçük bir pozitif sayıdır. RE, gri seviyeler ve koşu uzunluklarının dağılımlarındaki belirsizlik ve rastgeleliği ölçer. Daha yüksek değer, doku örneklerindeki daha fazla heterojenliği ifade eder. Eş. 2.66 ile ifade edilir.

$$RE = - \sum_{i=i}^{N_g} \sum_{j=1}^{N_r} p(i, j|\theta) \log_2(p(i, j|\theta) + \epsilon) \quad (2.66)$$

Düşük gri seviye koşu vurgusu (LGRE)

LGRE, daha yüksek değerlerin görüntüdeki gri seviye değerlerinin daha büyük yoğunluğu ifade etmesiyle, düşük gri seviye değerlerinin dağılımını ölçer. Eş. 2.67 ile ifade edilir.

$$LGRE = \frac{\sum_{i=i}^{N_g} \sum_{j=1}^{N_r} \frac{p(i, j|\theta)}{j^2}}{N_r(\theta)} \quad (2.67)$$

Yüksek gri seviye koşu vurgusu (HGRE)

HGRE, daha yüksek değerlerin görüntüdeki gri seviye değerlerinin daha büyük yoğunluğu ifade etmesiyle, yüksek gri seviye değerlerinin dağılımını ölçer. Eş. 2.68 ile ifade edilir.

$$HGRE = \frac{\sum_{i=i}^{N_g} \sum_{j=1}^{N_r} p(i, j|\theta)i^2}{N_r(\theta)} \quad (2.68)$$

Kısa koşu düşük gri seviye koşu vurgusu (SRLGE)

SRLGE, düşük gri seviye değerlerle, kısa koşu uzunluklarının birleşik dağılımını ölçer. Eş. 2.69 ile ifade edilir.

$$SRLGE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} \frac{P(i,j|\theta)}{i^2 j^2}}{N_r(\theta)} \quad (2.69)$$

Kısa koşu yüksek gri seviye koşu vurgusu (SRHGE)

SRHGE, yüksek gri seviye değerlerle kısa koşu uzunluklarının birleşik dağılımını ölçer. Eş. 2.70 ile ifade edilir.

$$SRHGE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} \frac{P(i,j|\theta) i^2}{j^2}}{N_r(\theta)} \quad (2.70)$$

Uzun koşu düşük gri seviye vurgusu (LRLGE)

LRLGE, düşük gri seviye değerlerle uzun koşu uzunluklarının birleşik dağılımını ölçer. Eş. 2.71 ile ifade edilir.

$$LRLGE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} \frac{P(i,j|\theta) i^2}{j^2}}{N_r(\theta)} \quad (2.71)$$

Uzun koşu yüksek gri seviye vurgusu (LRHGE)

LRHGE, yüksek gri seviye değerlerle uzun koşu uzunluklarının birleşik dağılımını ölçer. Eş. 2.72 ile ifade edilir.

$$LRHGE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_r} P(i,j|\theta) i^2 j^2}{N_r(\theta)} \quad (2.72)$$

Gri seviye büyüklük alan matrisi (Gray level size zone matrix - GLSZM)

Gri seviye büyüklük alan matrisi (GLSZM), görüntüdeki gri seviye alanların sayısını belirler. Bir gri seviye alanı, aynı gri seviye yoğunluğunu paylaşan bağlı voksellerin sayısı olarak tanımlanır. Eğer sonsuz norma göre uzaklık 1 ise vokselle, bağlantılı olarak değerlendirilir. Burada sonsuz normdan kasıt; 3 boyutta 26 bağlantılı, 2 boyutta 8 bağlantılı bölgedir. Bir $P(i,j)$ gri seviye büyüklük alan matrisinde, (i,j) 'inci eleman, görüntüdeki i gri seviyeli j büyüklüğündeki alanların sayısıdır. GLCM ve GLRLM'nin aksine GLSZM, dönme yönünden bağımsız ROI'deki bütün yönler için tek matris hesaplanarak elde edilir.

Figure 2.17 consists of two parts, (a) and (b), each showing a 5x5 matrix. Part (a) shows the matrix I with the following values:

$$I = \begin{bmatrix} 5 & 2 & 5 & 4 & 4 \\ 3 & 3 & 3 & 1 & 3 \\ 2 & 1 & 1 & 1 & 3 \\ 4 & 2 & 2 & 2 & 3 \\ 3 & 5 & 3 & 3 & 2 \end{bmatrix}$$

Part (b) shows the matrix P with the following values:

$$P = \begin{bmatrix} 0 & 0 & 0 & 1 & 0 \\ 1 & 0 & 0 & 0 & 1 \\ 1 & 0 & 1 & 0 & 1 \\ 1 & 1 & 0 & 0 & 0 \\ 3 & 0 & 0 & 0 & 0 \end{bmatrix}$$

Şekil 2.17. (a) Örnek bir I matrisi (b) I matrisine ait gri seviye büyüklük alan matrisi

5 farklı gri seviyeden oluşan 5x5'lik örnek bir I görüntü matrisi Şekil 2.17.a'da verilmiştir. I matrisine ait oluşturulan P gri seviye alan matrisi Şekil 2.17.b'deki gibidir.

N_g görüntüdeki farklı yoğunluk değerlerinin sayısı, N_g görüntüdeki farklı alan büyüklüklerinin sayısı, N_p görüntüdeki voksellerin sayısı, N_g ROI'deki alanların sayısıdır ve Eş. 2.73.a ile ifade edilir. $P(i,j)$ büyüklük alan matrisi. $P(i,j)$, Eş. 2.73.b ile tanımlanan normalize büyüklük alan matrisidir.

$$N_z = \sum_{i=1}^{N_g} \sum_{j=1}^{N_s} P(i,j), 1 \leq N_z \leq N_p \quad (2.73.a)$$

$$P(i, j) = \frac{P(i, j)}{N_z} \quad (2.73.b)$$

Küçük alan vurgusu (SZE)

SZE, daha hassas doku ve daha küçük büyüklükteki alanların daha büyük değer göstericisiyle, küçük büyüklük alanlarının dağılımının bir ölçümüdür. Eş. 2.74 ile ifade edilir.

$$SZE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_s} \frac{P(i, j)}{j^2}}{N_z} \quad (2.74)$$

Büyük alan vurgusu (LZE)

SZE, daha kaba doku ve daha büyük alanların daha büyük değer göstergesiyle, büyük büyüklük alanlarının dağılımını ölçer. Eş. 2.75 ile ifade edilir.

$$LZE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_s} P(i, j) j^2}{N_z} \quad (2.75)$$

Gri seviye değişebilirliği (GLN)

GLN, yoğunluk değerlerindeki daha fazla homojenliği gösteren daha düşük değerle, görüntüdeki gri seviye yoğunluk değerlerinin değişkenliğini ölçer. Eş. 2.76 ile ifade edilir.

$$GLN = \frac{\sum_{i=1}^{N_g} \left(\sum_{j=1}^{N_s} P(i, j) \right)^2}{N_z} \quad (2.76)$$

Normalize gri seviye düzensizliği (GLNN)

GLNN, gri seviye değişebilirliği ile aynı değişkenliği ölçer fakat bu değişkenliğin normalize edilmiş değerini verir. Eş. 2.77 ile ifade edilir.

$$GLN = \frac{\sum_{i=1}^{N_g} \left(\sum_{j=1}^{N_s} P(i, j) \right)^2}{N_z^2} \quad (2.77)$$

Alan büyüklük değişebilirliği (ZSN)

ZSN, büyüklük alan hacimlerindeki daha fazla homojenliği gösteren daha düşük değerlerle, görüntüdeki büyüklük alan hacimlerinin değişkenliğini ölçer. Eş. 2.78 ile ifade edilir.

$$ZSN = \frac{\sum_{j=i}^{N_s} \left(\sum_{i=1}^{N_g} P(i,j) \right)^2}{N_z} \quad (2.78)$$

Normalize büyüklük alan düzensizliği (SZNN)

SZNN, ZSN nin ölçtüğü değişkenliğin normalize edilmiş verisyonunu bulur. Eş. 2.79 ile ifade edilir.

$$SZNN = \frac{\sum_{j=i}^{N_s} \left(\sum_{i=1}^{N_g} P(i,j) \right)^2}{N_z^2} \quad (2.79)$$

Alan yüzdesi (ZP)

Alan yüzdesi, ROI'deki voksellerin sayısını ve alanların sayısının oranını kullanarak dokunun kabalığını ölçer.

$1/N_p \leq ZP \leq 1$ aralığındaki değerler, küçük alanlardan oluşan ROI'nin büyük bir kısmını belirten daha yüksek değerlerle birlikte. Eş. 2.80 ile ifade edilir.

$$ZP = \frac{N_z}{N_p} \quad (2.80)$$

Gri seviye varyansı (GLV)

GLV, alanlar için gri seviye yoğunluklarındaki varyansı ölçer. Eş. 2.81.b ile ifade edilir.

$$\mu = \sum_{i=1}^{N_g} \sum_{j=1}^{N_s} p(i,j) i \quad (2.81.a)$$

$$GLV = \sum_{i=1}^{N_g} \sum_{j=1}^{N_s} P(i, j) (i - \mu)^2 \quad (2.81.b)$$

Alan varyansı (ZV)

ZV, alanlar için alan büyüklük hacimlerindeki varyansı ölçer. Eş. 2.82.b ile ifade edilir.

$$\mu = \sum_{i=1}^{N_g} \sum_{j=1}^{N_s} p(i, j) j \quad (2.82.a)$$

$$ZV = \sum_{i=1}^{N_g} \sum_{j=1}^{N_s} P(i, j) (j - \mu)^2 \quad (2.82.b)$$

Alan entropisi (ZE)

ZE, alan büyüklükleri ve gri seviyelerin dağılımındaki belirsizliği ve rastlantısallığı ölçer. Daha yüksek değer, doku örneklerindeki daha fazla heterojenliği ifade eder. Eş. 2.83 ile ifade edilir. ϵ rasgele seçilmiş küçük bir pozitif sayıdır.

$$ZE = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_s} P(i, j) \log_2(p(i, j) + \epsilon) \quad (2.83)$$

Düşük gri seviye alan vurgusu (LGZE)

LGZE, yüksek değerlerin görüntüdeki büyüklük alanların ve düşük gri seviye değerlerinin büyük bir kısmını göstermesiyle beraber, düşük gri seviye büyüklük alanlarının dağılımını ölçer. Eş. 2.84 ile ifade edilir.

$$LGZE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_s} \frac{P(i, j)}{j^2}}{N_z} \quad (2.84)$$

Yüksek gri seviye alan vurgusu (HGZE)

HGZE, yüksek değerlerin görüntüdeki büyüklük alanların ve yüksek gri seviye değerlerinin büyük bir kısmını göstermesiyle beraber, yüksek gri seviye büyüklük alanlarının dağılımını ölçer. Eş. 2.85 ile ifade edilir.

$$HGZE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_s} P(i,j) i^2}{N_z} \quad (2.85)$$

Küçük alan düşük gri seviye vurgusu (SZLGE)

SZLGE, düşük gri seviye değerlerle küçük büyüklükteki alanların birleşik dağılımının görüntüdeki miktarını ölçer. Eş. 2.86 ile ifade edilir.

$$SZLGE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_s} \frac{P(i,j)}{i^2 j^2}}{N_z} \quad (2.86)$$

Küçük alan yüksek gri seviye vurgusu (SZHGE)

SZHGE, yüksek gri seviye değerlerle küçük büyüklükteki alanların birleşik dağılımının görüntüdeki miktarını ölçer. Eş. 2.87 ile ifade edilir.

$$SZHGE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_s} \frac{P(i,j) i^2}{j^2}}{N_z} \quad (2.87)$$

Büyük alan düşük gri seviye vurgusu (LZLGE)

LZLGE, düşük gri seviye değerlerle daha büyük alanların birleşik dağılımının görüntüdeki miktarını ölçer. Eş. 2.88 ile ifade edilir.

$$LZLGE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_s} \frac{P(i,j) j^2}{i^2}}{N_z} \quad (2.88)$$

Büyük alan yüksek gri seviye vurgusu (LZHGE)

LZHGE, yüksek gri seviye değerlerle daha büyük alanların birleşik dağılımının görüntüdeki miktarını ölçer. Eş. 2.89 ile ifade edilir.

$$LZHGE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_s} P(i,j) i^2 j^2}{N_z} \quad (2.89)$$

Komşuluk gri ton fark matrisi (Neighbouring gray tone difference matrix - NGTDM)

NGTDM, bir gri seviye ve bu gri seviyenin δ uzaklığı içerisindeki komşularının gri seviye ortalamaları arasındaki farkı ölçer. i gri seviye için mutlak farkların toplamı matriste de doldurulur. X_{gl} segmente edilmiş voksellerin bir seti ve $x_{gl}(j_x, j_y, j_z) \in X_{gl}(j_x, j_y, j_z)$ pozisyonunda bir vokselin gri seviyesi olursa, komşuluğun gri seviye ortalaması Eş. 2.90.a'daki gibi bulunur [79].

$$\begin{aligned} \bar{A}_i &= \bar{A}(j_x, j_y, j_z) \\ &= \frac{1}{W} \sum_{k_x=-\delta}^{\delta} \sum_{k_y=-\delta}^{\delta} \sum_{k_z=-\delta}^{\delta} x_{gl}(j_x + k_x, j_y + k_y, j_z + k_z) \\ &\text{eğer } (k_x, k_y, k_z) \neq (0,0,0) \text{ and } x_{gl}(j_x + k_x, j_y + k_y, j_z + k_z) \in X_{gl} \end{aligned} \quad (2.90.a)$$

Burada W , aynı zamanda X_{gl} 'de olan komşuluklardaki voksellerin sayısıdır.

İki boyutlu bir örnek olarak I matrisi 5 gri seviyeli fakat 4. gri seviyeli voksel içermeyen 4x4'lük bir görüntü olursa, NGTDM aşağıdaki Şekil 2.28'deki gibi elde edilebilir.

$\mathbf{I} =$	$\begin{bmatrix} 1 & 2 & 5 & 2 \\ 3 & 5 & 1 & 3 \\ 1 & 3 & 5 & 5 \\ 3 & 1 & 1 & 1 \end{bmatrix}$	i	n_i	p_i	s_i
		1	6	0.375	13.35
		2	2	0.125	2.00
		3	4	0.25	2.63
		4	0	0.00	0.00
		5	4	0.25	10.075
	(a)			(b)	

Şekil 2.18. (a) Örnek bir görüntü matrisi ve (b) bu görüntüye ait komşuluk gri ton fark matrisi

1 gri seviyeli 6 piksel olduğu için Eş. 2.90.b, 2 gri seviye değeri için 2 piksel olduğu için Eş. 2.90.c, 3 ve 5 gri seviye değerler de Eş. 2.90.d ve Eş. 2.90.e ile hesaplanır.

$$s_1 = \left|1 - \frac{10}{3}\right| + \left|1 - \frac{30}{8}\right| + \left|1 - \frac{15}{5}\right| + \left|1 - \frac{13}{5}\right| + \left|1 - \frac{15}{5}\right| + \left|1 - \frac{11}{3}\right| = 13.35 \quad (2.90.b)$$

$$s_2 = \left|2 - \frac{15}{5}\right| + \left|2 - \frac{15}{5}\right| = 2 \quad (2.90.c)$$

$$s_3 = \left|3 - \frac{12}{5}\right| + \left|3 - \frac{18}{5}\right| + \left|3 - \frac{20}{8}\right| + \left|3 - \frac{5}{3}\right| = 3.03 \quad (2.90.d)$$

$$s_5 = \left|5 - \frac{14}{5}\right| + \left|5 - \frac{18}{5}\right| + \left|5 - \frac{20}{8}\right| + \left|5 - \frac{11}{5}\right| = 10.075 \quad (2.90.e)$$

n_i , X_{gl} 'deki i gri seviyeli voksellerin sayısıdır. $N_{v,p}$, X_{gl} 'deki voksellerin toplamı sayısıdır ve Σn_i 'ye eşittir. (en az 1 komşuluklu geçerli bölge) voksellerin sayısı). Eğer $N_{v,p} \leq N_p$ ise N_p ilgi bölgesindeki (Region Of Interest - ROI) voksellerin toplam sayısı p_i , gri seviye olasılığıdır ve n_i 'nin N_v 'ye bölünmesiyle bulunur. i gri seviye için mutlak farkların toplamı Eş. 2.91 ile elde edilir.

$$s_i = \begin{cases} \sum_{i=1}^{n_i} |i - \bar{A}_i| & \text{for } n_i \neq 0 \\ 0 & \text{for } n_i = 0 \end{cases} \quad (2.91)$$

N_g farklı gri seviyelerin sayısı Eğer $p_i \neq 0$ ise $N_{g,p}$ gri seviyelerin sayısıdır.

NGTDM dokusu 5 farklı özellikle tanımlanabilir. Bunlar; kabalık (coariness), kontrast (contrast), meşguliyet (busyness), karmaşıklık (complexity) ve güç (strength)'tür.

Kabalık

Kabalık, merkez voksel ve komşuluğu arasındaki ortalama farkı ölçer, aynı zamanda kabalık, uzamsal oran değişiminin bir göstergesidir. Daha yüksek değer, daha düşük uzamsal değişim oranını ve yerel olarak daha tekdüze dokuları ifade eder. Eş. 2.92 ile ifade edilir.

$$\text{kabalık} = \frac{1}{\sum_{i=1}^{N_g} p_i s_i} \quad (2.92)$$

Zıtlık

Zıtlık eşitliği p_i ve $p_j \neq 0$ durumunda geçerlidir. Zıtlık, uzamsal yoğunluk değişiminin bir ölçümüdür, ama aynı zamanda tüm gri seviye dinamik bölgesine bağlıdır. Hem dinamik bölge hem uzamsal değişiminin ikisinin de yüksek olduğu durumda zıtlık yüksek olur. Örnek olarak, büyük gri seviye aralıklı bir görüntü, voksel ve komşulukları arasında büyük değişiklikler barındırır. Eş. 2.93 ile ifade edilir.

$$\text{zıtlık} = \left(\frac{1}{N_{g,p}(N_{g,p}-1)} \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p_i p_j (i-j)^2 \right) \left(\frac{1}{N_{v,p}} \sum_{i=1}^{N_g} s_i \right) \quad (2.93)$$

Meşguliyet

Meşguliyet eşitliği p_i ve $p_j \neq 0$ durumunda geçerlidir. Meşguliyet, bir pikselden onun komşuluğuna olan değişimin ölçümüdür. Yüksek bir meşguliyet değeri meşgul bir görüntü demektir, bu da pikseller ve komşuluklarının arasındaki yoğunluğun hızlı değişimi anlamına gelir. Eş. 2.94 ile ifade edilir.

$$\text{meşguliyet} = \frac{\sum_{i=1}^{N_g} p_i s_i}{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} |i p_i - j p_j|} \quad (2.94)$$

Karmaşıklık

Karmaşıklık eşitliği p_i ve $p_j \neq 0$ durumunda geçerlidir. Bir görüntü, içerisinde birçok kaba bileşen barındırdığında karmaşık olarak değerlendirilir. Bu görüntü tekdüze değildir ve gri seviye yoğunluğunda hızlı değişimler içerir. Eş. 2.95 ile ifade edilir.

$$\text{karmaşıklık} = \frac{1}{N_{v,p}} \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} |i-j| \frac{p_i s_i + p_j s_j}{p_i + p_j} \quad (2.95)$$

Güç


Güç eşitliği p_i ve $p_j \neq 0$ durumunda geçerlidir. Güç, görüntüdeki kabalıkları ölçer. Bu değer, kabalıklar kolayca tanımlanabilirken ve görünürken yüksektir. Örneğin, yoğunluğu yavaş

değişimli bir görüntünün, gri seviye yoğunluklarında daha büyük kaba farklar vardır. Eş. 2.96 ile ifade edilir.

$$\text{güç} = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (p_i + p_j)(i-j)^2}{\sum_{i=1}^{N_g} s_i} \quad (2.96)$$

Gri seviye bağıllık matrisi (Gray level dependence matrix - GLDM)

Bir GLDM, görüntüdeki gri seviye bağımlılıklarını ölçer. Gri seviye bağıllığı, merkez voksele bağlı δ uzaklığı içerisindeki bağlantılı voksellerin sayısı olarak tanımlanır. j gri seviyeli komşu vokseli i gri seviyeli merkez voksele, $|i-j| \leq \alpha$ koşulu sağlandığında bağıllık olarak değerlendirilir. $P(i,j)$ gri seviye bağıllık matrisinde (i,j) ' inci eleman, görüntüde görünen i gri seviyeli j bağıllı voksellerin komşuluğundaki tekrar sayısını tanımlar.



Şekil 2.19. (a) Örnek bir görüntü matrisi ve (b) bu görüntüye ait gri seviye bağıllık matrisi

Şekil 2.19.a'da 5x5'lik 5 farklı gri seviye barındıran bir I görüntü matrisi verilmiştir. Bu matristen, $\alpha=0$ ve $\delta=1$ için oluşturulan gri seviye bağıllık matrisi Şekil 2.19.b'de verilmiştir.

N_g görünüşteki farklı yoğunluk değerlerinin sayısı, d görüntüdeki farklı bağıllık büyüklüklerinin sayısı, N_z görüntüdeki bağıllık alanlarının sayısıdır ve Eş. 2.97.a ile ifade edilir. $P(i,j)$ bağıllık matrisi. $p(i,j)$, Eş. 2.97.b ile tanımlanan normalize bağıllık matrisidir.

$$\sum_{i=1}^{N_g} \sum_{j=1}^{N_d} P(i, j) \quad (2.97.a)$$

$$P(i, j) = \frac{P(i, j)}{N_z} \quad (2.97.b)$$

Küçük bağılılık vurgusu (SDE)

SDE, küçük bağılılıkların dağılımının, daha küçük bağılılıkların daha büyük değer göstergeleriyle ve daha az homojen dokularla olan bir göstergesidir. Eş. 2.98 ile ifade edilir.

$$SDE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_d} \frac{P(i, j)}{i^2}}{N_z} \quad (2.98)$$

Büyük bağılılık vurgusu (LDE)

LDE, büyük bağılılıkların dağılımının, daha büyük bağılılıkların daha büyük değer göstergeleriyle ve daha fazla homojen dokularla olan bir göstergesidir. Eş. 2.99 ile ifade edilir.

$$LDE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_d} P(i, j) j^2}{N_z} \quad (2.99)$$

Gri seviye düzensizliği (GLN)

GLN, düşük GLN değerinin yoğunluk değerlerinde daha büyük benzerlikle ilişkili olduğu yerde görüntüdeki gri seviye yoğunluk değerlerinin benzerliğini ölçer. Eş. 2.100 ile ifade edilir.

$$GLN = \frac{\sum_{i=1}^{N_g} \left(\sum_{j=1}^{N_d} P(i, j) \right)^2}{N_z} \quad (2.100)$$

Bağılılık düzensizliği (DN)

Bağılılık düzensizliği, görüntü boyunca bağılılık benzerliğini ölçer. Daha düşük değer, görüntüdeki bağılıklar boyunca daha fazla homojenliği işaret eder. Eş. 2.101 ile ifade edilir.

$$DN = \frac{\sum_{j=1}^{N_d} \left(\sum_{i=1}^{N_g} P(i,j) \right)^2}{N_z} \quad (2.101)$$

Normalize bağılılık düzensizliği (DNN)

Bağılılık düzensizliğiyle aynı benzerlikleri ölçer fakat onun normalize edilmiş sonucunu verir. Eş. 2.102 ile ifade edilir.

$$DNN = \frac{\sum_{j=1}^{N_d} \left(\sum_{i=1}^{N_g} P(i,j) \right)^2}{N_z^2} \quad (2.102)$$

Gri seviye varyansı (GLV)

Eş. 2.103.a'nın geçerli olduğu durum için GLV Eş. 2.103.b'deki gibi bulunabilir. GLV, görüntüde gri seviyedeki varyansı ölçer.

$$\mu = \sum_{i=1}^{N_g} \sum_{j=1}^{N_d} ip(i,j) \quad (2.103.a)$$

$$GLV = \sum_{i=1}^{N_g} \sum_{j=1}^{N_d} p(i,j)(i - \mu)^2 \quad (2.103.b)$$

Bağılılık varyansı (DV)

Eş. 2.104.a'nın geçerli olduğu durum için DV, Eş. 2.104.b'deki şekilde bulunabilir. DV, görüntüde bağılılık büyüklüğünde varyansı ölçer.

$$\mu = \sum_{i=1}^{N_g} \sum_{j=1}^{N_d} jp(i,j) \quad (2.104.a)$$

$$DV = \sum_{i=1}^{N_g} \sum_{j=1}^{N_d} p(i,j)(j - \mu)^2 \quad (2.104.b)$$

Bağılılık entropisi (DE)

DE, Eş. 2.105'deki gibi hesaplanır.

$$DE = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_d} p(i,j) \log_2(p(i,j) + \epsilon) \quad (2.105)$$

Düşük gri seviye vurgusu (LGLE)

LGLE, düşük gri seviye değerlerinin dağılımını ölçer. Yüksek değer, görüntüdeki düşük gri seviye değerlerinin daha büyük bir yoğunluğunu belirtir. Eş. 2.106 ile ifade edilir.

$$LGLE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_d} \frac{P(i,j)}{i^2}}{N_z} \quad (2.106)$$

Yüksek gri seviye vurgusu (HGLE)

HGLE, yüksek gri seviye değerlerinin dağılımını ölçer. Yüksek değer, görüntüdeki yüksek gri seviye değerlerinin daha büyük bir yoğunluğunu gösterir. Eş. 2.107 ile ifade edilir.

$$HGLE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_d} P(i,j) i^2}{N_z} \quad (2.107)$$

Küçük bağılılık düşük gri seviye vurgusu (SDLGLE)

Bu özellik, düşük gri seviye değerlerle, küçük bağılılığın birleşik dağılımını ölçer. Eş. 2.108 ile ifade edilir.

$$SDLGLE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_d} \frac{P(i,j)}{i^2 j^2}}{N_z} \quad (2.108)$$

Küçük bağıllık yüksek gri seviye vurgusu (SDHGLE)

Burada, yüksek gri seviye değerlerle, küçük bağıllığının birleşik dağılımı ölçülür.

Büyük bağıllık düşük gri seviye vurgusu (LDLGLE)

Küçük gri seviye değerlerle büyük bağıllığın birleşik dağılımı ölçülür. Eş. 2.109 ile ifade edilir.

$$LDLGLE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_d} \frac{P(i,j)j^2}{i^2}}{N_z} \quad (2.109)$$

Büyük bağıllık yüksek gri seviye vurgusu (LDHGLE)

Yüksek gri seviye değerlerle büyük bağıllığın birleşik dağılımı ölçülür. Eş. 2.110 ile ifade edilir.

$$LDLGLE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_d} P(i,j)i^2j^2}{N_z} \quad (2.110)$$

Şekil tabanlı özellikler

Bu grup özelliklerde ilgi bölgelerinin (Region Of Interest - ROI) üç boyutlu şekli ve büyüklüklerinin tanımlamaları vardır. Bu özellikler ROI'deki gri seviye yoğunluk dağılımlarından bağımsızdır ve bu yüzden türetilmemiş görüntülerden hesaplanırlar. Başka bir deyişle istatistiksel tabanlı özellik çıkarmada yapıldığı gibi görüntülerden matrisler oluşturulmaz, doğrudan görüntü üzerinden özellikler çıkarılır.

Başka bir şekilde belirtilmediği sürece, özellikler, üçgen bir ağ ile tanımlanan tahmini bir şekilden elde edilir. Bu ağ oluşturabilmek için, köşe noktaları, biri ROI'nin dışında biri ROI'nin içindeki voksellerin arasındaki kenarda yarı yarıya olacak şekilde tanımlanır. Bu tepe noktalarını birleştirerek bağlantılı bir üçgen ağ elde edilir. Her bir üçgen 3 yan yana tepe noktaları ile tanımlanır ki, bu tepe noktaları diğer üçgenle bir kenarını paylaşmaktadır.

Bu ağ yürüyüş küpleri (marching cubes) algoritması kullanılarak oluşturulur. Bu algoritmada, 2x2'lik küp maske uzamı boyunca ilerler. Her bir pozisyon için, 'segmente edilen' (1), 'segmente edilmeyen' (0) olarak işaretlenir. Köşerleri, iki tabanlı sistemde spesifik bitler olarak işleyerek, (0-255) aralığında özel bir küp-dizini elde edilir. Bu dizin daha sonrasında bir çizelgede tanımlanan küpte bulunan üçgenleri belirlemede kullanılır. Bu üçgenler şu şekilde tanımlanır: Normal olanlar (3 kenardan 2'sini tanımlayan vektörlerin çapraz ürünü) aynı yöne yönlendirilmiştir. Bizim kullandığımız PyRadiomics modeli için hesaplanan normaller her zaman dışı doğrudur. Bu işlem, ağ hacminin hesaplanmasında kullanılan doğru hacmi elde etmek için gereklidir [80].

N_v , ROI'de bulunan voksellerin sayısını, N_f , ağı tanımlayan üçgenlerin sayısını, V , ağın hacmini ve A , ağın yüzey alanını temsil etmektedir.

Ağ hacmi

$$V_i = \frac{Oa_i \cdot (Ob_i \times Oc_i)}{6} \quad (2.111.a)$$

$$V = \sum_{i=1}^{N_f} V_i \quad (2.111.b)$$

ROI hacmi V , ROI'nin üçgen ağından hesaplanır. Ağdaki a_i , b_i ve c_i noktaları ile tanımlanan her bir i üçgeni için, dört yüzeyle V_f hacmi belirtilen üçgenle tanımlanır ve görüntünün merkezi O hesaplanır. Hacmin işareti normalin işaretiyle Eş. 2.111.a'daki gibi hesaplanır. Daha sonrasında V_i toplamalarını alarak ROI'nin toplam hacmi Eş. 2.111.b'deki gibi elde edilir.

Voksel hacmi

ROI'deki V_{voksel} hacmi, ROI'deki voksellerin sayısı ile V_k tekli vokselinin hacminin çarpılmasıyla tahmin edilir. Bu tahmin düşük kesinliktedir ve daha sonraki özellikler için kullanılmaz. Bu özellik ağı kullanmaz ve diğer şekilsel özelliklerin hesaplanmasında kullanılmaz. Eş. 2.112 ile ifade edilir.

$$V_{\text{voksel}} = \sum_{i=1}^{N_v} V_k \quad (2.112)$$

Yüzey alanı

$a_i b_i$ ve $a_i c_i$ ağdaki i 'inci üçgenin kenarlarıdır ve a_i , b_i ve c_i köşe noktaları ile oluşturulmuştur. Yüzey alanını hesaplayabilmek için ağdaki her bir üçgenin yüzey alanı A_i Eş. 2.113.a ile hesaplanır. Sonrasında hesaplanan bütün alt alanlar toplanarak toplam yüzey alanı Eş. 2.113.b'deki gibi hesaplanır.

$$A_i = \frac{1}{2} [a_i b_i \times a_i c_i] \quad (2.113.a)$$

$$A = \sum_{i=1}^{N_f} A_i \quad (2.113.b)$$

Yüzey hacim oranı (SVR)

Daha düşük değer küre gibi daha sıkı bir şekli ifade eder. Bu özellik boyutsuz değildir ve bu sebepten dolayı kısmen de olsa ROI'nin hacmine bağlıdır. Eş. 2.114 ile ifade edilir.

$$SVR = \frac{A}{V} \quad (2.114)$$

Küresellik

Küresellik ilgili bölgenin bir küreye ilişkin şeklinin daireselliğini ölçer. Boyutsuz bir ölçümdür, ölçek ve yönelimden bağımsızdır. 0 ve 1 arası değer alabilir, 1'e yaklaştıkça küresellik artar. Eş. 2.115 ile ifade edilir.

$$\text{küresellik} = \frac{\sqrt[3]{36\pi V^2}}{A} \quad (2.115)$$

Sıklık 1

Küresellikteki benzer olarak, sıklık 1, ilgili bölgenin bir küreye ilişkin ne kadar sık olduğunu bir ölçümüdür. 0 ve $1/6\pi$ arası değerler alabilir. $1/6\pi$, mükemmel küreseli ifade eder. Eş. 2.116 ile ifade edilir.

$$\text{sıklık 1} = \frac{V}{\sqrt{\pi A^3}} \quad (2.116)$$

Sıklık 2

Sıklık 1 ile benzerdir fakat 0 ve 1 arası değerler alır. 1'e yaklaştıkça küresellik artar. Aynı zamanda küreselliğin küpü değerindedir. Eş. 2.117 ile ifade edilir.

$$\text{sıklık 2} = 36\pi \frac{V^2}{A^3} \quad (2.117)$$

Küresel oransızlık (SD)

R, ilgili bölgeyle aynı hacimli bir kürenin yarıçapıdır ve $\sqrt[3]{3V/4\pi}$ değerine eşittir. Küresel oransızlık, ilgi bölgesinin yüzey alanının ilgi bölgesiyle aynı hacimli bir kürenin yüzey alanına oranıdır. Tanım olarak ise küreselliğin tersidir, bu yüzden 1'e eşit ya da daha büyüktür. 1 değeri bu özellik için kusursuz küre olarak değerlendirilebilir. Eş. 2.118 ile ifade edilir.

$$SD = \frac{A}{4\pi R^2} = \frac{A}{\sqrt[3]{36\pi V^2}} \quad (2.118)$$

Maksimum 3D çapı

Bu özellik, ilgili bölge yüzeyi ile ağı köşe noktaları arasındaki en büyük öklit uzaklığını bulmaktadır.

Maksimum 2D çap kesiti

Bu parametre, satır sütun düzleminde, ilgili bölge yüzeyi ile ağı köşe noktaları arasındaki ikili en büyük öklit uzaklığını ifade etmektedir.

Maksimum 2D çap sütunu

Satır kesit düzleminde, ilgili bölge yüzeyi ile ağın köşe noktaları arasındaki ikili en büyük öklit uzaklığının bulunduğu karakteristiktir.

Maksimum 2D çap satırı

Sütun kesit düzleminde, ilgili bölge yüzeyi ile ağın köşe noktaları arasındaki ikili en büyük öklit uzaklığının belirtildiği özelliktir.

Büyük eksen

Bu özellik, elipsoiti kaplayan ROI'nin en büyük eksen uzaklığını bulmaktadır. En büyük esas bileşen olan $\lambda_{\text{büyük}}$ ile Eş. 2.119'deki gibi hesaplanır. Esas bileşen analizi, ROI'yi tanımlayan voksel merkezlerinin fiziksel koordinatları kullanılarak uygulanır.

$$\text{büyük eksen} = 4\sqrt{\lambda_{\text{büyük}}} \quad (2.119)$$

Küçük eksen

Küçük eksen özelliği, elipsoiti kaplayan ROI'nin ikinci en büyük eksen uzaklığını bulmaktadır. En büyük esas bileşen olan $\lambda_{\text{büyük}}$ ile Eş. 2.120'deki gibi hesaplanır. Büyük ekseninde olduğu gibi küçük ekseninde de, esas bileşen analizi, ROI'yi tanımlayan voksel merkezlerinin fiziksel koordinatlarından faydalanılarak gerçekleştirilir.

$$\text{küçük eksen} = 4\sqrt{\lambda_{\text{küçük}}} \quad (2.120)$$

En küçük eksen

Bu özellik bir elipsoiti çevreleyen ilgili bölgenin en küçük eksen uzunluğunu verir ve en büyük temel bileşen $\lambda_{\text{en küçük}}$ aracılığıyla üretilir ve Eş. 2.121 ile ifade edilir.

$$\text{en küçük eksen} = 4\sqrt{\lambda_{\text{en küçük}}} \quad (2.121)$$

Uzama

Uzama, ilgi bölgesinin şeklindeki en büyük iki temel bileşenin arasındaki ilişkiyi gösterir. Hesaplama nedenlerinden dolayı bu özellik gerçek uzamanın tersi olarak tanımlanır. Eş. 2.122 ile ifade edilir.

$$uzama = \sqrt{\frac{\lambda_{küçük}}{\lambda_{büyük}}} \quad (2.122)$$

Düzlük

Düzlük, ilgili bölgenin şeklindeki en büyük ve en küçük temel bileşenlerin arasındaki bağlantıya bakar. Uzama özelliğinde olduğu gibi yine hesaplama ait sebeplerden ötürü gerçek düzlüğün tersi olarak elde edilir. 2.123 ile ifade edilir.

$$düzlük = \sqrt{\left(\frac{\lambda_{en\ küçük}}{\lambda_{büyük}}\right)} \quad (2.123)$$

2.4.4. Özellik seçimi

Veriler, birçok değişkenle birlikte daha da büyük boyutlara ulaşmasından dolayı literatürde çok sayıda özellik seçimi yöntemi bulunmaktadır. Özellik seçimi metotları, hesaplama zamanının azaltılmasını, tahmin performansının geliştirilmesini ve makine öğrenmesi veya örüntü tanımasında verinin daha iyi anlaşılabilmesini sağlamaktadır.


Özellik seçimi, veriyi anlama, hesaplama gereksinimlerinin azaltılması, boyut sorununu etkisinin düşürülmesi ve tahmin performansının geliştirilmesinde yardımcı olur. Özellik seçiminin esas amacı, gürültü ya da ilişkisiz değişkenlerin etkisinin azalttığı ama yine de iyi tahmin sonuçlarının sağlandığı sürece giriş verisini etkili bir şekilde tanımlayan girişteki değişkenlerin bir alt kümesini seçmektir. İlişkisiz özellikleri kaldırmak için, çıkış sınıf ve etiketiyle her bir özelliğin ilişkisini ölçebilen ilişkisiz bir özellik seçme kriteri gereklidir. Makine öğrenmesi açısından, eğer bir sistem ilişkisiz değişkenler kullanıyorsa, zayıf genellemeye neden olan yeni bir veri için bu bilgiyi kullanır. İlişkisiz değişkenlerin kaldırılması, iyi özellikler verinin geri kalan kısmından bağımsız olabileceği için başka

boyut azaltma metotlarıyla karşılaştırılmamalıdır. Özellik ayırması sayıları azaltmak adına giriş özelliklerini kendi kullandığı için, yeni özellikler üretmezler. Bir özellik seçimi kriteri seçildiğinde, kullanışlı özelliklerin alt kümesinin bulunacağı bir prosedür geliştirilmelidir. Verilen data için bütün özelliklerin alt kümelerinin değerlendirilmesi, özellik sayıları arttıkça hesaplanamaz bir probleme dönüşebilir. Bu yüzden kolay hesaplamalarla alakasız veriyi yok edebilecek optimuma yakın bir prosedür uygulanmalıdır. Özellik seçimi metotları sarıcı ve filtre metotları olarak iki ana başlık altında toplanabilir. Filtre metotları yüksek derecelendirilmiş özelliklerin seçildiği ve tahmin ediciye uygulandığı yerdeki özellikleri derecelendirmek için ön işlemci olarak çalışırlar. Sarıcı metotlarda özellik seçimi kriteri tahmin edicinin performansdır. Örnek olarak, tahmin edici en yüksek tahmin edici performansını veren bir altküme bulacak bir arama algoritmasına sarılmıştır. Sarıcı yöntemleri özellik alt kümesini değerlendirmek için tahmin ediciyi kara kutu tahmin edici performansını da amaç fonksiyonu olarak kullanır. 2^N kadar alt kümenin değerlendirilmesi çözülemeyen bir problem olabileceğinden sezgisel olarak bir alt küme bulan arama algoritmasıyla bulunan optimuma yakın alt kümeler bulunur. Çok sayıda arama algoritması sınıflandırma performansı olan amaç fonksiyonunu maksimuma çıkaran özelliklerin altkümesini bulmak için kullanılabilir. Sarıcı metotlar, sıralı seçme algoritmaları ve sezgisel arama algoritmaları olarak sınıflandırılabilir. Sıralı seçme algoritmaları boş bir kümeyle başlar ve maksimum amaç fonksiyonu elde edilinceye kadar özellik ekler, çıkarır. Seçme işlemini hızlandırmak için minimum özellik sayısı ile maksimum elde edilinceye kadar amaç fonksiyonunu aşamalı olarak artıran bir kriter seçilir. Sezgisel arama algoritmaları amaç fonksiyonunun optimum seviyeye getirebilmek için farklı alt kümeler değerlendirir. Ya bir uzay alanında arama yaparak yada optimizasyon problemine çözümler üreterek farklı alt kümeler oluşturulur.

Sıralı seçme algoritmaları

Bu algoritmalar, algoritmalarının iteratif olmasından ötürü sıralı olarak adlandırılırlar. Sıralı özellik seçimi (Sequential feature selection - SFS) algoritması ilk olarak boş bir küme ile oluşturulur ve amaç fonksiyonu için en yüksek değeri veren bir özellik eklenerek ilk adım gerçekleştirilmiş olur. İkinci adımdan ileriye doğru kalan özellikler teker teker mevcut alt küme eklenir ve yeni alt küme değerlendirilir. Teker teker eklenen özelliklerden hangisi maksimum sınıflandırma oranının veriyorsa o özellik alt küme kalıcı olarak eklenir. Bu işlem gerekli sayıda özellik eklenene kadar tekrarlanır. Özellikler

arasındaki bağımlılık hesaba katılmadığı için bu yöntem bir naive sıralı seçme algoritması olarak değerlendirilebilir. Sıralı geri seçme (Sequential Backward Selection - SBS) algoritması SFS'ye benzer olarak oluşturulabilir ama bu algoritma bütün değişkenlerin bulunduğu bir kümeden başlar ve atıldığı anda tahmin edicinin performansında en az düşüşü sağlayan özelliği dışarıda bırakır. Sıralı ileri hareketli seçme (Sequential Forward Floating Selection - SFFS) algoritması, ekstra geri yönde izleme yapığundan SFS algoritmasından daha esnektir. SFFS'nin teme akış diyagramı Şekil 2.20.'de verilmiştir [81]. Burada k mevcut alt küme büyüklüğü ve d gereken büyüklüktür. Algoritmanın ilk adımı SFS algoritmasıyla aynıdır yani amaç fonksiyonu odaklı bir zamanda özellik eklenir. SFFS algoritması ilk adımda elde edilen bir alt kümeden bir zamanda bir özelliği dışarıda bırakan ve yeni alt kümeleri değerlendiren başka yeni bir adım ekler. Eğer bir özelliğin dışarıda bırakılması amaç fonksiyonunun değerini artırıyorsa o özellik hariç tutulur ve azaltılmış yeni bir alt kümeyle ya da yukarıdan tekrarlanan bir algoritmayla ilk adıma geri dönülür. Bu işlem gereken sayıda özellik eklenene ya da istenilen performansa ulaşılan kadar tekrar edilir.




Şekil 2.20. Sıralı ileri hareketli seçme algoritmasının akış diyagramı

Sıralı ileri seçme ve sıralı ileri hareketli seçme yönteminde bir sonraki dâhil edilen özellik her zaman koşulsuz olarak kümeye eklendiğinden dolayı bazı sıkıntılar yaşanabilmektedir. Bu şu anlama gelmektedir; eğer bu sıralı ileri seçmede en yüksek performansı verirse iki yüksek ilişkili değişken dâhil edilebilir. İç içe geçme etkisinden korunmak için sıralı ileri hareketli seçme yönteminin adaptif versiyonu geliştirilmiştir. Bu algorithmada adaptif olarak hesaplanan özellik ekleme aşamasında özelliklerin sayısını belirten r parametresi kullanılır. r parametresi, performansı artırırsa maksimum sayıda özelliği kaldırmak için dışarı alma fazında kullanılır. Teorik olarak bu metot sıralı ileri hareketli seçme yönteminden daha iyi bir alt küme oluşturur fakat bu yöntem veri dağılımına ve amaç fonksiyonuna bağlıdır.

2.4.5. Gözetimli makine öğrenmesi ve sınıflandırma

Makine öğrenmesi, bilgisayar bilimlerinde birçok uygulamayla birlikte en hızlı gelişen alanlardan biridir ve amacı verideki anlamlı örüntülerin tespit edilmesidir. Makine öğrenmesi gereçleri adaptasyon ve öğrenme yeteneği olan yazılımlarla ilişkilidir. Makine öğrenmesi için çeşitli uygulamalar mevcuttur, bunlardan en önemlilerinden biri veri madenciliğidir. Veri madenciliği ve makine öğrenmesi birbirine bağlı iki tanımdır. Bu iki alanda da verideki gizli örüntülerden bir değer bulmak adına ciddi gelişmeler yaşanmıştır. İstatistik, makine öğrenmesi, bilgi teorisi ve hesaplama, katı bir matematiksel temel ve güçlü gereçlerle sağlam bir bilim dalı oluşturmuştur. Makine öğrenmesi algoritması, algoritmanın istenen çıktılarına göre kategorize edilmiştir. Gözetimli ve gözetimsiz olarak iki ana başlık altında değerlendirilebilir. Gözetimli öğrenme, istenilen çıktılara göre girişleri saptayan bir fonksiyon üretir. Yeni bir veri üretimi makine öğrenmesi tekniklerini zaman içerisinde daha da çok yönlü ve gelişmiş hale getirmiştir. Bu, hem gözetimli hem de gözetimsiz makine öğrenmesi için çeşitli algoritmalarından faydalanılmasını sağlamıştır. Gözetimli öğrenme, genellikle amacın geliştirilen sınıflandırma sisteminin bilgisayara öğretilmesi olduğu için daha sık kullanılır. Çok sayıda verinin içinden gizli örüntünün bulunmasında makine öğrenmesi çok iyi sonuçlar verir, büyük ve farklı veri kaynaklarından önemli kısmı çıkarır. Gözetimli öğrenmenin standart formülasyonlarından biri sınıflandırma problemidir; öğrenici, fonksiyonun çeşitli giriş ve çıkış örneklerine bakarak çeşitli sınıflardan birine bir vektörü ayıran fonksiyona ihtiyaç duyar. Endüktif makine öğrenmesi, eğitim setindeki örneklerden ya da yeni örneklerle kullanılarak genelleştirmek için kullanılan bir sınıflandırıcıdan faydalanılarak bir dizi kuralların öğrenilme işlemidir. Makine öğrenmesinin gerçek bir probleme uygulanma süreci Şekil 2.21.'de gösterilmiştir [82].



Şekil 2.21. Gözetimli makine öğrenmesinin akış diyagramı

Buradaki esas amaç makine öğrenmesinin sınıflandırma işlemi üzerine yoğunlaşarak en yüksek doğruluk ve kesinlik değere sahip en etkili algoritmaya karar vermektir. Büyük ve küçük veri kümelerindeki farklı algoritmaların performansı sağlandığı sürece sınıflandırma işlemi daha doğru bir şekilde yapılır ve gözetimli makine öğrenmesi modellerinin nasıl oluşturulacağı konusunda anlayış kazanılır. Daha çok sınıflandırma problemiyle uğraşan gözetimli makine öğrenmesi bu anlamda çeşitli algoritmalar içerir.

Doğrusal sınıflandırıcılar

Sınıflandırma için kullanılan doğrusal modeller doğrusal (hiperdüzlem) karar sınırları kullanarak giriş vektörlerini sınıflara ayırır. Makine öğrenmesinde doğrusal sınıflandırıcılardaki sınıflandırma işleminin amacı benzer özellik değerlerine sahip öğeleri gruplara ayırmaktır. Bu şu anlama gelmektedir; doğrusal sınıflandırıcı bu amacı özelliklerin doğrusal kombinasyonlarının değeri temelli bir sınıflandırma kararı vererek gerçekleştirmektedir. Doğrusal bir sınıflandırıcı genellikle sınıflandırma zamanının kısıtlı olduğu durumlarda kullanılır. Bu özelliği ile en hızlı sınıflandırma metotlarından biridir. Aynı zamanda boyut olarak büyük veri setlerinde sıklıkla tercih edilir [83].

Lojistik regresyon

Bu sınıflandırma yöntemi, tek bir tahmin ediciye sahip tek bir çokterimli lojistik regresyon ve oluşturma için sınıf kullanan bir sınıflandırma fonksiyonudur. Bu metot genelde iki sınırın olduğu sınıfları ifade eder ve aynı zamanda belli bir yaklaşımda sınırdan olan uzaklığa bağlı sınıf olasılıklarını belirtir. Veri kümesi büyük olduğunda uç noktalar arası (0 ve 1) hızlı geçişler yapar. Olasılık ile ilgili bu süreçler lojistik regresyonu basit bir sınıflandırıcıdan ötesi haline getirir. Bu sayede daha güçlü, daha detaylı tahminler yapar. Lojistik regresyon uygulamalı istatistik ve ayrık veri analizi için en sık kullanılan yöntemlerden biridir [84].

Naive Bayes (NB) sınıflandırıcı

Makine öğrenmesindeki bu sınıflandırıcı farklı öğelerin belirli özelliklere göre ayrılmasında kullanılır. NB sınıflandırıcı, sınıflandırma işlemlerinde kullanılan olasılıksal bir makine öğrenmesi modelidir. Bu sınıflandırıcının temel noktası Bayes teoremi odaklıdır.

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (2.124)$$

Bayes teoremi kullanılarak, B ortaya çıktığında A'nın gerçekleşme olasılığı bulunabilir. Eş. 2.124 ile ifade edilir. Burada B bulgu, A hipotezdir. Buradaki varsayım tahmin


edicilerin/özelliklerin bağımsız olmasıdır. Yani belirli bir özelliğin varlığı diğer özelliği etkilememektedir. Bu yüzden naive olarak adlandırılır.

Çok katmanlı algılayıcı

Bu, ağırlıklarının standart sinir ağı eğitimiyle dış bükey olmayan sınırlandırılmamış minimizasyon problemiyle çözmekten ziyade doğrusal sınırlarla ikinci dereceden programlama probleminin çözülmesiyle sağlanan bir sınıflandırma metodudur [83]. Eğitim seti boyunca tekrar ederek çalışan algoritmayla bütün eğitim kümesinde doğru olan tahmin vektörünü bulana kadar algılayıcı algoritması kullanılır. Bu tahmin kuralı sonrasında test kümesinde etiketlerin tahmininde kullanılır [85].

Destek vektör makineleri

Destek vektör makine (Support Vector Machine, SVM) modelleri klasik çok katmanlı algılayıcı sinir ağlarıyla yakından ilişkilidir. SVM, iki sınıfı ayıran bir hiperdüzlemin her iki tarafında da bir sınır (marjin) uzaklığında işlem yapar. Marjini maksimuma çıkarma hiperdüzlemi ve her iki taraftaki durumları ayırarak olası en büyük uzaklığı sağladığı için beklenen genelleştirme hatasını düşürür [85].



Şekil 2.22. Destek vektör makineleri sınıflandırıcısı

K-ortalamlar

K-ortalamlar iyi bilinen kümeleme problemini çözen en basit gözetimsiz öğrenme algoritmalarından biridir. İşlem, bir önselde sabitlenmiş belirli sayıda küme (k küme sayısı) aracılığıyla verilen veri setini sınıflandırmak için kolay bir yol izler. K-ortalamlar yöntemi etiketlenmiş verinin olmadığı durumlarda kullanılabilir [86]. Genel metodu kabataslak elde edilen kuralları yüksek doğruluk oranlı tahmin kurallarına dönüştürmektir. Örnek olarak %55 doğruluk oranlı yetersiz bir öğrenme algoritması (ampirik olarak) bile rasgele seçimden daha iyidir. Yeterli veri ile geliştirilmiş bir algoritma örneğin %99 yüksek doğruluk oranlı bir sınıflandırıcı oluşturabilir [87].

K- en yakın komşuluk

K- en yakın komşuluk (k-nearest neighbour - k-NN) örnek tabanlı bir öğrenme türüdür. Aynı zamanda fonksiyonun yerel olarak tahmin edildiği ve bütün hesaplamaların sınıflandırmaya kadar ötelendiği bir tembel öğrenmedir. k-NN, sınıflandırma ve regresyon için kullanılan parametrik olmayan bir yöntemdir. Sınıflandırma çıktısının sınıf elemanı olduğu durumda nesnenin, komşuluklarının çoğunluğuna bakılarak sınıfı belirlenir. k

sayıda komşuluklarının arasından komşuluk sayısı hangi sınıfa daha çok dahilse, nesne o sınıfın elemanı olarak değerlendirilebilir. Bu kural kolay bir şekilde öğrenme süresince eğitim kümesinde uygulanır. k-NN, anlaşılması ve uygulanması gayet kolay bir algoritmadır aynı zamanda iki örnek arasındaki uzaklığın ölçülmesi dışında hiçbir varsayımda bulunmadığı için güçlü bir gereçtir. Bu yüzden, parametrik olmayan ya da doğrusal olmayan olarak adlandırılır. Örneğin komşuluklara olan uzaklıklarının belirlenmesinde çeşitli uzaklık metrikleri kullanılır. Belirlenmiş bir veri kümesinde en iyi çalışacak algoritmayı belirlemek için en uygun uzaklık metriğinin seçilmesi gerekmektedir.

Öklit uzaklığı k-nn sınıflandırmada en sık kullanılan metriklerden biridir. İki nokta arasındaki tam doğrusal uzaklığı ölçer. Manhattenn uzaklığı iki nokta arasındaki mutlak farkların toplamını hesaplar. Çebişev ise iki nokta arasındaki maksimum mutlak farkları hesaplar. Minowski ise bütün bu mesafelerin genellenebilir halidir.

Çizelge 2.2. K-nn uzaklık metriklerinin formülasyonları

Uzaklık metriği	Formül
Öklit	$d(p, q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2}$
Manhattenn	$d(p, q) = \sum_{i=1}^n p_i - q_i $
Çebişev	$d(p, q) = \text{maksimum}(p_i - q_i)$
Minkowski	$d(p, q) = (\sum_{i=1}^n p_i - q_i ^p)^{\frac{1}{p}}$

Karar ağaçları

Karar ağaçları, durumları özelliklerin değerine göre ayırarak ağacın dalları gibi sınıflandırır. Karar ağacındaki her düğüm sınıflandırılacak durumdaki bir özelliği temsil eder ve her bir dal düğümün üstleneceği bir değeri ifade eder. Durumlar temel düğümden başlayarak ve özellik değerlerine göre ayrılarak sınıflandırılır. Veri madenciliği ve makine öğrenmesinde kullanılan karar ağaçları öğrenmesi, ögenin hedef değeriyle ilgili sonuçlara göre öge hakkında gözlemleri haritalandıran tahmin edici bir model gibi bir karar ağacı kullanır. Karar ağacı sınıflandırıcıları genellikle karar ağaçlarının performansını değerlendiren budama (pruning) tekniğini kullanırlar. Eğitim durumlarının en sık kullanılan herhangi bir düğüm kaldırılabilir ya da eklenebilir [85].

Sinir ağıları (Neural networks - NN)

Sinir ağıları belli sayıda regresyon ve/veya sınıflandırma işlemini aynı anda yapabilir fakat buna rağmen genelde her ağ tek bir işlem yapar. Bu yüzden çoğu durumda fazla durum sınıflandırması olduğu halde ağın tek bir çıkış değeri olur. Bu çıkış birimlerinin sayısı ile ilişkilidir. Yapay sinir ağıları (Artificial neural networks - ANN) 3 temel hale bağlıdır, bunlar; birimin giriş ve aktivasyon fonksiyonları, ağ mimarisi ve her giriş bağlantısının ağırlığıdır. İlk iki durum sabitlendiğinde, ANN'in davranışı ağırlıkların mevcut değerleriyle tanımlanır. Eğitilecek ağların ağırlıkları ilk olarak rastgele değerlere ayarlanmalı ve sonrasında eğitim kümesi sürekli ağa maruz bırakılır. Bir durumun girişi için değerleri giriş birimlerine kaydedilir ve ağın çıkışı bu durum için istenen çıkışla karşılaştırılır. Sonrasında, ağdaki bütün ağırlıklar istenen çıkış değerlerine yakın ağın çıkış değerini getirecek yönde yavaşça ayarlanır [88].

Bayes ağı

Bayes ağı (Bayesian network, BN) bir dizi özellik arasındaki olasılık ilişkisini belirleyen bir grafiksel modeldir. Bayes ağları istatistiksel öğrenme algoritmalarının en çok bilinen temsilcilerindendir. Karar ağaçları veya sinir ağlarıyla karşılaştırıldığında bayes ağlarının en ilgi çekici özelliği, özellikleri arasında yapısal ilişki bakımından verilen problemle ilgili önsel bilgiyi kesinlikle hesaba katma olasılığıdır [85]. Bu sınıflandırıcılar ilgili bir problemde çok fazla özellik içeren veri kümeleri için uygun olmayışdır [89].

Makine öğrenmesi algoritmalarının özellikleri

Gözetimli makine öğrenmesi algoritmaları birçok alanda kullanılmaktadır. Genel olarak, SVM ve NN algoritmaları çok boyutlu ve sürekli özelliklerle daha iyi çalışmaktadır. Diğer yandan, mantık temelli sistemler ayrık/kategorik özelliklerle işlem yapmaya daha yatkındır. NN ve SVM modellerinde maksimum doğruluk elde etmek için örnek kümesi büyük olmalıdır oysaki NB onlara kıyasla daha küçük veri setiyle de işlemini başarıyla yapabilir.

k-NN'in birbiriyle ilişkisi olmayan özelliklere karşı çok hassas olduğuna dair genel bir görüş vardır. Bu karakteristik algoritmasının çalışma şekliyle açıklanabilir. Dahası ilişkisiz

özelliklerin mevcudiyeti sinir ağı eğitimini çok verimsiz ve kullanışsız hale getirir. Çoğu karar ağacı algoritması diyagonal ayırmanın gerekli olduğu problemlerde çok iyi işlem yapamaz. Uzay durumunun bölünmesi değişkenlerin birinin eksenine dikey diğer bütün eksenlere paraleldir. Bu yüzden ayırmanın sonunda elde edilen son bölgelerin hepsi hiper dikdörtgendir. Yapay sinir ağları ve destek vektör makineleri çoklu bağlanım olması ve giriş-çıkış özelliklerinin arasında doğrusal olmayan bir ilişki olması halinde verimli şekilde uygulanır.

NB eğitim ve sınıflandırma adımlarının ikisinde de az hafızaya ihtiyaç duyar. Önseli ve koşullu olasılıkları depolamak için ihtiyaç duyulması asgari şarttır. Temel k-NN algoritması eğitim aşamasında alan depolanmasıyla alakalı iyi çalışır. Algoritmanın çalışma alanı en azından eğitim alanı kadar büyük olmalıdır. Buna karşılık, bütün tembel olmayan öğrenme algoritmaları için çalışma alanı, sınıflandırıcı genelde verinin yüksek derecede sıkıştırılmış toplamı olduğu için eğitim alanından çok daha küçüktür. Bunu yanında, NB ve k-NN sürekli artan öğrenme algoritmalarında kolayca kullanılabilirken kural algoritmaları kullanılamaz. NB kendi doğası itibarıyla özellikleri azaltma konusunda güçlüdür çünkü bu özellikler hesaplama olasılıklarında kolayca göz ardı edilebilirler bu yüzden son kararda etkileri yoktur. Bunun aksine, k-NN ve sinir ağları kendi işlerini yapabilmek için bütün kayıtlara gereksinim duyarlar.

Son olarak, karar ağaçları ve naive naves genelde farklı işlevsel karakteristiklere sahiptirler. Biri çok isabetli karar verirken diğer öyle değildir ya da tam tersidir. Diğer taraftan karar ağaçları ve kural sınıflandırıcılarının benzer operasyonel profilleri vardır. Aynı şekilde SVM ve ANN'de benzer çalışma mekanizmalarına sahiptir. Tek başına hiçbir öğrenme algoritması her veri kümesinde diğerlerinden daha iyi olamaz.

Çeşitli özelliklere sahip farklı veri kümeleri ve birtakım durumlar iyi çalışacak algoritmanın türüne karar verir. Çizelge 2.3.'te sınıflandırma algoritmalarının karşılaştırmalı değerlendirmesi yapılmıştır [85]. "*****" en iyi "*" en kötü performansı ifade etmektedir.


Çizelge 2.3. Öğrenme algoritmalarının karşılaştırılması

	Karar ağaçları	Sinir ağları	Naive Bayes	k-nn	SVM	Kural öğrenicileri
Gene olarak doğruluk	**	***	*	**	****	**
Özellik ve durum sayıları bakımından öğrenme hızı	***	*	****	****	*	**
Sınıflandırma hızı	****	****	****	*	****	****
Eksik değerlere tolerans	***	*	****	*	**	**
İlişkisiz özelliklere tolerans	***	*	**	**	****	**
Gereksiz özelliklere tolerans	**	**	*	**	***	**
Yüksek derecede birbirine bağlı özelliklere tolerans	**	***	*	*	***	**
Ayrık/ikili/sürekli özelliklerle başa çıkma	****	***	***	***	**	***
Gürültüye tolerans	**	**	***	*	**	*
Aşırı öğrenmeyle başa çıkma	**	*	***	***	**	**
Sürekli öğrenme girişimleri	**	***	****	****	**	*
Kabiliyetin/bilginin şeffaflığını/sınıflandırmanın açıklanması	****	*	****	**	*	****
Model parametre kullanılması	***	*	****	***	*	****

2.4.6. Sınıflandırma performansının değerlendirilmesi

Çapraz doğrulama veriyi iki bölüme ayırarak öğrenme algoritmalarını değerlendiren ve karşılaştıran bir istatistiksel yöntemdir. Birinci bölüm modeli öğrenme veya eğitime için ikinci bölüm ise modeli doğrulamak için kullanılır. Geleneksel çapraz doğrulamada eğitim ve doğrulama kümeleri her bir veri noktasının karşılıklı doğrulanma şansı olacak şekilde çapraz geçiş yapmalıdır. Çapraz doğrulamanın temel formu k-kat çapraz doğrulamadır. Çapraz doğrulamanın diğer formları k-kat çapraz doğrulamanın özel durumlarıdır ya da k-kat çapraz doğrulamanın tekrarlanan dizilerini içerir. k-kat çapraz doğrulamada veri ilk olarak eşit k büyüklüğündeki (veya neredeyse eşit) kısımlara ya da katlara ayrılır. Sonrasında eğitim ve doğrulamanın k iterasyonları, kalan k-1 katlar öğrenme için kullanıldığı esnada geçerleme için saklanan verinin farklı bir kattaki her iterasyonu içinde olacak şekilde uygulanır [90]. Şekil 2.23'te 5-kat çapraz doğrulama örneği verilmiştir. Bu örnekte k=5 olduğu için veri kümesi 5 eşit parçaya bölünmüştür. Sonrasında bir bölüm geçerleme katı diğer dört bölüm eğitim katı olacak şekilde işlem sıralı olarak devam etmiştir. Her bir kat için yerine getirilen eğitim ve doğrulama işlemlerine ait performanslar

bulunmuş ve en sonunda da bu performansların aritmetik ortalaması alınarak modelin performansı ortaya çıkarılmıştır.



Şekil 2.23. 5-kat çapraz doğrulama örneği

Çapraz doğrulama öğrenme algoritmalarını değerlendirmek ve karşılaştırmak için şu şekilde kullanılır: bir ya da daha fazla öğrenme algoritması, bir ya da daha fazla modeli öğrenmek için veri kümesinin $k-1$ katını kullanır ve sonrasında öğrenmiş modellerin doğrulama katındaki veri hakkında tahmin yapması beklenir. Her kattaki her öğrenme algoritmasının performansı öncesinde belirlenmiş örneğin doğruluk gibi bir performans metriğiyle değerlendirilebilir. İşlem tamamlandıktan sonra k sayıda performans metriği elde edilmiş olur. Bu örneklerden tek bir ölçüm elde edebilmek için ortalama alma gibi farklı metodolojiler kullanılabilir ya da bu örnekler bir algoritmanın bir değerine olan üstünlüğünü test etmek için bir istatistiksel varsayımda kullanılabilir [90].

Bu amaçlar doğrultusunda k -kat doğrulama yönteminden çeşitli prosedürler türetilmiştir. Bunlar; yeniden yerleştirme doğrulaması, hold-out doğrulama, tek-çıkışlı çapraz doğrulama ve tekrarlı k -kat çapraz doğrulama yöntemleridir. Bu yöntemlerin her birinin ayrı ayrı avantajları ve dezavantajları vardır ve bunlar Çizelge 2.4'te yer almaktadır.

Çizelge 2.4. Farklı doğrulama yöntemlerinin avantajları ve dezavantajları

Doğrulama yöntemi	Avantajları	Dezavantajları
Yeniden yerleştirme doğrulaması	Basit	Aşırı öğrenme
Hold-out doğrulama	Bağımsız eğitim ve test	Test ve eğitim için azaltılmış veri, büyük varyans
K-kat çapraz doğrulama	Doğru performans tahmini	Performans tahmininin küçük örnekleri, örtüşmeli eğitim verisi, karşılaştırma için yüksek tip I hatası, düşük tahmin edilmiş performans varyansı veya karşılaştırma için yüksek tahmin edilmiş serbestlik derecesi
Tek-çıkışlı çapraz doğrulama	Tarafsız performans tahmini	Çok büyük varyans
Tekrarlı k-kat çapraz doğrulama	Çok sayıda performans tahmini	Her tur arası örtüşmeli eğitim ve test verisi, düşük tahmin edilmiş performans varyansı ya da karşılaştırma için yüksek tahmin edilmiş serbestlik derecesi

10-Kat çapraz doğrulama

İster öğrenme algoritmasının performansını değerlendirilmesinde ister iki ya da daha fazla algoritmanın öğrenme yetenekleri bakımından karşılaştırılmasında, ideal veya istatistiksel olarak uygun deneysel bir tasarım, algoritma performansının değerlendirilmesi için yeterli sayıda bağımsız ölçümler sağlamalıdır. Bir algoritma performansının bağımsız ölçümlerinin oluşturabilmek için, ölçümleri etkileyen faktörlerin birbirini izleyen iki işlemten bağımsız olmaları sağlanmalıdır. Bu faktörlerden biri, eğitim verisinden elde edilen algoritma ve algoritma performansını ölçmek için kullanılan test verisidir. Eğer bazı veriler test için birden fazla turda kullanılıyorsa elde edilen sonuçlar örnek olarak bu iki turdan elde edilen doğruluk ölçümleri bağımlı olur ve istatistiksel karşılaştırma geçerli olmayabilir. Aslında, yüksek derecede Tip I hata olasılığına sahip olma ve hiçbir zaman kullanılmama eğilimi olan çeşitli rastgele eğitim/test bölümleri bulma odaklı ikili t-testi gösterilmiştir [91]. Sadece zorunlu veri kümelerinin kontrollü farklı işlemler boyunca bağımsız olması değil, aynı işlemde öğrenme için kullanılan veriyle doğrulama arasında kullanılan veri arasında örtüşme olmaması gerekmektedir. Genel anlamda, bir öğrenme algoritması öğrenme aşamasında görülmeyenden ziyade görülen veride daha doğru tahmin

yapabilir. Bu sebepten, eğitim ve doğrulama kümesi arasındaki bir örtüşme performans metriğinin tahminin gerçek değerinden büyük olmasına yol açabilir ve kullanılmaz.

Burada mesele k için uygun bir değerin belirlenmesidir. Yüksek bir k değeri ilk bakışta mantıklı gelmektedir çünkü yüksek bir k değeri daha fazla performans tahmini yapılır ve eğitim kümesi büyüklüğü bütün veri büyüklüğüne yakındır. Böylece, öğrenme modelini eğitmek için kullanılan bütün verilerdeki duruma genelleyecek test altındaki öğrenme algoritmasıyla ilgili herhangi bir sonucun yaptığı olasılığı artırır. k arttığında, eğitim kümeleri arasındaki örtüşme de aynı zaman da artar. Örneğin bir 5-kat çapraz doğrulamayla her bir eğitim kümesi, diğer 4 eğitim kümesiyle birlikte eğitim kümesinin durumlarının sadece $3/4$ 'ünü paylaşır oysaki 10-kat çapraz doğrulamayla her eğitim kümesi diğer 9 eğitim kümelerinin her biriyle birlikte kendi durumlarının $8/9$ 'unu paylaşır. Buna ek olarak, k 'yı artırmak test kümesinin büyüklüğünü azaltır bu da kesinliğin düşmesine, performans metriğinden daha az hassas ölçümler alınmasına yol açar. Örnek olarak, 10 durum büyüklüğündeki bir test kümesiyle, %10'a yakın bir doğruluk ölçülebilirken 20 durumluyla bu değere %5'e yakın olur. Birbirine rakip olan bütün bu faktörler değerlendirilmiş ve $k=10$ değeri üzerinde uzlaşılarak bir fikir birliği sağlanmıştır. Bu k değeri verinin %90'ını kullanarak tahmin ve tüm veriyi daha genellenebilir yaptığı için özellikle ilgi çekicidir [90]. Sonuç olarak k 'nın belirlenmesi için kesin bir kural yoktur fakat çalışmalarda genellikle 10 kabul görmüş bir değerdir [92].



3. YÖNTEM

Bu bölümde çalışmada kullanılan yöntemler verilmiştir.

3.1. Sınıflandırma Modelinin Oluşturulması

3.1.1. Veri alımı


Çalışmaya Bozok Üniversitesi Nükleer Tıp Anabilim Dalı'na MPS çekirmek üzere başvuran, vücut kitle indeksi ortalaması 32,33, yaş ortalaması $52,3 \pm 9,7$ olan 81 kadın hasta dahil edilmiştir. Hastalara egzersiz/ farmakolojik stres sonrasında intravenöz yoldan 20 mCi Tc-99m sestamibi enjeksiyonunu takiben 45-60 dakikada Stres Gated-SPECT görüntüleme çalışması yapılmıştır. Stres-MPS çalışması sonucunda iskemi lehine bulgu gözlenen hastalara ertesi gün 20 mCi Tc-99m sestamibi enjeksiyonunu takiben 45-60 dakikada Rest Gated-SPECT çalışması yapılmıştır. Gated-SPECT görüntüleri, EKG ile senkronize edilerek düşük enerjili, yüksek çözünürlüklü, paralel delikli kolimatör takılı çift başlı gama kamera (Philips, Brightview) ile 45° sağ anterior oblikten, 45° sol posterior obliğe, 140 ± 20 keV enerji piki ve R-R mesafesi 8 eşit aralığa bölünerek, 64×64 matriste, sırtüstü yatar pozisyonda her bir görüntü 30 saniye olacak şekilde toplam 32 görüntü elde edilmiştir. Görüntülere Butterworth filtresi (order: 5,0; cut off: 0,50 siklus/ piksel) kullanılarak, geriye projeksiyon metodu ile rekonstrüksiyon işlemi uygulanmıştır. Kısa eksen, horizontal uzun eksen ve vertikal uzun eksen kesitleri alınmıştır.

Elde edilen veriler QGS-SPECT otomatik kantifikasyon programı kullanılarak 17 segment-5 dereceli skorlama yöntemi ile vizüel ve kantitatif olarak değerlendirildi. Otomatik kantifikasyon; sol ventrikül, kısa eksen görüntüleri toplatılarak apikal, mid-ventriküler ve bazal kesitler olmak üzere üç kesitte, vertikal uzun eksen kesitlerinde ise midventriküler düzeyden tek kesit olarak 17 segment-5 dereceli skorlama modeline göre oluşturulan polar harita (bull's-eye) kullanılarak semikantitatif olarak değerlendirildi. Gated-SPECT çalışmasının sonucunda perfüzyon, duvar hareketi ve duvar kalınlaşması için en az iki segmentte, iki ve üzeri derecede (≥ 2) skor bulunması ve bu değerlendirmenin görsel olarak da desteklenmesi durumu pozitif sonuç (iskemi) olarak kabul edildi.

İskemi bulgusu gözlenen hastalar, kalp damarlarındaki darlığın tespit edilmesi amacıyla Koroner Anjiyografiye (KAG) yönlendirildi. KAG sonucuna göre MPS’de Mİ tespit edilen hastalar doğru pozitif (damar tıkanıklığı olanlar) ve yanlış pozitif (meme atenüasyonu olanlar) olarak iki gruba ayrıldı. Veri setindeki 81 örneğin 51’i gerçek pozitif, kalan 30’u ise yanlış pozitif, yani kullanılan hasta grubundan sadece 51 tanesi gerçekten hasta iken diğer 30 tanesinde meme atenüasyonu vardır.


3.1.2. Görüntü bölütleme (Segmentasyon)

Bölütlemeye amaç, kullanılacak ilgi alanının (Region of Interest - ROI) elde edilmesidir. Çalışmamızda Otsu yöntemi kullanılarak ilgi alanı otomatik olarak elde edilmiştir.




Şekil 3.1. Ham görüntüden ilgi alanının (ROI) elde edilmesi: (1) ham görüntü (2) 21x21 boyutlu önceden belirlenen bölge (3) Otsu metodundan sonra (4) morfolojik işlemler sonrası (5) ilgi alanı (ROI)

Şekil 3.1’de ROI’nin nasıl elde edildiği gösterilmiştir. İlk olarak ham görüntüde daha öncesinde belirlenen konumdaki 21x21’lik büyüklükte alt bölge elde edilmiştir. Sonrasında çıkarılan bu bölgeye Otsu metoduyla eşikleme yapılmıştır. İstenmeyen pikseller çeşitli morfolojik işlemler sonrası temizlenmiştir. Oluşturulan bu maske sayesinde ROI elde edilmiştir.



Şekil 3.2. (a) Bir hastaya ait ham kesit görüntüsü (b) ham görüntüden otomatik olarak elde edilen ROI

Şekil 3.2’de görüldüğü gibi ROI’ni otomatik olarak belirlenmesi esnasında bazı örneklerde istenmeyen bölgenin de ROI’ye dâhil edildiği tespit edilmiştir. Bu durumun önüne geçmek için ROI’nin otomatik olarak elde edilmesinin yanında, kullanıcının ROI’yi elle manuel olarak seçmesine imkân sağlayan bir program geliştirilmiştir.



Şekil 3.3. (a) Bir hastaya ait ham kesit görüntüsü (b) ham görüntüdeki ROI’nin işaretlenmesi (c) elde edilen bölgenin ham görüntüdeki pozisyonu

Elle ROI seçiminin adımları Şekil 3.3.’te gösterilmiştir. ROI’nin elle seçilmesi, ROI’ye istenmeyen bölgelerin dâhil olmasının önüne geçmektedir.

3.1.3. Özellik çıkarma

Özellik çıkarma işlemleri için Radiomics modeli ve Pyradiomics paket programı kullanılmıştır. Bu yöntemler sayesinde çok sayıda özellik çıkarılmıştır. Özellik sayısının fazla olması temsil gücü yüksek özellik bulunma ihtimalini artırdığı için, modelin doğruluğunu etkilemektedir.

Radiomics modeli

Radiomics, medikal alanda elde edilen radyolojik görüntülerden çeşitli özellikler çıkarmamıza imkan sağlayan bir modeldir. Bu özellikler görüntüler hakkında gözle anlaşılamayabilecek farklılıkların belirlenmesinde kullanılır. Bu özelliklerin çıkarılması daha sonrasında yapılacak olan sınıflandırma işlemlerinden elde edilecek sonuçları olumlu yönde etkilemektedir. Radiomics modeli [93] sayesinde, varyans, çarpıklık ve basıklık olan 3 tanesi birinci derece, GLCM, GLRLM, GLSZM ve NGTDM ile elde edilen 39 tanesi ikinci ve yüksek derece olan toplamda 42 özellik çıkarılmıştır. Bu model kullanılarak yapılan özellik çıkarma işlemleri Matlab 2014a programı yardımıyla gerçekleştirilmiştir.

Pyradiomics paket programı

Bu paket programı sayesinde iki ve ya üç boyutlu medikal görüntülerden Radiomics özellikleri çıkarılabilmektedir [78]. Bu program bir önceki bölümde bahsedilen Radiomics modelinden farkı çok daha fazla özellik çıkarabilmesidir. Sayı olarak fazla özellik çıkarmasının yanında Radiomics modelinde olmayan GLDM'ye ait özellikler ve şekil tabanlı özelliklerle birlikte toplam 109 farklı özellik üretmektedir. Pyradiomics ve Radiomics modellerinin oluşturduğu özelliklerin karşılaştırılması Çizelge 3.1'de verilmiştir.

Çizelge 3.1. Radiomics ve Pyradiomics modellerinin çıkardıkları özelliklerin sayısal olarak karşılaştırılması

Özellikler	Radiomics	Pyradiomics
Birinci Derece Özellikler	3	19
Şekil-Tabanlı Özellikler	0	16
GLCM Özellikleri	8	23
GLRLM Özellikleri	13	16
GLSZM Özellikleri	13	16
GLDM Özellikleri	0	14
NGTDM Özellikleri	5	5
Toplam	42	109

Birinci derece istatistiksel özellikler

Birinci-derece doku analizi ölçümleri, dokuyu hesaplayabilmek için görüntü histogramını ve piksel oluşum olasılığını kullanır. Bu yaklaşımın başlıca avantajı veriyi karakterize etmek için standart tanımlayıcılar (ortalama, varyans vs.) kullanılarak işlemi kolaylaştırmasıdır. Fakat, bu yaklaşımın dokuları ayırmadaki gücü belirli uygulamalarla sınırlanmıştır çünkü bu metot pikseller arası uzaysal ilişkiyi ve korelasyonu hesaba katmaz. Herhangi bir yüzey ya da görüntü için, gri seviyeler $0 \leq i \leq N-1$ aralığındadır ve N belirli gri seviyelerin toplam sayısıdır. Eğer N(i), i yoğunluklu piksellerin sayısıysa, M görüntüdeki toplam piksel sayısıdır. Eş. 3.1’de histogram ya da piksel oluşum olasılığı verilmiştir.

$$p(i) = \frac{N(i)}{M} \quad (3.1)$$

İzotropik vokselle boyutlu ilgi hacmimiz ve birinci derece histogram sırasıyla $V(x,y,z)$ and P şeklinde ifade edilebilir. P(i), i gri seviyeli voksellerin sayısını ve N, P seti için gri seviye değeri sayısını ifade etmektedir. Histogramın i’inci girişi Eş. 3.2’deki gibi hesaplanabilir.

$$p(i) = \frac{P(i)}{\sum_{i=1}^N P(i)} \quad (3.2)$$


Çalışmamızda görüntülerimizden çıkarılan birinci derece istatistikler Çizelge 2.2’de verilmiştir.

Çizelge 3.2. Çalışmamızdaki görüntülerden çıkarılan birinci derece istatistikler


1. Varyans	11. Minimum (Minimum)
2. Çarpıklık (Skewness)	12. Aralık (Range)
3. Basıklık (Kurtosis)	13. Dayanıklı Ortalama Mutlak Sapma (Robust Mean Absolute Deviation)
4. Entropi (Entropy)	14. Karekök Ortalama (Root Mean Squared)
5. Çeyrekler Arası Aralık (Interquartile Range)	15. Toplam Enerji (Total Energy)
6. 10 Yüzdelik (10 Percentile)	16. Düzenlilik (Uniformity)
7. 90 Yüzdelik (90 Percentile)	17. Maksimum (Maximum)
8. Ortalama Mutlak Sapma (Mean Absolute Deviation)	18. Enerji (Energy)
9. Ortalama (Mean)	19. Standart Sapma (Standard Deviation)
10. Medyan (Median)	

İkinci derece istatistiksel özellikler

Komşu iki piksel arasındaki ilişkiyi belirlemek için kullanılan doku analizi, ikinci-derece istatistiksel doku analizi olarak tanımlanır. Gri-seviye eş oluşum matrisi (Gray Level Co-occurrence Matrix, GLCM) , M.Haralick tarafından ortaya atılmış bir özellik çıkarma yöntemi olup, gri tonlu bir görüntünün özneteliğini çıkarmaya yarar. GLCM, iki komşu piksel arasındaki ilişkiyi tanımlar. Bu piksellerden birincisi referans pikseli, ikincisi de komşu piksel olarak bilinir [94]. P , izotropik voksel büyüklüklü kuantize edilmiş $V(x,y,z)$ hacminin GLCM'sini tanımlar. $P(i,j)$, V 'deki i gri seviyeli voksellerin, j gri seviyeli voksellerle komşuluk sayısını ve N_g , V 'deki daha önceden belirlenmiş kuantize edilmiş gri seviye setinin sayısını ifade eder. Üç boyutlu uzaydaki bağlantılı 26 komşuluklu bütün voksellerin eş oluşumlarının sıklıklarının aynı anda eklenmesiyle V hacim başına $N_g \cdot N_g$ boyutlu çevresel bölgeleri içeren merkez voksel olarak kabul edilen bütün voksellerle sadece bir GLCM oluşturulur. Sonuçta bir vokselde, merkez voksele uzaklıkları 1, $\sqrt{2}$ ve $\sqrt{3}$ olan toplam 26 komşuluk bulunur. Farklı uzaklıkta ve sayılardaki komşuluklar Şekil 3.4 ve Şekil 3.5'te gösterilmiştir. Şekil 3.5'te u , komşuluk sayısını ifade etmektedir. Mavi küp merkez vokseli, kırmızı vokseller komşu vokselleri göstermektedir. Maksimum komşu sayısı 26'dır.




Şekil 3.4. Merkez vokselile ilişkili 26 komşuluğun gösterimi



Şekil 3.5. 26 komşuluğun 3 boyutlu gösterimi

Şekil 3.6.a'da gri seviye sayısı 8, pikseller arası uzaklık $d=1$ ve yön açısı $0=9$ olarak hesaplanmış bir eş-oluşum matrisinin örneği verilmiştir. En çok ortak bilinen yönler 135,90,45,0=9 ve bunların simetrik benzerleridir. Bu durum Şekil 3.6.b'de gösterilmiştir.



Şekil 3.6. (a) GLCM örneği (b) GLCM'ye ait simetrik benzerlikler

Çıkarılan GLCM özellikleri Çizelge 3.3'te verilmiştir.

Çizelge 3.3. Çalışmamızdaki görüntülerden çıkarılan GLCM özellikleri

1. Enerji (Energy)	14. Fark Varyansı (Difference Variance)
2. Zıtlık (Contrast)	15. Ters Fark (Inverse Difference, ID)
3. Korelasyon (Correlation)	16. Ters Fark Momenti (Inverse Difference Moment, IDM)
4. Homojenlik (Homogeneity)	17. Normalize Ters Fark Momenti (Inverse Difference Moment Normalized, IDMN)
5. Varyans (Variance)	18. Normalize Ters Fark (Inverse Difference Normalized, IDN)
6. Toplam Ortalama (Sum Average)	19. Korelasyon Düzensiz Ölçümü 1 (Informal Measure of Correlation, IMC 1)
7. Entropi (Entropy)	20. Korelasyon Düzensiz Ölçümü 2 (Informal Measure of Correlation, IMC 2)
8. Benzeşmezlik (Dissimilarity)	21. Ters Varyans (Inverse Variance)
9. Küme Uzantısı (Cluster Prominence)	22. Birleşik Ortalama (Joint Average)
10. Küme Gölgesi (Cluster Shade)	23. Maksimum Olasılık (Maximum Probability)
11. Küme Eğilimi (Cluster Tendency)	24. Toplam Entropi (Sum Entropy)
12. Fark Ortalaması (Difference Average)	25. Toplam Kareler (Sum Squares)
13. Fark Entropisi (Difference Entropy)	26. Otokorelasyon (Autocorrelation)

Yüksek derece istatistiksel özellikler

Gri seviye koşu uzunluğu matrisi


Gözlemlere dayanarak, bir dokuda uzun gri seviye tekrarları nispeten daha fazladır. İyi bir doku kısa tekrarlar içermelidir. Galloway koşu tekrarı matrisinin kullanılmasını doku özelliği çıkarmak için teklif etmiştir [95]. Verilen bir görüntü için, P izotropik voksel boyutlu $V(x,y,z)$ 'nin gri seviye koşu uzunluğu matrisi olarak tanımlanır. $P(i,j)$, V'deki i gri seviyeli j koşusunu gösterir. N gri seviye setinin büyüklüğünü ifade etmektedir. L_r , V'deki en uzun koşuyu belirtmektedir. Her bir V hacmi için $N \times L_r$ büyüklüğünün sadece bir gri seviye koşu uzunluğu matrisi (Gray Level Run Length Matrix, GLRLM), 3 boyutta 13 yöndeki bütün koşu uzunluklarının eş zamanlı olarak toplanmasıyla aşağıdaki eşitliklerle hesaplanır.

Normalize edilmiş GLRLM'nin girişi (i,j) Eş. 3.3.a'daki gibi tanımlanır.

$$p(i,j) = \frac{P(i,j)}{\sum_{i=1}^N \sum_{j=1}^{L_r} P(i,j)} \quad (3.3.a)$$

$$\mu_i = \sum_{i=1}^N i \sum_{j=1}^{L_r} p(i,j) \quad (3.3.b)$$

$$\mu_j = \sum_{j=1}^{L_r} j \sum_{i=1}^N p(i,j) \quad (3.3.c)$$



Şekil 3.7. (a) Örnek bir doku matrisi (b) bu doku için gri seviye koşu uzunluğu matrisi oluşturulması

Şekil 3.7.a’da örnek bir doku matrisi, b’de ise koşu uzunluğu matrisi verilmiştir. Örnek olarak, doku matrisini 2 gri seviye ve 2 tekrar uzunluğu için sıfır derecede incelersek görüldüğü üzere bu kombinasyon matraste toplam dört adet bulunmuştur. Bu değer Şekil 3.7. b’ de kırmızı renk yazı tipi ile gösterilmiştir.

Çizelge 3.4. Çalışmamızdaki görüntülerden çıkarılan GLRLM özellikleri

1. Kısa Koşu Vurgusu (Short Run Emphasis, SRE)	9. Kısa Koşu Yüksek Gri-Seviye Koşu Vurgusu (Short Run High Gray-Level Run Emphasis (SRHGE)
2. Uzun Koşu Vurgusu (Long Run Emphasis, LRE)	10. Uzun Koşu Düşük Gri-Seviye Vurgusu (Long Run Low Gray-Level Emphasis, LRLGE)
3. Gri-Seviye Değişebilirliği (Gray-Level Nonuniformity, GLN)	11. Uzun Koşu Yüksek Gri-Seviye Vurgusu (Long Run High Gray-Level Emphasis, LRHGE)
4. Koşu-Uzunluğu Değişebilirliği (Run-Length Nonuniformity, RLN)	12. 20.Gri-Seviye Varyansı (Gray-Level Variance, GLV)
5. Koşu Yüzdesi (Run Percentage, RP)	13. Koşu Uzunluğu Varyansı (Run-Length Variance, RLV)
6. Düşük Gri-Seviye Koşu Vurgusu (Low Gray-Level Run Emphasis , LGRE)	14. Normalize Gri Seviye Düzensizliği (Gray Level Non Uniformity Normalized)
7. Yüksek Gri-Seviye Koşu Vurgusu (High Gray-Level Run Emphasis, HGRE)	15. Koşu Entropisi (Run Entropy)
8. Kısa Koşu Düşük Gri-Seviye Koşu Vurgusu (Short Run Low Gray-Level Run Emphasis, SRLGE)	16. Normalize Koşu Uzunluğu Düzensizliği (Run Length Non-Uniformity Normalized)

Gri seviye büyüklük alan matrisi

P, izotropik vksel boyutlu $V(x,y,z)$ ’nin gri seviye büyüklük alan matrisi (Gray-Level Size Zone Matrix - GLSZM) olarak tanımlanır. $P(i,j)$, V ’deki i gri seviyeli j büyüklüklü 3 boyutlu alanların sayısını gösterir. N_g gri seviye setinin büyüklüğünü ifade etmektedir. L_z en büyük alanın büyüklüğünü gösterir. Her bir V hacmi için, bütün en büyük alanların büyüklüğü eş zamanlı toplanarak sadece bir tane $N_g \cdot L$ büyüklüğünde GLSZM hesaplanır. Bu alanlar, üç boyutlu uzaydaki aynı gri seviyeli 26 bağlantılı komşunun birleşiminden oluşur [96].

Normalize edilmiş GLSZM’nin girişi (i,j) Eş. 3.4.a’daki gibi tanımlanır.

$$p(i, j) = \frac{P(i, j)}{\sum_{i=1}^{N_g} \sum_{j=1}^{L_z} P(i, j)} \quad (3.4.a)$$

$$\mu_i = \sum_{i=1}^{N_g} i \sum_{j=1}^{L_z} p(i, j) \quad (3.4.b)$$

$$\mu_j = \sum_{j=1}^{L_z} j \sum_{i=1}^{N_g} p(i, j) \quad (3.4.c)$$

Doku				$\Rightarrow$	Gri seviye					
					Büyüklik Alan (j)					
				1 2 3 4 5						
1	1	3	4	1	0	1	1	0	0	
1	3	4	4	2	0	1	0	0	0	
3	2	4	4	3	0	0	0	1	0	
3	2	1	1	4	0	0	0	0	1	
(a)				(b)						

Şekil 3.8. (a) Örnek bir doku matrisi ve (b) bu dokuya ait gri seviye büyüklük alan matrisi

Şekil 3.8.a'da örnek bir dokuya ait gri seviye büyüklük alan matrisi çıkarılmıştır. Örnek olarak $i=1$ gri seviyeli 2 ve 3 büyüklüklü birer tane alan bulunmaktadır. $i=4$ gri seviyeli 5 büyüklüklü bir alan bulunmaktadır. Bunlar matriste belirtilmiştir.

Çizelge 3.5. Çalışmamızdaki görüntülerden çıkarılan GLSZM özellikleri

1. Küçük Alan Vurgusu (Small Zone Emphasis, SZE)	9. Küçük Alan Yüksek Gri-Seviye Vurgusu (Small Zone High Gray-Level Emphasis, SZHGE)
2. Büyük Alan Vurgusu (Large Zone Emphasis, LZE)	10. Büyük Alan Düşük Gri-Seviye Vurgusu (Large Zone Low Gray-Level Emphasis, LZLGE)
3. Gri-Seviye Değişebilirliği (Gray-Level Nonuniformity, GLN)	11. Büyük Alan Yüksek Gri-Seviye Vurgusu (Large Zone High Gray-Level Emphasis, LZHGE)
4. Alan-Büyüklik Değişebilirliği (Zone-Size Nonuniformity, ZSN)	12. Gri-Seviye Varyansı (Gray-Level Variance, GLV)
5. Alan Yüzdesi (Zone Percentage, ZP)	13. Alan-Büyüklik Varyansı (Zone-Size Variance, ZSV)
6. Düşük Gri-Seviye Alan Vurgusu (Low Gray-Level Zone Emphasis, LGZE)	14. Normalize Gri Seviye Düzensizliği (Gri Seviye Gray Level Non Uniformity Normalized, GLNN)
7. Yüksek Gri-Seviye Alan Vurgusu (High Gray-Level Zone Emphasis, HGZE)	15. Normalize Büyüklük Alan Düzensizliği (Size Zone Non-Uniformity Normalized)
8. Küçük Alan Düşük Gri-Seviye Vurgusu (Small Zone Low Gray-Level Emphasis, SZLGE)	16. Alan Entropisi (Zone Entropy)

Komşuluk gri ton fark matrisi

Komşuluk gri ton fark matrisinin (Neighbouring Gray Tone Difference Matrix - NGTDM) amacı her bir görüntü pikselinin gri seviye değerlerinin ve komşuluklarının gri seviye değerlerinin ortalaması arasındaki farkı ölçmektir. NGTDM'nin j 'inci elemanı, j gri seviyeli pikseller ile l satır c sütunlu d uzaklığı ile verilen görüntüdeki komşu piksellerin gri seviye değerlerinin ortalaması ile arasındaki farkı göstermektedir. Bu ölçümler bir d uzaklığında görüntünün kenarındaki pikseller için hesaplanmamaktadır. Başka bir ifadeyle, l satır c sütunlu matristeki her bir NGTDM elemanı, (i,j) pozisyonlarında pikseller için $d < i < l$ ve $d < j < c - d$ şartlarının sağlanırken hesaplanır.

3	2	0	1	0
1	2	1	3	0
3	3	0	2	3
1	2	3	0	3
0	0	0	0	1

(a)

j	$S(j)$
0	3,5
1	0,625
2	1,5
3	5,625

(b)

Şekil 3.9. (a) Örnek bir doku matrisi ve (b) bu dokuya ait komşuluk gri ton fark matrisi

Şekil 2.20.a'da 5x5'lik örnek bir doku matrisi verilmiştir. Şekil 3.9.b'de $d=1$ için, j gri seviyesi, j gri seviyeleri ve onun etrafının ortalaması arasındaki farkların toplamı $S(j)$ olduğu durumda oluşturulan komşuluk gri ton fark matrisi gösterilmektedir.

Şekil 3.9.a'da ki matrisin (3,3) ve (4,4) elmanı olan 0 için hesaplama Eş. 3.5'teki gibi yapılmıştır.

$$S(0) = \left| 0 - \frac{2+1+3+3+2+2+3+0}{8} \right| + \left| 0 - \frac{0+2+3+3+3+0+0+1}{8} \right| = 3,5 \quad (3.5)$$

NGTDM için çalışmamızda 5 farklı özellik çıkarılmıştır. Bunlar; kabalık (coariness), kontrast (contrast), meşguliyet (busyness), karmaşıklık (complexity) ve güç (strength)'tür.

Gri seviye bağımlılık matrisi

Çalışmamızda gri seviye bağımlılık matrisi'ne (Gray Level Dependence Matrix - GLDM) ait toplan 14 farklı özellik çıkarılmıştır. Bu özellikler Çizelge 3.6'da verilmiştir.

Çizelge 3.6. Çalışmamızdaki görüntülerden çıkarılan GLDM özellikleri

1. Bağıllık Entropisi (Dependence Entropy, DE)	8. Büyük Bağıllık Vurgusu (Large Dependence Emphasis, LDE)
2. Bağıllık Düzensizliği (Dependence Non- Uniformity, DN)	9. Büyük Bağıllık Yüksek Gri Seviye Vurgusu (Large Dependence High Gray Level Emphasis, LDHGLE)
3. Normalize Bağıllık Düzensizliği (Dependence Non-Uniformity Normalized, DNN)	10. Büyük Bağıllık Düşük Gri Seviye Vurgusu (Large Dependence Low Gray Level Emphasis, LDLGLE)
4. Bağıllık Varyansı (Dependence Variance, DV)	11. Düşük Gri Seviye Vurgusu (Low Gray Level Emphasis, LGLE)
5. Gri Seviye Düzensizliği (Gray Level Non-Uniformity, GLN)	12. Küçük Bağıllık Vurgusu (Small Dependence Emphasis, SDE)
6. Gri Seviye Varyansı (Gray Level Variance, GLV)	13. Küçük Bağıllık Yüksek Gri Seviye Vurgusu (Small Dependence High Gray Level Emphasis, SDHGLE)
7. Yüksek Gri Seviye Vurgusu (High Gray Level Emphasis, HGLE)	14. Küçük Bağıllık Düşük Gri Seviye Vurgusu (Small Dependence Low Gray Level Emphasis, SDLGLE)

Şekil tabanlı özellikler

Bu özellikler görüntüden herhangi bir matris oluşturmada doğrudan seçilen ilgi bölgesine ait şekilsel karakterlere bakılarak oluşturulur. Çalışmamızda şekil tabanlı toplam 17 adet özellik çıkarılmıştır. Bu özellikler Çizelge 3.7’de verilmiştir.

Çizelge 3.7. Çalışmamızdaki görüntülerden çıkarılan şekil tabanlı özellikler

1. Ağ hacmi (Mesh volume)	10. Maksimum 2D Çap Kesiti (Maximum 2D Diameter Slice)
2. Voksel Hacmi (Voxel Volume)	11. Maksimum 2D Çap Sütunu (Maximum 2D Diameter Column)
3. Yüzey Alanı (Surface Area)	12. Maksimum 2D Çap Satırı (Maximum 2D Diameter Row)
4. Yüzey Hacim Oranı (Surface Volume Ratio)	13. Büyük Eksen (Major Axis)
5. Küresellik (Sphericity)	14. Küçük Eksen (Minor Axis)
6. Sıklık 1 (Compactness 1)	15. En Küçük Eksen (Least Axis)
7. Sıklık 2 (Compactness 2)	16. Uzama (Elongation)
8. Küresel Oransızlık (Spherical Disproportion)	17. Düzlük (Flatness)
9. Maksimum 3D Çapı (Maximum 3D Diameter)	

3.1.4. Özellik seçimi

Özellik seçimindeki amaç, veri setini temsil edebilecek en iyi özelliklerden oluşan bir alt kümenin belirlenmesidir. Özellik seçimi sonucunda, daha az sayıda ve temsil gücü yüksek özellikler elde edileceği için sınıflandırıcının hızı ve doğruluk oranı artar. Özellik seçiminde yapılan çalışmalar sarıcı (wrapper) ve filtre (filter) modeller üzerinde yoğunlaşmıştır [97]. Filtre modelinde özellikler her hangi bir sınıflandırıcı algoritması olmadan daha önceden belirlenmiş bazı kriterlere göre değerlendirilirken, sarıcı modelde özelliklerin değerlendirilmesinde bir sınıflandırıcı algoritmasından faydalanılır. Özelliklerin değerlendirilmesinde bizim çalışmamızda daha iyi sonuçlar verdiği için sarıcı model tercih edilmiştir.

Özellik seçiminin yapılabilmesi için birçok metot vardır. Sıralı ileri seçmede (Sequential Forward Selection, SFS), $A = \{a_1, a_2, \dots, a_n\}$ özellik kümesi ve $F(B)$ sonuç fonksiyonu olarak belirlenirse, B_0 boş kümesiyle seçme işlemi başlatılır. X kümesi içinden sonuç fonksiyonundaki en başarılı a_i özelliği belirlenerek B_1 kümesi oluşturulur. Daha sonra elde edilen bu kümeye $a \notin B_j$ (j seçilen özellik sayısı) olacak şekilde özelliklerin teker teker eklenmesiyle elde edilen ikili kümelerden başarı oranı en iyi olan ikili küme seçilir ve B_2 kümesi elde edilir. Bu şekilde işlem tekrarlanarak istenen B_N kümesi oluşturulur [98]. SFS yönteminde optimum kümede bulunan özellikler sonraki adımlarda kümeden çıkarılamaz. Bunun aksine, SFS'nin daha gelişmiş bir formatı olan sıralı ileri hareketli seçme (Sequential Forward Floating Selection, SFFS) yöntemi her aşamada özellikleri karşılaştırarak temsil gücü en yüksek olanların kümede kalmasına, düşük olanların kümeden çıkarılmasına izin verir. Örnek olarak a_1, a_2, a_3, a_4 ve a_5 özelliklerinden en iyi üç özellik seçilmek istenirse birinci işlemde a_1 özelliğinin en başarılı, ikinci işlemde a_1 ve a_3 en iyi, üçüncü işlemde a_1, a_3 ve a_4 özelliklerin en iyi özellik kümesini oluşturduğu düşünülürse, SFS yöntemi bu şekilde çalışmaya devam eder fakat SFFS yöntemi ise a_1 özelliğini çıkararak $\{a_3, a_4\}$, a_3 özelliğini çıkararak $\{a_1, a_4\}$ alt kümelerini bulur ve bu kümelerin başarısı $\{a_1, a_3\}$ kümesiyle karşılaştırıldığında daha yüksek ise $\{a_4, a_x\}$ kümesi ile yoksa $\{a_1, a_3\}$ kümesiyle işleme devam edilir. Bu yüzden SFS ve SFFS karşılaştırılacak olursa, SFFS veri setini daha iyi temsil eden bir alt küme çıkarılmasına imkan sağlar. Bununla birlikte, ne SFS ne de SFFS global optimumun bulunmasını garanti etmez [99]. Diğer bir yöntem olan, kapsamlı arama yönteminde (Exhaustive Search, ES) M adet

özellikten N adet özellik çıkartılır. Bu durumda $\binom{M}{N}$ kombinasyonu kadar alt küme değerlendirileceği için, ES çok zaman alan bir özellik seçim yöntemidir. Örneğin 42 özellikten 5 özellikli bir alt küme oluşturulmak istendiğinde 850668 adet alt küme değerlendirmesinin yapılması gerekir. Genetik algoritmalar da (GA) değişkenler kullanılarak bir fonksiyon oluşturulur ve bu fonksiyon sayesinde en iyi özellik alt kümesi çıkarılır [100]. GA mekanizmasına göre giriş özelliklerinin bütün seti bir bit dizisi kromozom (c) gibi kodlanmıştır [101]. Bu dizinin denklemleri Eş. 3.6'da verilmiştir.

$$c = (g_1, g_2, \dots, g_{N_F})$$

eğer i özelliği dahilse

eğer i özelliği dahil değilse

(3.6)

N_F , veri kümesindeki toplam özellik sayısıdır. Genetik algoritmalar, çok farklı alanlarda çeşitli amaçlar için kullanılmaktadır.

3.1.5. Sınıflandırma

Sınıflandırma algoritmaları genellikle gözetimli ve gözetimsiz olarak iki ana başlık altında toplanır. Aralarındaki fark, gözetimli sınıflandırmada sınıflandırılacak özelliklerin sınıfları önceden belliyken, gözetimsiz sınıflandırmada sınıfların belli olmamasıdır yani gözetimsiz sınıflandırmada girişlerin sınıfları etiketlenmemiştir [102]. Tezimizde kullanılan görüntülerin sınıfları meme atenüasyonu ve kanlanma azlığı şeklinde daha önceden etiketlendiği için, gözetimli sınıflandırma yöntemleri kullanılmıştır. Gözetimli sınıflandırma yöntemlerinden en önemlileri; mantık temelli algoritmalar, algılayıcı temelli teknikler, istatistiksel öğrenme algoritmaları ve destek vektör makineleridir [103].

Algılayıcı (perceptron) kavramı odaklı algoritmalarda, algılayıcı şu şekilde tanımlanabilir; eğer x_n boyunca x_1 giriş değerleri ve w_n boyunca w_1 ağırlık/ tahmin vektörü ise algılayıcı ağırlıklandırılmış girişlerin toplamını $\sum_i x_i w_i$ ile hesaplar ve çıkış ayarlanabilir bir eşik boyunca ilerler. Bunun sonucunda eğer toplamı eşikğin üstündeyse çıkış 1 yoksa 0'dır. Bu algoritmalarından en popüler olanı yapay sinir ağlarıdır (YSA). Algılayıcılar, örneklerin lineer olarak ayrılabilir olmaması durumunda sınıflandırma işlemini düzgün bir şekilde yapamazken YSA bu problemin üstesinden gelmek için üretilmiştir [104].

Bir diğer sınıflandırma yöntemi ise istatistiksel öğrenme temelli algoritmalarıdır. İstatistiksel yaklaşımlar, basit olarak bir sınıflandırmadan ziyade bir sınıfa ait olan bir örneğin olasılığını sağlayan belirli bir olasılık modeliyle karakterize edilmiştir. Bu algoritmalarından Naive Bayes (NB) ve k-en yakın komşuluk(k-Nearest Neighbour - k-NN) yöntemi bu çalışmada uygulanmıştır. NB, olasılık temelli bir sınıflandırıcıdır. Eğitim için verilen örneklerin sınıflarıyla ilgili olasılık işlemleri üzerinden sınıfı bilinmeyen örneğin hangi sınıfa ait olduğu tahmin edilir. NB sınıflandırıcının veri setiyle uyumlu olması durumunda çok yüksek başarı oranı verdiği çalışmalar vardır [105]. Bu algoritmalarından en öne çıkan ve en sık kullanılanlarından biri k-NN sınıflandırıcısıdır. Bu sınıflandırıcı, bir veri kümesindeki örneklerin yakın komşusuna göre genelde benzer özelliklere sahip olması prensibine dayanır. k-NN sınıflandırıcı eğitim aşamasında YSA ve NB'den daha az hesaplama zamanına ihtiyaç duyarken, sınıflandırma aşamasında daha fazla hesaplama zamanına ihtiyaç duyar. k 'nin seçimi k-NN algoritmasının başarısını etkiler [102]. Bu çalışmada k komşu sayısı olarak 1, 3 ve 5 değerleri kullanılmıştır. Tek değerler kullanılmasının sebebi farklı sınıfların eşit komşulukta çıkmasının önüne geçmektir.

Ayrıca örneklerin komşusuna olan uzaklığı farklı parametreler üzerinden değerlendirilir. Bu çalışmada parametre olarak öklit ve çebişev uzaklıkları kullanılmıştır. Öklit uzaklığı iki nokta arasındaki uzaklığı bulan bir ölçümdür. Kartezyen koordinatlarında, x ve y noktaları öklit k uzayında iki nokta ise, x'ten y'ye veya y'den x'e d uzaklığı Pisagor teoremiyle tanımlanır. Formülasyonu Eş. 3.7'de verilmiştir.


$$d(x, y) = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (3.7)$$

Çebişev uzaklığı, (x,y) iki vektör veya noktaları arasındaki bütün koordinatlar boyunca farklarının en büyüğü olan uzaklığı bulmak için kullanılan bir ölçümdür ve Eş. 3.8'deki gibi tanımlanır.

$$d(x, y) = \lim_{p \rightarrow \infty} \left(\sum_{i=1}^k |x_i - y_i|^p \right)^{1/p} \quad (3.8)$$

Şekil 3.10'da k=3 komşulukla örneğin hangi sınıfa ait olduğunun belirlenmesi gösterilmiştir. Şekil 3.10'da da görüldüğü gibi örnek en yakın üç komşuluğundan ikisi sınıf

1'e ait olduğundan bu örnek birinci sınıfa aittir şeklinde yorumlanabilir. k-NN sınıflandırıcı, bir çok alanda kullanılan, başarı oranı yüksek çalışmaların olduğu bir sınıflandırıcıdır.




Şekil 3.10. $k=3$ komşulukla örneğin sınıfının belirlenmesi

3.1.6. Sınıflandırma performansının değerlendirilmesi

Sınıflandırma performansının değerlendirilmesi, sınıflandırıcının bizim örneklerimizle nasıl sonuç verdiğinin görülmesi açısından en önemli adımlardan biridir. Bu performansın değerlendirilebilmesi için sınıflandırıcı doğruluğunun hesaplanması gerekir ve bu işlem yeterli veri kümesinin olması durumunda, veri kümesinin belli oranlarda eğitim ve test kümesi olarak bölünmesiyle gerçekleştirilir. Bu anlamda en sık kullanılan tekniklerden biride n -kat çapraz doğrulama yöntemidir. Bu metotta veri setindeki örnekler yaklaşık olarak eşit bir şekilde k parçaya bölünür, oluşan $k-1$ adet alt küme eğitim için 1 adet küme ise test için kullanılır ve bu işlem k kere tekrarlanır ve ortalama doğruluk oranı hesaplanır. Bu süreç Şekil 3.11.'de gösterilmiştir. k 'nin belirlenmesi için kesin bir kural yoktur fakat çalışmalarda genellikle 10 kabul görmüş bir değerdir [92]. Bu sebeple tezimizde

sınıflandırma performansının değerlendirilmesi için 10-kat çapraz doğrulama yöntemi kullanılmıştır.



Şekil 3.11. k-kat çapraz doğrulama yönteminin uygulanması

Sınıflandırıcının yorumlanması aşamasında Alıcı İşletim Karakteristiği (Receiver Operating Characteristic - ROC) eğrisi, hata matrisi ve buna bağlı bazı kavramlardan da yararlanılmıştır. Çizelge 3.8’de ROC eğrisinin oluşturulması için gereken kavramlar, hata matrisi üzerinde açıklanmıştır.

Çizelge 3.8. Hata matrisi

		TAHMİN	
		Pozitif	Negatif
GERÇEK	Pozitif	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Negatif	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Çizelge 3.8’de verilen hata matrisinde pozitif, meme atenuasyonu olan sınıfı temsil ederken, negatif Mİ olan sınıfı temsil etmektedir. Doğru pozitif (DP), gerçekte atenuasyon olup sınıflandırıcının doğru tahmin ettiği, yanlış negatif (YN), gerçekte atenuasyon olmasına rağmen sınıflandırıcının yanlış tahmin ettiği, yanlış pozitif (YP), gerçekte MI olmasına rağmen sınıflandırıcının atenuasyon olarak tahmin ettiği ve doğru negatif (DN), gerçekte MI olup sınıflandırıcının doğru tahmin ettiği durumdur. Bu matrisle ilgili önemli dört parametre daha vardır. Bunlar; doğruluk (accuracy), hassasiyet (sensitivity), seçicilik (selectivity ya da specificity) ve geri çağırma (recall)’dır. Doğruluk, sınıflandırıcının doğruluk oranını vermektedir ve $(DP+DN)/(DP+YP+YN+DN)$ oranıyla bulunmaktadır, hassasiyet, bizim matrisimizde gerçekte atenuasyon olanlardan testin pozitif verme durumudur ve bu oran $DP/(DP+YN)$ oranına eşittir. Seçicilik ise MI olanlar arasında testin negatif verme durumudur ve $DN/(DN+YP)$ oranına eşittir. Kesinlik (precision), atenuasyon var denilen durumların başarısını gösterir ve $DP/(DP+YP)$ ile formüle edilebilir. Geri çağırma (recall) sadece gerçekte atenuasyonun olduğu durumlardaki doğru tahmin oranıdır ve $DP/(DP+YN)$ oranına eşittir. F-skoru ise kesinlik ve geri çağırmanın harmonik ortalamasıdır. Tüm bu parametrelerin formülasyonları Çizelge 3.9’da verilmiştir. [102].

Çizelge 3.9. Hata matrisinden elde edilen performans değerlendirme kriterlerinin formülasyonları

Parametre	Formül
Doğruluk	$\frac{DP + DN}{DP + YP + YN + DN}$
Hassasiyet	$\frac{DP}{DP + YN}$
Seçicilik	$\frac{DN}{DN + YP}$
Kesinlik	$\frac{DP}{DP + YP}$
Geri çağırma	$\frac{DP}{DP + YN}$
F – skoru	$F = 2 \times \frac{\text{Kesinlik} \times \text{Geri Çağırma}}{\text{Kesinlik} + \text{Geri Çağırma}}$

WEKA yazılımı

Bu yazılım bir makine öğrenmesi yazılımı olarak geliştirilmiştir. Çok sayıda öğrenme algoritması ve özellik seçme metotlarını barındırmaktadır. WEKA, verilerin istenilen

formatta girilmesi halinde çok sayıda sınıflandırma, özellik seçme ve sınıflandırma performans değerlendirme yöntemlerinin uygulanmasına imkân sağlar [106]. Bu yöntemler farklı parametrelerle bir çok kombinasyon oluşturduğu için WEKA yazılımından tez çalışmamızda sıklıkla faydalanılmıştır.





4. SONUÇ VE ÖNERİLER

Tezimizin bu bölümde, daha önceki kısımlarda detaylı olarak incelenen yöntemler kullanılarak farklı modeller oluşturulmuştur. Oluşturulan bütün bu modellerdeki amaç daha yüksek doğruluk oranları elde etmektir. Her model sonrası yöntemler geliştirilerek ya da değiştirilerek daha yüksek başarı oranları elde edilmesi hedeflenmiştir. Sırasıyla verilen modeller bir önceki modele göre daha iyi sonuçlar içermektedir. Bu anlamda toplam 5 model oluşturulmuştur. Bu 5 modelden bağımsız olarak vücut kitle indeksi (Body Mass Index, BMI) bilgisi sağlanan hastalara ait görüntüler kullanılarak yeni bir veri kümesi oluşturulmuştur. Bu veri kümesi belirli BMI aralıklarına göre üç gruba ayrılmış, üç farklı veri kümesi üretilmiştir ve bu veri kümeleri üzerinden BMI odaklı bir model yapılmıştır.

4.1. Birinci Modelin Sonuçları

k-NN Sınıflandırıcısı ile elde edilen sonuçlar

Farklı uzaklık parametreleri, özellik seçim yöntemleri ve komşu sayıları kullanılarak k-NN sınıflandırıcısı ile çeşitli kombinasyonlar denenmiştir. Bu kombinasyonlar arasında en iyi sonuç, SFFS özellik seçim yöntemiyle belirlenen üç özelliğin çebişev uzaklık parametre ve $k=1$ komşu ile sınıflandırılması sonucu bulunmuştur. En iyi sınıflandırıcının doğruluk oranı 10-kat çapraz doğrulama metoduyla %81,4815 olarak elde edilmiştir. Elde edilen bütün sonuçlar Çizelge 4.1’de verilmiştir.


Çizelge 4.1. k-NN sınıflandırıcı ile farklı parametrelerle elde edilen sonuçlar

Komşuluk Sayısı	Uzaklık Metriği	Özellik Seçimi Yöntemi	Seçilen Özellikler (Sıraları)	Doğruluk Oranı (%)
1	Çebişev	SFS	6-21	76,54
1	Çebişev	SFFS	15-21-33	81,48
1	Öklit	SFS	6-21	76,54
1	Öklit	SFFS	6-21	76,54
3	Çebişev	SFS	15-19-21-23-28-30-41	77,78
3	Çebişev	SFFS	15-19-21-23-28-30-41	77,78
3	Öklit	SFS	6-15-21-32	79,01
3	Öklit	SFFS	6-15-21-32	79,01
5	Çebişev	SFS	6-17-19	70,37
5	Çebişev	SFFS	6-17-19	70,37
5	Öklit	SFS	4-6-19-20-21-28	74,07
5	Öklit	SFFS	4-15-19-21	71,60

Toplam 42 özellik arasından SFFS ile seçilen özellikler: Gri Seviye Koşu Uzunluğu Matrisi (GLRLM) ile üretilmiş olan Yüksek Gri-Seviye Koşu Vurgusu (High Gray-Level Run Emphasis - HGRE)), Koşu Uzunluğu Varyansı (Run-Length Variance - RLV) ve Gri Seviye Alan Büyüklüğü Matrisi (GLSZM) ile oluşturulmuş olan Gri-Seviye Varyansı (Gray-Level Variance - GLV)'dir. Bu özelliklerin eldeki görüntüler için neden ayırt edici olduğunu anlayabilmek için, bu özelliklerin ilk olarak türetildikleri makaleler [95, 107] detaylı olarak incelenmiştir. Bu iki makalede kullanılan görüntüler bu çalışmada kullanılan görüntülerle benzerlik göstermektedir. Kullanılan görüntülerde de küçük bölgeler kendi içinde homojen bir yapıya sahipken, tüm görüntüyü oluşturan diğer küçük bölgelerle birleştiğinde heterojen bir yapı meydana getirmektedir. Bundan dolayı bu özellikler bu çalışmada kullanılan görüntüler için de ayırt edicidir denilebilir. Özellikle GLRLM ve GLSZM'deki bazı özellikler bu çalışma için diğer özelliklere göre daha ayırt edicidir. RLV ve GLV ilk defa biyomedikal tabanlı bir çalışmada türetilmiş ve başarılı sonuçlar elde edilmiştir [95]. Bu modelde, özellik seçimi yöntemlerinden çıkarılan en ayırt edici 3 özellikten ikisi bu özelliklerdir. Bu özelliklerle birlikte, GLRLM'deki HGRE özelliği de yine diğer referans makalede yeni türetilmiş bir özellik olup bu çalışmadaki görüntüler için de ayırt edici bulunmuştur.

Şekil 4.1'teki ROC eğrisine ait AUC 0,813'tür. Bu büyüklük akademik puanlama sistemine göre iyi bir performans değeridir. Yine önerilen modele ait daha önce bahsedilen diğer parametreler ve hata matrisi sırasıyla Çizelge 4.2 ve Çizelge 4.3'te verilmiştir.

Çizelge 4.2’de verilen hata matrisine göre, meme atenuasyonu olan 51 hastadan 45’si doğru tahmin edilirken 6’sında yanlış tahmin yapılmıştır. MI olan 30 hastadan 21’i doğru tahmin edilirken 9 tanesinde yanlış tahmin yapılmıştır.



Şekil 4.1. %81,48 doğruluk için k-NN ile elde edilen ROC eğrisi (AUC=0,813)

Çizelge 4.2. %81,48 doğruluk için k-NN ile elde edilen hata matrisi

		TAHMİN	
		Pozitif	Negatif
GERÇEK	Pozitif	45 (DP)	6 (YN)
	Negatif	9 (YP)	21 (DN)


Çizelge 4.3. %81,4815 doğruluk için k-NN ile elde edilen performans değerlendirme kriterleri

Sınıf	DP Oranı	YP Oranı	Hassasiyet	Seçicilik	Kesinlik	Geri Çağırma	F-skor	AUC
1	0,882	0,267	0,882	0,734	0,849	0,882	0,865	0,813

Naive Bayes sınıflandırıcısı ile elde edilen sonuçlar

Bu bölümde Naive Bayes Sınıflandırıcısı ile elde edilen sonuçlara yer verilmiştir. Şekil 4.2, Çizelge 4.4 ve Çizelge 4.5’te sırasıyla ROC eğrisi, sınıflandırıcıya ait parametre

sonuçları ve hata matrisi verilmiştir. SFS ve SFFS özellik seçim yöntemlerinin her ikisinde de en ayırt edici özellikler 5., 21., 25. ve 35. özellikler olarak belirlenmiştir. Bu özellikler Tablo 2’den de görüleceği gibi sırasıyla GLCM, GLRLM, GLSZM ve NGTDM matrislerine ait varyans, koşu uzunluğu varyansı, alan büyüklük değişebilirliği ve kabalık özellikleridir. Bu özellikler kullanılarak Naive Bayes sınıflandırıcı ile yapılan sınıflandırma sonucu doğruluk oranı %70,7317 olarak bulunmuştur.



Şekil 4.2. Naive Bayes sınıflandırıcısı ile elde edilen ROC eğrisi

ROC eğrisi altındaki alan (AUC) ise 0,673 olarak bulunmuştur. Bu oran akademik puanlama sistemine göre zayıf bir performanstır.

Çizelge 4.4. Naive Bayes sınıflandırıcısı ile elde edilen performans değerlendirme kriterleri

Sınıf	DP Oranı	YP Oranı	Hassasiyet	Seçicilik	Kesinlik	Geri Çağırma	F-skor	AUC
1	0,827	0,500	0,827	0,500	0,741	0,827	0,782	0,673

Çizelge 4.5. Naive Bayes sınıflandırıcısı ile elde edilen hata matrisi

		TAHMİN	
		Pozitif	Negatif
GERÇEK	Pozitif	43 (DP)	9 (YN)
	Negatif	15 (YP)	15 (DN)

Çizelge 4.5’te verilen hata matrisine göre, meme atenüasyonu olan 52 hastadan 43’ü doğru tahmin edilirken 9’unda yanlış tahmin yapılmıştır, Mİ olan 30 hastadan 15’i doğru tahmin edilirken 15 tanesinde yanlış tahmin yapılmıştır.

Genel olarak, Naive Bayes Sınıflandırıcısı ile elde edilen sonuçlar çok tatmin edici değildir. Çizelge 4.4’teki kriterlere bakacak olursak özellikle seçicilik değeri yani yanlış pozitiflerin gerçekteki bütün negatiflere oranı çok yüksektir.

Yapay sinir ağları ile elde edilen sonuçlar


Bu bölümde ise çalışmamızda Yapay sinir ağları (YSA) ile elde edilen sonuçlara yer verilmiştir. SFS ve SFFS ile seçilen bu YSA sınıflandırıcısı için temsil gücü en yüksek özellikler 7., 16., 21., 29. ve 42. özelliklerdir. Bu özellikler sırasıyla GLCM’ye ait entropi, GLRLM’ye ait kısa koşu düşük gri-seviye koşu vurgusu ve koşu uzunluğu varyansı, GLSZM’ye ait küçük alan düşük gri-seviye vurgusu ve global özelliklerden basıklıktır.

En yüksek doğruluk oranı tek gizli katmanlı iki sinir sayılı 500 epoklu 0,2 momentum ve 0,4 öğrenme oranları kullanılarak elde edilmiştir. Farklı parametre değerleri ile elde edilen doğruluk oranları Çizelge 4.6’da verilmiştir.

Çizelge 4.6. Yapay sinir ağları ile farklı parametrelerle elde edilen sonuçlar

Öğrenme Oranı	Momentum	Gizli Katman	Sinir Sayısı	Epok	Doğruluk Oranı (%)
0,1	0,2	1	3	500	70,73
0,3	0,2	1	3	500	71,95
0,4	0,2	1	3	500	75,61
0,5	0,2	1	3	500	73,17
0,7	0,2	1	3	500	71,95
0,9	0,2	1	3	500	70,73
0,1	0,4	1	3	500	68,29
0,3	0,4	1	3	500	74,39
0,5	0,4	1	3	500	69,51
0,7	0,4	1	3	500	70,73
0,9	0,4	1	3	500	65,85
0,1	0,6	1	3	500	69,51
0,3	0,6	1	3	500	74,39
0,5	0,6	1	3	500	68,29
0,7	0,6	1	3	500	67,07
0,9	0,6	1	3	500	65,85
0,1	0,8	1	3	500	75,61
0,3	0,8	1	3	500	65,85
0,5	0,8	1	3	500	69,51
0,7	0,8	1	3	500	67,07
0,9	0,8	1	3	500	68,29
0,4	0,2	1	2	500	76,83
0,4	0,2	1	4	500	69,51
0,1	0,8	1	2	500	75,61
0,1	0,8	1	4	500	71,95
0,4	0,2	2	2-2	500	65,85
0,4	0,2	3	2-2-2	500	63,41
0,1	0,8	2	2-2	500	64,63
0,1	0,8	3	2-2-2	500	63,41

Şekil 4.3'te ROC eğrisi gösterilmektedir, bu eğri altında kalan alan 0,714'tür. Bu değer makul değerli bir performanstır.



Şekil 4.3. YSA ile elde edilen ROC eğrisi (AUC=0,714)

Çizelge 4.7. Yapay Sinir Ağları ile elde edilen performans değerlendirme kriterleri

Sınıf	DP Oranı	YP Oranı	Hassasiyet	Seçicilik	Kesinlik	Geri Çağırma	F-skor	AUC
1	0,904	0,467	0,904	0,534	0,770	0,904	0,832	0,714

Çizelge 4.7’de YP oranının değeri makul bir seviyede değildir. Ayrıca kesinlik de beklenen seviyenin altındadır. Buna karşın, hassasiyet ve geri çağırma değerleri iyi seviyededir.

Çizelge 4.8’deki hata matrisine bakılacak olursa YSA sınıflandırıcı meme atenuasyonu olan 47 hastayı doğru tahmin ederken, Mİ olan 16 hastayı doğru tahmin edebilmiştir ve sınıflandırma doğruluk oranı %76,83’tür.

Çizelge 4.8. Yapay Sinir Ağları ile elde edilen hata matrisi

		TAHMİN	
		Pozitif	Negatif
GERÇEK	Pozitif	47 (DP)	5 (YN)
	Negatif	14 (YP)	16 (DN)

Sonuç olarak birinci modelin genel değerlendirmesi yapılacak olursa, denenen sınıflandırıcılar arasından veri kümesiyle en verimli çalışan yöntem k-NN'dir. Bu yüzden diğer modellerin oluşturulmasında k-NN sınıflandırıcıların temel alındığı modeller üzerinde çalışılmıştır.

4.2. İkinci Modelin Sonuçları

Bu modelin oluşturulmasında birinci modelden farklı olarak özellik seçimi yöntemi olarak kurt araması (Wolf Search - WS) algoritması kullanılmıştır. Bu yöntemle daha yüksek sınıflandırma başarı oranlarının yükseltilmesi hedeflenmiştir. Aynı zamanda, özellik seçiminden önce özelliklere çeşitli ölçeklemeler yapılmıştır.

Çizelge 4.9. k-NN sınıflandırıcı ve WS özellik seçimi yöntemiyle elde edilen doğruluk oranları

Uzaklık Metriği	Özellik Ölçekleme	Özellik Seçimi Yöntemi	Özellik sayısı	Doğruluk oranı (%)
Öklit	-	WS	14	79,01
Çebişev	-	WS	11	82,72
Öklit	Randomize	WS	21	85,19
Öklit	Normalize	WS	14	79,01
Çebişev	Normalize	WS	11	82,71
Çebişev	Randomize	WS	21	76,54
Manhattenn	Normalize	WS	18	77,78
Manhattenn	Randomize	WS	23	82,72
Minkowski	Normalize	WS	14	79,01
Minkowski	Randomize	WS	21	85,19
Manhattenn	-	WS	18	77,78
Minkowski	-	WS	14	79,01
Çebişev	Kernel	WS	16	67,90
Çebişev	Standardize	WS	11	82,72

Çizelge 4.9'da görüldüğü gibi en yüksek başarı oranı öklit uzaklık metrikli k-NN sınıflandırıcı, WS özellik seçim algoritması ve 10-kat çapraz doğrulama yöntemlerinin beraber uygulanmasıyla elde edilmiştir. Burada uygulanan ölçeklemeler Weka ile gerçekleştirilmiştir.

Çizelge 4.10. %85,19 doğruluk oranı elde edilen yönteme ait hata matrisi

		TAHMİN	
		Pozitif	Negatif
GERÇEK	Pozitif	45 (DP)	6 (YN)
	Negatif	6 (YP)	24 (DN)

Çizelge 4.10’da en yüksek başarı oranına sahip modelin hata matrisi gösterilmiştir. Bu model 51 Mİ hastadan 45’ini, 30 atenuasyon olan hastadan 24’ünü doğru tahmin etmiştir.

Çizelge 4.11. %85,19 doğruluk oranı elde edilen yönteme ait performans değerlendirme kriterleri

Sınıf	DP Oranı	YP Oranı	Hassasiyet	Seçicilik	Kesinlik	Geri Çağırma	F-skör	AUC
1	0,882	0,200	0,882	0,800	0,882	0,882	0,882	0,833

ROC eğirişi altında kalan alan 0,833’tür ki bu değer modelin performansı açısından iyi bir değerdir. Yanlış pozitif oranı da istenilen düşüklükte bir seviyededir. Diğer parametreler de birbirlerine yakın tatmin edici düzeydedirler. Bütün bu parametrelere Çizelge 4.11’te yer verilmiştir.

Veri kümesinden elde edilen özellikler Matlab ile normalize edilmiş ve çeşitli kombinasyonlar oluşturularak başarı oranları incelenmiştir. Bu sonuçlara göre en yüksek doğruluk oranı %80,25 olarak bulunmuştur.

Çizelge 4.12. Matlab ile normalize edilen verilerin sonuçları


Kat Sayısı	Uzaklık Metriği	Özellik Ölçekleme	Özellik Seçimi Yöntemi	Seçilen Özellik Sayısı	Doğruluk oranı (%)
10	Çebişev	-	SFFS	6	75,31
10	Çebişev	-	WS	20	74,07
10	Öklit	Normalize	WS	19	75,31
10	Çebişev	Normalize	WS	20	74,07
10	Çebişev	Standardize	WS	20	74,07
10	Öklit	Standardize	WS	19	75,31
10	Çebişev	Normalize	SFFS	6	79,01
5	Çebişev	Normalize	SFFS	5	80,25
5	Çebişev	Normalize	WS	21	76,54
81	Öklit	Randomize	WS	19	80,25

Modelin k-NN sınıflandırıcı ile daha iyi sonuçlar verdiği daha önce belirtilmişti. YSA ve Naive Bayes sınıflandırıcı denenmiş fakat beklenildiği gibi düşük sonuçlar verdiği için çok fazla parametre çeşitliliğine gerek duyulmamıştır.

Çizelge 4.13. YSA ve Naive Bayes sınıflandırıcı ile elde edilmiş sonuçlar

Sınıflandırıcı	Özellik Ölçekleme	Özellik Seçimi Yöntemi	Seçilen Özellik Sayısı	Doğruluk oranı (%)
YSA	-	WS	1	62,96
YSA	Normalize	WS	1	62,96
Naive Bayes	-	WS	9	67,90
Naive Bayes	Normalize	WS	10	69,14

Çizelge 4.13'te, görüntülere Wiener 3x3 filtresi uygulanmasının ardından elde edilen veri kümesinin k-NN sınıflandırıcıyla farklı parametre ve yöntemlerin birleşimleriyle edilen sonuçlar verilmiştir. Görüldüğü üzere Wiener filtresinin uygulanması ile bulunan başarı oranı, daha önce elde edilen %85,19'luk başarı oranını yakalayamayarak daha düşük seviyede kalmıştır. Çalışmamızda 3x3 matrisli Wiener filtresi kullanımının bu anlamda başarı sağlamadığı görülmüştür.




Şekil 4.4. Filtre işlemleri öncesi bir hastaya ait 32 farklı ham projeksiyon görüntüsü

Farklı filtre işlemlerinin gerçekleştirilmesi için Şekil 4.4'te gösterilen, bir hastaya ait 32 farklı projeksiyonunun görüntüsü kullanılmıştır. Bu bölümde ham görüntüye uygulanan filtreler bu görüntüye uygulanmıştır.

Çizelge 4.14. Görüntülere Wiener 3x3 filtresinin uygulanması sonrası k-NN sınıflandırıcı ve 10-kat çapraz doğrulama kullanılarak elde edilen doğruluk oranları

Uzaklık Metriği	Özellik Ölçekleme	Özellik Seçimi Yöntemi	Seçilen Özellik Sayısı	Doğruluk oranı (%)
Öklit	Randomize	WS	1	70,37
Öklit	Randomize	SFFS	1	70,37
Çebişev	Normalize	WS	9	77,78
Çebişev	Normalize	SFFS	4	72.84
Çebişev	Standardize	WS	9	77,78
Çebişev	Standardize	SFFS	4	72.84
Çebişev	-	SFFS	4	72.84
Öklit	-	SFFS	5	72.84
Manhattenn	-	SFFS	3	72.84
Minkowski	-	SFFS	5	72.84
Çebişev	-	WS	1	72,84
Öklit	-	WS	6	66,67
Manhattenn	-	WS	14	70,37
Minkowski	-	WS	4	69,14




Şekil 4.5. Wiener 3x3 filtresinin ham görüntüye uygulanması sonrası elde edilen görüntü

Çizelge 4.15. Görüntülere Wiener 5x5 filtresinin uygulanması sonrası k-NN sınıflandırıcı ve 10-kat çapraz doğrulama kullanılarak elde edilen doğruluk oranları

Uzaklık Metriği	Özellik Ölçekleme	Özellik Seçimi Yöntemi	Seçilen Özellik Sayısı	Doğruluk Oranı (%)
Öklit	Randomize	WS	6	79,01
Öklit	Randomize	SFFS	6	76,54
Çebişev	Normalize	WS	13	77,78
Çebişev	Normalize	SFFS	4	69,14
Çebişev	Standardize	WS	13	77,78
Çebişev	Standardize	SFFS	4	69,14
Çebişev	-	SFFS	4	69,14
Öklit	-	SFFS	7	70,37
Manhattenn	-	SFFS	4	69,14
Minkowski	-	SFFS	7	70,37
Çebişev	-	WS	13	77,78
Öklit	-	WS	20	77,78
Manhattenn	-	WS	16	75,31
Minkowski	-	WS	20	77,78

Çizelge 4.15'te 5x5 matrisli Wiener filtresi uygulanmıştır. 3x3'lük olana göre oranlarda kısmi bir artış vardır ama yine de filtresiz elde edilen %85,19'luk değerden uzaktır.



Şekil 4.6. Wiener 5x5 filtresinin ham görüntüye uygulanması sonrası elde edilen görüntü

Şekil 4.6’da Wiener 5x5 filtrenin orijinal görüntüye uygulanması gösterilmiştir. Her iki filtrede de başarı oranlarında bir iyileşme görülmemiştir.


Ham görüntüye ayrıca bir nokta yayma fonksiyonlu Wiener bulanıklaştırma ve netleştirme işlemleri uygulanmıştır. Şekil 4.7 ve Şekil 4.8’de sırasıyla 5x45 bir nokta yayma fonksiyonu ile bulanıklaştırma ve netleştirme, aynı şekilde Şekil 4.9 ve 4.10’da da sırasıyla 21x11 bir nokta yayma fonksiyonlu bulanıklaştırma ve netleştirme işlemleri uygulanmıştır. Bu işlemler sonrası görüntülerde görsel olarak iyileşme olsa da bu durum başarı oranlarına yansımamıştır.




Şekil 4.7. Wiener 5x45 bir nokta yayma fonksiyonuyla ile ham görüntünün bulanıklaştırılması



Şekil 4.8. Wiener ile bulanıklaştırılmış görüntünün netleştirilmiş hâli



Şekil 4.9. Wiener 21x11 bir nokta yayma fonksiyonuyla ile ham görüntünün bulanıklaştırılması




Şekil 4.10. Wiener ile bulanıklaştırılmış görüntünün netleştirilmiş hâli

Wiener ile netleştirme işleminden sonra en yüksek başarı oranı %76,83 olarak bulunmuştur. Bu değerin bulunmasında kullanılan parametre ve yöntemler. Çizelge 4.16’da verilmiştir.

Çizelge 4.16. Wiener netleştirme işlemi sırasında en yüksek başarı oranı elde edilmesinde kullanılan yöntemler ve doğruluk oranları

Sınıflandırma Yöntemi	Kat Sayısı	Uzaklık Metriği	Özellik Seçimi Yöntemi	Seçilen Özellik Sayısı	Doğruluk Oranı (%)
k-NN	10	Çebişev	SFFS	2	75,61
k-NN	10	Öklit	SFFS	2	75,61
k-NN	10	Çebişev	WS	15	75,61
k-NN	10	Öklit	WS	18	76,83

Ham görüntüler üzerinde yapılan histogram eşitleme sonrası görüntüler Şekil 4.11’de verilmiştir.




Şekil 4.11. Histogram eşitleme sonrası elde edilen görüntü

Çizelge 4.17. Histogram eşitleme sonrası sınıflandırma için kullanılan yöntemler ve doğruluk oranları

Sınıflandırma Yöntemi	Kat Sayısı	Uzaklık Metriği	Özellik Seçimi Yöntemi	Seçilen Özellik Sayısı	Doğruluk Oranı (%)
k-NN	10	Çebişev	WS	17	79,27
k-NN	10	Öklit	WS	17	74,39
k-NN	10	Öklit	SFFS	2	74,39
k-NN	10	Çebişev	SFFS	5	73,17


Çizelge 4.17’de görüldüğü gibi en yüksek doğruluk oranı % 79,27 olarak bulunmuştur.



Şekil 4.12. Karekök işlemi sonrası elde edilen görüntü

Çizelge 4.18. Karekök sonrası sınıflandırma için kullanılan yöntemler ve doğruluk oranları

Sınıflandırma Yöntemi	Kat Sayısı	Uzaklık Metriği	Özellik Seçimi Yöntemi	Seçilen Özellik Sayısı	Doğruluk Oranı (%)
k-NN	10	Çebişev	SFFS	2	65,85
k-NN	10	Öklit	SFFS	4	69,51
k-NN	10	Çebişev	WS	17	79,27
k-NN	10	Öklit	WS	14	76,83



Şekil 4.13. Küpkök işlemi sonrası elde edilen görüntü

Çizelge 4.19. Küpkök sonrası sınıflandırma için kullanılan yöntemler ve doğruluk oranları

Sınıflandırma Yöntemi	Kat Sayısı	Uzaklık Metriği	Özellik Seçimi Yöntemi	Seçilen Özellik Sayısı	Doğruluk Oranı (%)
k-NN	10	Çebişev	SFFS	3	69,51
k-NN	10	Öklit	SFFS	4	70,73
k-NN	10	Çebişev	WS	13	75,61
k-NN	10	Öklit	WS	14	75,61



Şekil 4.14. (a) Bir hastaya ait 32 farklı projeksiyonlu ham görüntü (b) ham görüntünün kontrastının ayarlanmış hâli



Şekil 4.15. (a) Farklı bir hastaya ait 32 farklı projeksiyonlu ham görüntü (b) ham görüntünün kontrastının ayarlanmış hâli

Çizelge 4.20. Kontrast ayarlama sonrası sınıflandırma için kullanılan yöntemler ve doğruluk oranları

Sınıflandırma Yöntemi	Uzaklık Metriği	Özellik Seçimi Yöntemi	Seçilen Özellik Sayısı	Kat Sayısı	Doğruluk Oranı (%)
k-NN	Çebişev	SFFS	5	10	78,01
k-NN	Öklit	SFFS	3	10	74,39
k-NN	Çebişev	WS	19	10	79,27
k-NN	Öklit	WS	19	10	75,61

Şekil 4.14 ve 4.15’de farklı iki hastaya ait 32 farklı açıdan alınmış ham görüntüler ve bu görüntüler üzerinde kontrast ayarlaması yapılmış hâlleri verilmiştir. Bu işlemler sonrası görüntülerde görsel olarak iyileşme olmuştur. Fakat Çizelge 4.20 incelendiğinde, bu iyileşmenin başarı oranlarına yansımadağı görülmektedir.

Sonuç olarak bu bölümde kullanılan filtreleme işlemleri, çalışmamızda kullanılan görüntüler üzerinde görsel olarak fayda sağlasa da, başarı oranları üzerine olumlu bir etki göstermemektedir.

4.3. Üçüncü Modelin Sonuçları

Bu zamana kadar oluşturulan modellerde toplam 42 temel özellik çıkarılmıştır. üçüncü model itibariyle 42 temel özellik sayısı 109'a yükseltilmiştir. Bunun yanında 109 temel özelliğe çeşitli filtreler uygulanarak toplamda 1969 özellik elde edilmiştir. Burada özellik sayısının artırılmasındaki amaç, temsil gücü yüksek yeni özellikler bulma ihtimalinin artırılmasıdır. Çıkarılan özellikler şu şekildedir:

- Orjinal: Hiçbir filtre uygulanmamıştır. Toplam çıkarılan özellik sayısı 109'dur.
- Wavelet: Wavelet filtreleme her bir seviye için 8 farklı analiz yapar. (Tüm üç boyutlu görüntüler için yüksek ve ya alçak geçiren filtrelerin olası bütün kombinasyonları uygulanır). Toplam çıkarılan özellik sayısı 744'tür.
- LoG: Bu filtreye Marr-Hildreth (Laplacian of Gaussian – LoG) algoritması denir. Gauss filtresine Laplası alınarak işlem yapar. Kenar iyileştirme filtresidir. Gri seviye değişiminin alanını vurgular, sigma vurgulanmış dokunun kabalığını tanımlar, yüksek sigma değeri kaba dokuyu vurgular. (gri seviye büyük uzaklık boyunca değişir.) (sigma: 0.5, 1, 2, 3, 4, 5)). Toplam çıkarılan özellik sayısı 558'dir.
- Kare: Görüntü yoğunluğunun karesini alır ve lineer olarak onları orijinal aralığına ölçekler. Orijinal görüntüdeki negatif değerler filtrenin uygulanmasından sonra tekrar negatif yapılır. Toplam çıkarılan özellik sayısı 93'tür.
- Karekök: Görüntü yoğunluklarının kare kökünü alır ve onları orijinal aralığına yeniden ölçekler. Orijinal görüntüdeki negatif değerler filtrenin uygulanmasından sonra tekrar negatif yapılır. Toplam çıkarılan özellik sayısı 93'tür.
- Logaritma: Yoğunlukların logaritmasını alır. ve onları orijinal aralığına yeniden ölçekler. Orijinal görüntüdeki negatif değerler filtrenin uygulanmasından sonra tekrar negatif yapılır. Toplam çıkarılan özellik sayısı 93'tür.
- Eksponansiyel: Eksponansiyelini alır. Orijinal görüntüdeki negatif değerler filtrenin uygulanmasından sonra tekrar negatif yapılır. Toplam çıkarılan özellik sayısı 93'tür.

- Gradyan: Lokal gradyanın büyüklüğüne geri döner. Toplam çıkarılan özellik sayısı 93'tür.
- Yerel ikili örüntü: Kesit operasyonundaki (2D) yerel ikili örüntüsünü hesaplar. Toplam çıkarılan özellik sayısı 93'tür.

Ayrıca bu zamana kadar denenen k-NN sınıflandırıcısı dışındaki sınıflandırma yöntemleri veri setimizde beklenen düzeyde doğruluk oranı veremediği için bu modelden itibaren kullanılan modellerde k-NN sınıflandırıcısı tercih edilmiştir.

Çizelge 4.21. k-NN sınıflandırıcı ve SFFS özellik seçimi yöntemi kullanılarak elde edilen doğruluk oranları

Uzaklık Metriği	Özellik Ölçekleme	Seçilen Özellik Sayısı	Kat Sayısı	Doğruluk Oranı (%)
Çebişev	-	1	10	77,78
Öklit	-	3	10	82,72
Öklit	-	3	5	83,95
Manhattenn	-	3	10	81,48
Minkowski	-	3	10	82,72
Minkowski	-	3	5	83,95
Minkowski	-	3	81	80,25
Öklit	Normalize	3	10	82,72
Öklit	Standardize	3	10	82,72
Çebişev	Standardize	1	10	77,78
Çebişev	Normalize	1	10	77,78
Çebişev	Normalize	1	6	80,25

Çizelge 4.22. Özelliklerin 0-1 arası normalize edilmesiyle k-NN sınıflandırıcı, WS özellik seçimi yöntemleri kullanılarak elde edilen doğruluk oranları


Uzaklık Metriği	Seçilen Özellik Sayısı	Kat Sayısı	Doğruluk Oranı (%)
Çebişev	841	10	87,65
Öklit	472	10	70,37
Çebişev	841	81	86,42
Manhattenn	690	10	72,84
Minkowski	472	10	70,37

Çizelge 4.23. %87,65 doğruluk oranı elde edilen yönteme ait hata matrisi

		TAHMİN	
		Pozitif	Negatif
GERÇEK	Pozitif	46 (DP)	5 (YN)
	Negatif	5 (YP)	25 (DN)

Çizelge 4.24. %87,65 doğruluk oranı elde edilen yöntemle ait performans değerlendirme kriterleri

Sınıf	DP Oranı	YP Oranı	Hassasiyet	Seçicilik	Kesinlik	Geri Çağırma	F-skor	AUC
1	0,902	0,167	0,902	0,833	0,902	0,902	0,902	0,864



Şekil 4.16. %87,65 doğruluk oranı elde edilen yöntemle ait ROC eğrisi (AUC= 0,864)

4.4. Dördüncü Modelin Sonuçları

İlk üç modelde ilgi bölgelerinin otomatik olarak elde edilmesi sonucunda elde edilen ilgi bölgeleri üzerinden özellikler çıkarılmıştır. Bu modelde ise elle ROI seçilmesi sonucu elde edilen ilgi bölgelerinin özelliklerinin çıkarılması odaklı çalışılmıştır. Bu modelde sınıflandırıcı olarak 1 komşuluklu k-NN yöntemi tercih edilmiştir.

Çizelge 4.25. k-NN sınıflandırıcı, WS özellik seçimi yöntemleri kullanılarak elde edilen doğruluk oranları

Uzaklık Metriği	Özellik Ölçekleme	Özellik Seçimi Yöntemi	Kat Sayısı	Doğruluk oranı (%)
Çebişev	Normalize	WS	10	85,19
Öklit	Normalize	WS	10	76,54
Çebişev	Normalize	SFFS	10	75,31
Öklit	Normalize	SFFS	10	79,01
Çebişev	Normalize	WS	10	87,65
Çebişev	Normalize	WS	5	91,36

Özellik seçim yöntemi olarak Wolf Search algoritması kullanılarak özellikler seçilmiş ve bu özellikler 0-1 arası normalize edilmiştir. En yüksek başarı oranı %91,36 olarak 5-kat çapraz doğrulama yöntemi kullanılarak bulunmuştur. 81 örnekten 74 tanesi doğru tahmin edilmiştir. Bu oran şimdiye kadar bulunan en yüksek başarı oranıdır.

Çizelge 4.26. %91,36 doğruluk oranı elde edilen modele ait hata matrisi

		TAHMİN	
		Pozitif	Negatif
GERÇEK	Pozitif	50 (DP)	1 (YN)
	Negatif	6 (YP)	24 (DN)


Bu model 51 gerçek hastadan 50 tanesini doğru tahmin ederken, 30 atenuasyon olan hastadan 24'ünü doğru bir şekilde tespit etmiştir. Bu modele ait hata matrisi Çizelge 4.26'te verilmiştir.

Performans değerlendirme kriterleri de tatmin edicidir. Şimdiye kadar oluşturulan modeller içerisinde en iyi kriterler bu model aracılığıyla elde edilmiştir. Bu kriter değerleri Çizelge 4.27'te paylaşılmıştır.

Çizelge 4.27. %91,36 başarı oranı elde edilen modele ait performans değerlendirme kriterleri

Sınıf	DP Oranı	YP Oranı	Hassasiyet	Seçicilik	Kesinlik	Geri Çağırma	F-skör	AUC
1	0,980	0,200	0,980	0,800	0,902	0,980	0,935	0,910

Bu kriterler arasından sınıflandırma performansının değerlendirmesin çok büyük bir rol oynayan AUC kriteri de 0,910 olarak bulunmuştu ki bu değer geleneksel akademik puanlama sistemine göre çok iyi olarak değerlendirilir. ROC eğrisi grafiği Şekil 4.17’de gösterilmiştir. Bu grafikte de görüldüğü gibi ROC eğrisi beklenen şekilde doğru pozitif tarafında yükselmektedir.



Şekil 4.17. %91,36 doğruluk oranı elde edilen modele ait ROC eğrisi (AUC= 0,910)

4.5. Beşinci Modelin Sonuçları

Dördüncü modelde toplam 1969 özellik çıkarılmaktadır. beşinci Modelde ise bu özellikler kendi içinde filtre türüne göre bölümlere ayrılarak sadece o bölüme ait özelliklerin kullanıldığı modeller denenmiştir. Burada amaç, dördüncü modelden daha az sayıda özellik kullanarak, beşinci modelde elde edilen sonuçların dördüncü modelle karşılaştırmasının yapılmasıdır. Bu modelde çizelgelerde özellik kümelerinin başında kullanılan ‘N_’ ifadesi o filtre harici elde edilen tüm özellikleri belirtmektedir. Bu modelde sınıflandırma yöntemi olarak 1 komşuluklu k-NN sınıflandırıcısı kullanılmıştır.

Çizelge 4.28’te Orijinal ve Orijinal özelliklerin dışındaki (N_ Orijinal) özellikler ayrı ayrı kullanılarak elde edilen doğruluk oranları verilmiştir. Ayrıca bu doğruluk oranlarının elde edilmesinde kullanılan çapraz doğrulamanın katı ve seçilen özellik sayıları da paylaşılmıştır. Görüldüğü üzere orijinal özellik sayısı 109 iken harici özelliklerin sayısı 1860’tır.

Çizelge 4.28. Filtresiz orijinal özelliklerin ve onun harici diğer tüm özelliklerin kullanılmasına ait sonuçlar

Kullanılan Özellikler	Kullanılan Özelliklerin Sayısı	Özellik Seçimi Yöntemi	Seçilen Özelliklerin Sayısı	Kat Sayısı	Doğruluk Oranı (%)
Orjinal	109	WS	45	10	86,42
Orjinal	109	WS	45	5	79,01
N_ Orjinal	1860	WS	792	10	83,95
N_ Orjinal	1860	WS	792	5	80,25

Çizelge 4.29’da Gauss’un laplası filtresinin uygulanması sonucu (LoG) elde edilen özellikler ve bu filtre harici (N_ LoG) özelliklerin kullanılması neticesinde ulaşılan doğruluk oranları paylaşılmıştır. Bu filtre sayesinde 558 özellik üretilmiştir.

Çizelge 4.29. Gauss’un laplası filtresi sonucu elde edilen özellikler ve onun harici diğer tüm özelliklerin kullanılmasına ait sonuçlar

Kullanılan Özellikler	Kullanılan Özelliklerin Sayısı	Özellik Seçimi Yöntemi	Seçilen Özelliklerin Sayısı	Kat Sayısı	Doğruluk Oranı (%)
LoG	558	WS	221	10	86,42
LoG	558	WS	221	5	82,72
N_ LoG	1411	WS	637	10	82,72
N_ LoG	1411	WS	637	5	80,25

Wavelet filtresiyle toplam 744 özellik çıkarılmıştır. Bu filtre harici 1225 özellik bulunmaktadır. Bu bilgiler Çizelge 4.30’da ifade edilmiştir.

Çizelge 4.30. Wavelet filtresi sonucu elde edilen özellikler ve onun harici diğer tüm özelliklerin kullanılmasına ait sonuçlar

Kullanılan Özellikler	Kullanılan Özelliklerin Sayısı	Özellik Seçimi Yöntemi	Seçilen Özelliklerin Sayısı	Kat Sayısı	Doğruluk Oranı (%)
Wavelet	744	WS	333	10	91,36
Wavelet	744	WS	333	5	86,42
N_ Wavelet	1225	WS	484	10	83,95
N_ Wavelet	1225	WS	484	5	81,48

Kare filtresiyle elde edilen özellik sayısı 93'tür. Bu filtresinin özellikleri kullanılarak yapılan sınıflandırma işlemlerinde doğruluk oranları beklenilenin çok altında kalmıştır. Bu filtreye ait sonuçlar Çizelge 4.31'de verilmiştir.

Çizelge 4.31. Kare filtresi sonucu elde edilen özellikler ve onun harici diğer tüm özelliklerin kullanılmasına ait sonuçlar

Kullanılan Özellikler	Kullanılan Özelliklerin Sayısı	Özellik Seçimi Yöntemi	Seçilen Özelliklerin Sayısı	Kat Sayısı	Doğruluk Oranı (%)
Kare	93	WS	34	10	69,1358
Kare	93	WS	34	5	65,4321
N_ Kare	1876	WS	873	10	82,716
N_ Kare	1876	WS	873	5	79,0123

Görüntü yoğunluklarının karekökünün alınıp tekrar ölçeklenmesi işlemini gerçekleştiren karekök filtresi uygulaması sonrasında bulunan sonuçlar Çizelge 4.32'de paylaşılmıştır.

Çizelge 4.32. Karekök filtresi sonucu elde edilen özellikler ve onun harici diğer tüm özelliklerin kullanılmasına ait sonuçlar

Kullanılan Özellikler	Kullanılan Özelliklerin Sayısı	Özellik Seçimi Yöntemi	Seçilen Özelliklerin Sayısı	Kat Sayısı	Doğruluk Oranı (%)
Karekök	93	WS	44	10	74,07
Karekök	93	WS	44	5	83,95
N_ Karekök	1876	WS	934	10	80,25
N_ Karekök	1876	WS	934	5	72,84

Görüntü seviyelerinin logaritmasının alınması ve sonrasında yeniden ölçeklenmesini sağlayan Logaritma filtresinin uygulanmasının ardından çıkarılan özelliklerle ilişkili bulgular Çizelge 4.33'te verilmiştir.

Çizelge 4.33. Logaritma filtresi sonucu elde edilen özellikler ve onun harici diğer tüm özelliklerin kullanılmasına ait sonuçlar

Kullanılan Özellikler	Kullanılan Özelliklerin Sayısı	Özellik Seçimi Yöntemi	Seçilen Özelliklerin Sayısı	Kat Sayısı	Doğruluk Oranı (%)
Logaritma	93	WS	35	10	77,78
Logaritma	93	WS	35	5	72,84
N_ Logaritma	1876	WS	769	10	81,48
N_ Logaritma	1876	WS	769	5	80,25

Ekspansiyel işlemi yardımıyla elde edilen doğruluk oranları istenilen seviyeden uzak kalmıştır. Bu değerler Çizelge 4.34 aracılığıyla ifade edilmiştir.

Çizelge 4.34. Ekspansiyel filtresi sonucu elde edilen özellikler ve onun harici diğer tüm özelliklerin kullanılmasına ait sonuçlar

Kullanılan Özellikler	Kullanılan Özelliklerin Sayısı	Özellik Seçimi Yöntemi	Seçilen Özelliklerin Sayısı	Kat Sayısı	Doğruluk Oranı (%)
Ekspansiyel	93	WS	39	10	70,37
Ekspansiyel	93	WS	39	5	66,67
N_ Ekspansiyel	1876	WS	857	10	85,19
N_ Ekspansiyel	1876	WS	857	5	82,72

Görüntü yoğunluklarının yerel gradyana dönmesini sağlayan gradyan filtresinin kullanılmasının ardından seçilen özellik sayıları ve doğruluk oranları Çizelge 4.35'te verilmiştir.

Çizelge 4.35. Gradyan filtresi sonucu elde edilen özellikler ve onun harici diğer tüm özelliklerin kullanılmasına ait sonuçlar

Kullanılan Özellikler	Kullanılan Özelliklerin Sayısı	Özellik Seçimi Yöntemi	Seçilen Özelliklerin Sayısı	Kat Sayısı	Doğruluk Oranı (%)
Gradyan	93	WS	35	10	79,01
Gradyan	93	WS	35	5	80,25
N_ Gradyan	1876	WS	917	10	83,95
N_ Gradyan	1876	WS	917	5	80,25

İki boyutta yerel ikili örüntüler (local binary pattern, LBP) hesaplanarak özelliklerin çıkarılması sonucu elde edilen doğruluk oranları Çizelge 4.36'da verilmiştir.

Çizelge 4.36. LBP filtresi sonucu elde edilen özellikler ve onun harici diğer tüm özelliklerin kullanılmasına ait sonuçlar

Kullanılan Özellikler	Kullanılan Özelliklerin Sayısı	Özellik Seçimi Yöntemi	Seçilen Özelliklerin Sayısı	Kat Sayısı	Doğruluk Oranı (%)
LBP	93	WS	35	23	76,54
LBP	93	WS	35	23	72,84
N_ LBP	1876	WS	781	10	82,72
N_ LBP	1876	WS	781	5	79,01

Bütün bu filtreler sonrasında yapılan kombinasyonlar sonucu çıkarılan özelliklerin kullanılmasıyla elde edilen sonuçlar incelendiğinde en yüksek doğruluk oranı Çizelge 4.27’de verildiği gibi wavelet filtresinin uygulanması sonrası elde edilmiştir. Bu işlem sırasında wavelet filtresiyle çıkarılan 744 özellik içinden seçim işlemi WS algoritmasıyla gerçekleştirilerek 333 özellik seçilmiştir. Bu özellikler kullanılarak k-NN ile sınıflandırma işlemi yapılmıştır. Sonrasında 10-kat çapraz doğrulama yöntemi ile %91,36 doğruluk oranı elde edilmiştir.

Geliştirilen bu modelde 51 gerçek hastadan 50’si, 30 meme atenüasyonu olan hastadan 24’ü doğru tahmin edilmiştir. Çizelge 4.37’de bu değerler görülmektedir.


Çizelge 4.37. %91,36 doğruluk oranı elde edilen modele ait hata matrisi

		TAHMİN	
		Pozitif	Negatif
GERÇEK	Pozitif	50 (DP)	1 (YN)
	Negatif	6 (YP)	24 (DN)

Bu modelde özellikle hassasiyet ve geri çağırma kriterleri çok yüksek bulunmuştur. Bunlarla birlikte diğer kriterler Çizelge 4.38’de verilmiştir.

Çizelge 4.38. %91,36 doğruluk oranı elde edilen modele ait performans değerlendirme kriterleri

Sınıf	DP Oranı	YP Oranı	Hassasiyet	Seçicilik	Kesinlik	Geri Çağırma	F-skör	AUC
1	0,980	0,200	0,980	0,800	0,893	0,980	0,935	0,904



Şekil 4.18. %91,36 doğruluk oranı elde edilen modele ait ROC eğrisi (AUC= 0,904)

Bu modele ait ROC eğrisi Şekil 4.18’de gösterilmiştir. Bu eğrinin altında kalan alan 0,904 olarak bulunmuştur. Bu değer geleneksel akademik puanlama sistemine göre çok iyi olarak değerlendirilir.

Beşinci modelde bulunan doğruluk oranı dördüncü modelle aynı, ROC eğrisi altında kalan alanlar ise birbirine çok yakındır. Bu yüzden dördüncü modeldeki gibi bütün özelliklerin kullanılması yerine sadece wavelet filtresi sonucu elde edilen özelliklerin kullanılması yeterli olacaktır. Bu da modelin hızının artmasını ve hesaplama zamanının kısalmasını sağlayacaktır.

4.6. Vücut Kitle İndeksi Odaklı Yapılan Çalışmalar

Daha önceki bölümlerde yapılan çalışmalarda hastaların vücut kitle indeksleri (BMI) göz önünde bulundurulmamıştır. BMI ve atenuasyon arasında doğru orantılı bir ilişki olduğu için bu bölümde bazı hastaların BMI’leri hesaplanmış ve BMI’lerine göre üç gruba ayrılmıştır. Hastaların BMI’leri Eş. 4.1’deki gibi hesaplanmaktadır.

$$\text{BMI} = \frac{\text{ağırlık}}{\text{boy}^2} \quad (4.1)$$

Eş. 4.1’de ifade edildiği gibi BMI kişinin kilogram (kg) cinsinden ağırlığının, metre (m) cinsinden boyunun karesine bölünmesiyle elde edilir. Bu bilgilere sadece 60 hasta için ulaşılabildiğinden, 60 hastanın BMI’leri hesaplanabilmiştir. Bunun sonucunda bu bölümde yapılan çalışmada veri seti sayısı 60 olarak güncellenmiştir.

Çizelge 4.39. BMI bilgisi içeren veri setini dağılımı ve BMI ortalamaları

		HASTA SAYISI	BMI ORTALAMASI
HASTA TİPİ	Atenüasyon	24	33,95
	İskemi	36	29,96
	Toplam	60	31,56

Çizelge 4.39’da gösterildiği üzere bu veri setindeki 60 hastanın BMI ortalaması 31,56 olarak bulunmuştur. Meme atenüasyonu olan 24 hastanın BMI ortalaması 33,95 iken gerçekten hasta olan 36 hastanın BMI’si 29,96 olarak bulunmuştur. Bu değerler bizim veri setimizi doğrulayan sonuçlardır çünkü BMI ve atenüasyon arasında doğru orantı vardır yani hastanın BMI’si arttıkça atenüasyon olma ihtimali artmaktadır.

Literatürde kabul edilmiş dünya sağlık örgütünün hazırladığı beslenme durumu BMI tablosu göz önünde bulundurularak, veri kümemiz vücut kitle indekslerine göre üç gruba ayrılmıştır.

Çizelge 4.40. Hastaların vücut kitle indekslerine göre gruplandırılması

	BMI < 30	30 ≤ BMI ≤ 35	BMI ≥ 35	Toplam
Hasta Sayısı	19	25	16	60


Vücut kitle indeksi 30’dan küçük 19 hasta, 30-35 arasında 25 hasta ve 35’ten büyük 16 hasta bulunmaktadır ve bunlar Çizelge 4.40’da görüldüğü gibi 3 farklı veri kümesi oluşturmuşlardır. BMI < 30, vücut kitle indeksi 30’dan küçük, 30 ≤ BMI ≤ 35, vücut kitle indeksi 30-35 arasında ve BMI ≥ 35, vücut kitle indeksi 35’ten büyük hastalarla oluşturulan veri kümesini ifade etmektedir. Oluşturulan bu yeni veri kümeleriyle çeşitli sınıflandırma işlemleri yapılmış ve sonuçlar değerlendirilmiştir. Bu veri kümeleriyle yapılan bütün sınıflandırmalar için k=1 komşuluklu k-NN sınıflandırıcısı kullanılmıştır.

Bunu sebebi daha önce kullanılan veri kümelerinde çeşitli sınıflandırma yöntemlerinin kullanılmasına rağmen en yüksek doğruluk oranlarının sürekli $k=1$ komşuluklu k -NN sınıflandırıcı ile elde edilmiş olmasıdır. Ayrıca zaman zaman farklı katlı çapraz doğrulama yöntemi kullanılmasına rağmen 10 kat üzerinde literatürde ortak bir fikir birliği olması ve daha güvenilir olarak değerlendirilmesi sebebiyle bu kısımda sadece 10-kat çapraz doğrulama yöntemi kullanılmıştır. Daha önceki modellerde toplam 1969 adet özellik çıkarılmıştır. dördüncü modelde ise sadece wavelet filtresi sonucu çıkarılan özelliklerin kullanılarak da aynı seviyede yüksek doğruluk oranının elde edildiği gösterilmiştir. Bu yüzden bu BMI odaklı çalışmada toplam 1769 özelliğin (Bütün özellikler) ve sadece wavelet filtresi sonucu çıkarılan (Wavelet özellikleri) 744 özelliğin ayrı ayrı kullanıldığı modeller denenmiştir.

Çizelge 4.41. BMI odaklı yapılan çalışmanın sonuçları


BMI Aralığı	Hasta Sayısı	Kullanılan Özellikler	Özellik Seçimi Yöntemi	Seçilen Özelliklerin Sayısı	Kat Sayısı	Doğruluk Oranı (%)
30'dan küçük	19	Bütün özellikler	WS	Toplam 1969 Seçilen 417	10	100
30-35 arası	25	Bütün özellikler	WS	Toplam 1969 Seçilen 632	10	92
35'ten büyük	16	Bütün özellikler	WS	Toplam 1969 Seçilen 589	10	87,5
30'dan küçük	19	Wavelet özellikleri	WS	Toplam 744 Seçilen 206	10	100
30-35 arası	25	Wavelet özellikleri	WS	Toplam 744 Seçilen 322	10	92
35'ten büyük	16	Wavelet özellikleri	WS	Toplam 744 Seçilen 187	10	93,5
30'dan küçük	19	Bütün özellikler	SFFS	Toplam 1969 Seçilen 1	10	100
30-35 arası	25	Bütün özellikler	SFFS	Toplam 1969 Seçilen 2	10	88
35'ten büyük	16	Bütün özellikler	SFFS	Toplam 1969 Seçilen 1	10	100
30'dan küçük	19	Wavelet özellikleri	SFFS	Toplam 744 Seçilen 2	10	100
30-35 arası	25	Wavelet özellikleri	SFFS	Toplam 744 Seçilen 2	10	88
35'ten büyük	16	Wavelet özellikleri	SFFS	Toplam 744 Seçilen 1	10	100

Denenen bütün modeller ve bu modellere ait sonuçlar Çizelge 4.41'de verilmiştir. Görüldüğü üzere daha önce oluşturulan modellerden daha yüksek başarı oranları elde edilmiştir. Vücut kitle indeksi 30'dan küçük ve 35'ten büyük hasta verilerinin oluşturulmasıyla yapılan sınıflandırma işlemlerinde %100 doğruluk oranları elde edilmiştir. Vücut kitle indeksi 30-35 arası olan veri kümesinde ise en yüksek doğruluk oranı %92 olarak bulunmuştur.




Şekil 4.19. Bütün özelliklerin kullanıldığı WS özellik seçim metoduyla seçilen özellikler sonucu elde edilen ROC eğrileri

Bütün özellikler kullanılarak WS algoritmasıyla özelliklerin seçilmesi sonucu elde edilen ROC eğrileri aynı grafikte Şekil 4.19’da gösterilmiştir. 30’dan küçük BMI grubundan elde edilen ROC eğrisi altında kalan alan olabilecek maksimum değerdedir. Geleneksel akademik puanlama sistemine 30-35 arası grup için AUC çok iyi, 35’den büyük grup için ise iyi seviyededir.




Şekil 4.20. Wavelet filtresi sonucu elde edilen özelliklerin kullanıldığı WS özellik seçim metoduyla seçilen özellikler sonucu elde edilen ROC eğrileri

Wavelet filtresinin uygulanması akabinde çıkarılan özellikler kullanılarak WS metoduyla özelliklerin seçilmesi sonucu elde edilen ROC eğrileri aynı grafikte Şekil 4.20’de verilmiştir. Aynı zamanda ROC eğrisi altında kalan alanlar 30’dan küçük ve 30-35 arası grup için çok iyi, 35’den büyük grup için ise iyidir.



Şekil 4.21. Bütün özelliklerin kullanıldığı SFFS özellik seçim metoduyla seçilen özellikler sonucu elde edilen ROC eğrileri

Şekil 4.21’de ROC eğrileri aynı çıktığı için mavi ve yeşil çizgiler üst üste binmiştir. BMI<30 ve BMI>35 grubu için AUC maksimum değerindedir. 30-35 arası grup için diğer gruplara kıyasla düşük olmasına rağmen iyi olarak değerlendirilebilecek seviyededir.



Şekil 4.22. Wavelet filtresi sonucu elde edilen özelliklerin kullanıldığı SFFS özellik seçim metoduyla seçilen özellikler sonucu elde edilen ROC eğrileri

Wavelet filtresinin ardından çıkarılan özelliklerle yapılan işlemler sonrası üretilen ROC eğrileri Şekil 4.22’de verilmiştir. Bu sonuçlar bütün özellikler kullanılarak aynı yöntemlerle gerçekleştirilen ve Şekil 4.21’de verilen sonuçlarla aynıdır. Bu sonuca göre bütün özelliklerin kullanılmasına gerek olmadığı değerlendirilebilir.

Vücut kitle indekslerine göre ayrılmış her hasta grubu için yapılan özellik seçimlerinde farklı özellikler seçilmiştir. Bu sonuca göre bütün hastalar için aynı veri setinin veya aynı özelliklerin kullanılmasına gerek olmadığı sonucu çıkarılmıştır. Ayrıca hastaların BMI’sine göre gruplandırılıp yapılan çalışmada başarı oranları, BMI gruplandırması yapılmamış çalışmalara göre çok daha yüksek bulunmuştur. Bu da teşhis açısından çok daha fazla katkı sağlayabilir.

Sonuç olarak, literatürle kıyaslandığında, gerçekleştirilen bu çalışma, hiçbir ek donanıma ihtiyaç duyulmadan veya atenuasyon katsayısı hesabına gerek olmadan bu doğruluk oranı elde edilen ilk çalışma olması dolayısıyla önem arz etmektedir.

Çalışmada sunulan model, daha önceden uygulanmamış olmakla birlikte, ek radyasyon yükü getirmeme, kullanıcı ve yorumlayıcıya bağımlı olmaksızın, objektif, doğru, genellenebilir bir yöntem olma gibi özelliklere sahiptir. Ayrıca atenüasyon problemine maliyet-etkin bir çözüm yolu sunmaktadır.

Çalışmamda kullanılan veri kümesi iki farklı tetkik (Miyokard perfüzyon sintigrafisi ve Koroner Anjiyografi) sonucu elde edildiği için oluşturulması zor bir veri kümesidir, bu yüzden farklı çalışmalarda farklı metotlar kullanılarak değerlendirilebilir.

Bunun yanında veri kümesi artırılarak ya da farklı öğrenme algoritmalarından faydalanılarak doğruluk oranı yüksek modellerin geliştirilmesi üzerinde çalışmalar yapılabilir.

KAYNAKLAR

1. Cagle, S. D., and Cooperstein, N. (2018). Coronary Artery Disease: Diagnosis and Management. *Primary Care: Clinics in Office Practice*, 45(1), 45-61.
2. Ong, S. B., Samangouei, P., Kalkhoran, S. B., and Hausenloy, D. J. (2015). The mitochondrial permeability transition pore and its role in myocardial ischemia reperfusion injury. *Journal of Molecular and Cellular Cardiology*, 78, 23-34.
3. Lim, M. J., and White, C. J. (2013). Coronary Angiography Is the Gold Standard for Patients with Significant Left Ventricular Dysfunction. *Progress in Cardiovascular Diseases*, 55(5), 504-508.
4. Scanlon, P. J., Faxon, D. P., Audet, A. M., Carabello, B., Dehmer, G. J., Eagle, K. A., Smith, S. C., Jr. (1999). ACC/AHA guidelines for coronary angiography. A report of the American College of Cardiology/American Heart Association Task Force on practice guidelines (Committee on Coronary Angiography). Developed in collaboration with the Society for Cardiac Angiography and Interventions. *Journal of the American College of Cardiology*, 33(6), 1756-1824.
5. Noto, T. J., Jr., Johnson, L. W., Krone, R., Weaver, W. F., Clark, D. A., Kramer, J. R., Jr., and Vetrovec, G. W. (1991). Cardiac catheterization 1990: a report of the Registry of the Society for Cardiac Angiography and Interventions (SCA&I). *Cathet Cardiovasc Diagn*, 24(2), 75-83.
6. Mirza, A. J., Taha, A. Y., Aldoori, J. S., Hawas, J. M., and Hassan, K. W. (2018). Coronary artery perforation complicating percutaneous coronary intervention. *Asian Cardiovasc Thorac Ann*, 26(2), 101-106.
7. Karaman, K., Karayakali, M., Arisoy, A., Akar, I., and Celik, A. (2017). A late complication of coronary artery perforation during primary percutaneous coronary intervention: Coronary arteriovenous fistula. *Turk Kardiyol Dern Ars*, 45(8), 739-743.
8. Fernandez-Rodriguez, D., Anmad Shihadeh, L., Martos-Maine, J. L., Couto-Comba, P., Quijada-Fumero, A., Pimienta, R., Bosa Ojeda, F. (2018). [Impact of rotational coronary angiography in the amount of iodinated contrast and the exposure to ionising radiations in patients undergoing invasive coronary procedures: A systematic review and meta-analysis]. *Arch Cardiol Mex*, 88(4), 277-286.
9. Goetze, S., Brown, T. L., Lavelly, W. C., Zhang, Z., and Bengel, F. M. (2007). Attenuation correction in myocardial perfusion SPECT/CT: effects of misregistration and value of reregistration. *The Journal of Nuclear Medicine*, 48(7), 1090-1095.
10. Holder, L., Lewis, S., Abrames, E., and Wolin, E. A. (2016). Review of SPECT myocardial perfusion imaging. *Journal of the American Osteopathic College*, 5(3), 5-13.
11. Slomka, P., and Germano, G. (2017). Optimizing radiation dose and imaging time with conventional myocardial perfusion SPECT: Technical aspects. *Journal of Nuclear Cardiology*, 24(3), 888-891.

12. Bateman, T. M. (2012). Advantages and disadvantages of PET and SPECT in a busy clinical practice. *Journal of Nuclear Cardiology*, 19(1), 3-11.
13. Burrell, S., and MacDonald, A. (2006). Artifacts and pitfalls in myocardial perfusion imaging. *Journal of Nuclear Medicine Technology*, 34(4), 193-211.
14. Qutbi, M., and Soltanshahi, M. (2018). A practical method to reduce breast attenuation during SPECT myocardial perfusion imaging. *Journal of Nuclear Cardiology*, 25(6), 2179-2181.
15. Fricke, H., Fricke, E., Weise, R., Kammeier, A., Lindner, O., and Burchert, W. (2004). A method to remove artifacts in attenuation-corrected myocardial perfusion SPECT introduced by misalignment between emission scan and CT-derived attenuation maps. *Journal of Nuclear Medicine*, 45(10), 1619-1625.
16. Chang, L. T. (1978). A method for attenuation correction in radionuclide computed tomography. *IEEE Transactions on Nuclear Science*, 25(1), 638-643.
17. Fernandez-Delgado, M., Cernadas, E., Barro, S., and Amorim, D. (2014). Do we Need Hundreds of Classifiers to Solve Real World Classification Problems? *Journal of Machine Learning Research*, 15, 3133-3181.
18. Blankespoor, S. C., Wu, X., Kalki, K., Brown, J. K., Tang, H. R., Cann, C. E., and Hasegawa, B. H. (1996). Attenuation correction of SPECT using X-ray CT on an emission-transmission CT system: Myocardial perfusion assessment. *IEEE Transactions on Nuclear Science*, 43(4), 2263-2274.
19. Utsunomiya, D., Tomiguchi, S., Shiraishi, S., Yamada, K., Honda, T., Kawanaka, K., Yamashita, Y. (2005). Initial experience with X-ray CT based attenuation correction in myocardial perfusion SPECT imaging using a combined SPECT/CT system. *Annals of Nuclear Medicine*, 19(6), 485-489.
20. Nycz, J., and Freeman, M. (2017). Prone SPECT imaging, an effective remedy for artifacts seen in supine SPECT/CT myocardial perfusion scans. *Journal of Nuclear Medicine*, 58(1), 770-770.
21. Goetze, S., and Wahl, R. L. (2007). Prevalence of misregistration between SPECT and CT for attenuation-corrected myocardial perfusion SPECT. *Journal of Nuclear Cardiology*, 14(2), 200.
22. Gurajala, R., Safar, B., Nasr, E., Karuppasamy, K., and Shrikanthan, S. (2015). Role of Hybrid SPECT/CT in combination with 99mTc-labeled RBC dynamic planar scintigraphy for acute non-variceal gastrointestinal bleeding: Our experience. *Journal of Nuclear Medicine*, 56(3).
23. Etchebehere, E. C., de Oliveira Santos, A., Gumz, B., Vicente, A., Hoff, P. G., Corradi, G., . . . Costa, F. P. (2014). 68Ga-DOTATATE PET/CT, 99mTc-HYNIC-octreotide SPECT/CT, and whole-body MR imaging in detection of neuroendocrine tumors: a prospective trial. *The Journal of Nuclear Medicine*, 55(10), 1598-1604.

24. Brix, G., Nekolla, E. A., Borowski, M., and Noßke, D. (2014). Radiation risk and protection of patients in clinical SPECT/CT. *European Journal of Nuclear Medicine and Molecular Imaging*, 41(1), 125-136.
25. DePuey, E. G., and Rozanski, A. (1995). Using gated technetium-99m-sestamibi SPECT to characterize fixed myocardial defects as infarct or artifact. *Journal of Nuclear Medicine*, 36(6), 952-955.
26. Shimokawa, H., and Yasuda, S. (2008). Myocardial ischemia: current concepts and future perspectives. *Journal of Cardiology*, 52(2), 67-78.
27. Ross, R. (1999). Atherosclerosis--an inflammatory disease. *New England Journal of Medicine*, 340(2), 115-126.
28. Shimokawa, H. (1999). Primary endothelial dysfunction: atherosclerosis. *Journal of Molecular and Cellular Cardiology*, 31(1), 23-37.
29. Rebeyka, I., Coles, J., and Wilson, G. (1987). Hoffman JIE: Transmural myocardial per-fusion. *Prog Cardiovasc Dis* 29:429-464, 1987. *Drugs*, 33, 392-412.
30. Cohn, P. F., Fox, K. M., of, W. t. A., and Daly, C. (2003). Silent myocardial ischemia. *Circulation*, 108(10), 1263-1277.
31. Buffon, A., Santini, S. A., Ramazzotti, V., Rigattieri, S., Liuzzo, G., Biasucci, L. M., Maseri, A. (2000). Large, sustained cardiac lipid peroxidation and reduced antioxidant capacity in the coronary circulation after brief episodes of myocardial ischemia. *Journal of the American College of Cardiology*, 35(3), 633-639.
32. Weiss, R. G., Bottomley, P. A., Hardy, C. J., and Gerstenblith, G. (1990). Regional myocardial metabolism of high-energy phosphates during isometric exercise in patients with coronary artery disease. *New England Journal of Medicine*, 323(23), 1593-1600.
33. Armstrong, W. F., and Zoghbi, W. A. (2005). Stress echocardiography: current methodology and clinical applications. *Journal of the American College of Cardiology*, 45(11), 1739-1747.
34. Kaufmann, P. A., and Camici, P. G. (2005). Myocardial blood flow measurement by PET: technical aspects and clinical applications. *The Journal of Nuclear Medicine*, 46(1), 75-88.
35. Wilke, N. M., Jerosch-Herold, M., Zenovich, A., and Stillman, A. E. (1999). Magnetic resonance first-pass myocardial perfusion imaging: clinical validation and future applications. *Journal of Magnetic Resonance Imaging*, 10(5), 676-685.
36. Fearon, W. F., Farouque, H. M., Balsam, L. B., Caffarelli, A. D., Cooke, D. T., Robbins, R. C., Yock, P. G. (2003). Comparison of coronary thermodilution and Doppler velocity for assessing coronary flow reserve. *Circulation*, 108(18), 2198-2200.

37. Hozumi, T., Yoshida, K., Ogata, Y., Akasaka, T., Asami, Y., Takagi, T., and Morioka, S. (1998). Noninvasive assessment of significant left anterior descending coronary artery stenosis by coronary flow velocity reserve with transthoracic color Doppler echocardiography. *Circulation*, 97(16), 1557-1562.
38. Kataoka, Y., Nakatani, S., Tanaka, N., Kanzaki, H., Yasuda, S., Morii, I., Kitakaze, M. (2007). Role of transthoracic Doppler-determined coronary flow reserve in patients with chest pain. *Circulation Journal*, 71(6), 891-896.
39. Madsen, M. T. (2007). Recent advances in SPECT imaging. *The Journal of Nuclear Medicine*, 48(4), 661-673.
40. Russell, R. R., 3rd, and Zaret, B. L. (2006). Nuclear cardiology: present and future. *Current Problems in Cardiology*, 31(9), 557-629.
41. Hendel, R., Berman, D., Di Carli, M., Heidenreich, P., Henkin, R., and Pellikka, P. (2009). Appropriate use criteria for cardiac radionuclide imaging: a report of the American College of Cardiology Foundation Appropriate Use Criteria Task Force, the American Society of Nuclear Cardiology, the American College of Radiology, the American Heart Association, the American Society of Echocardiography, the Society of Cardiovascular Computed Tomography, the Society for Cardiovascular Magnetic Resonance, and the Society of Nuclear Medicine. *Journal of the American College of Cardiology*, 53(23), 2201-2229.
42. Kharabsheh, S. M., Al-Sugair, A., Al-Buraiki, J., and Al-Farhan, J. (2006). Overview of exercise stress testing. *Annals of Saudi Medicine*, 26(1), 1-6.
43. Fathala, A. (2011). Myocardial perfusion scintigraphy: techniques, interpretation, indications and reporting. *Annals of Saudi Medicine*, 31(6), 625-634.
44. Taillefer, R., Gagnon, A., Laflamme, L., Gregoire, J., Leveille, J., and Phaneuf, D. C. (1989). Same day injections of Tc-99m methoxy isobutyl isonitrile (hexamibi) for myocardial tomographic imaging: comparison between rest-stress and stress-rest injection sequences. *European Journal of Nuclear Medicine and Molecular Imaging*, 15(3), 113-117.
45. Husain, S. S. (2007). Myocardial perfusion imaging protocols: is there an ideal protocol? *Journal of Nuclear Medicine Technology*, 35(1), 3-9.
46. Holly, T. A., Abbott, B. G., Al-Mallah, M., Calnon, D. A., Cohen, M. C., DiFilippo, F. P., Jain, D. (2010). Single photon-emission computed tomography. *Journal of Nuclear Cardiology*, 17(5), 941-973.
47. Zaidi, H., and Erwin, W. (2006). *Quantitative analysis in nuclear medicine imaging*. *Journal of Nuclear Medicine*, 48(8), 1401-1401.
48. Celler, A., Dixon, K. L., Chang, Z., Blinder, S., Powe, J., and Harrop, R. (2005). Problems created in attenuation-corrected SPECT images by artifacts in attenuation maps: a simulation study. *Journal of Nuclear Medicine*, 46(2), 335-343.

49. Coldwell, R. (1986). Iterative codes for fitting complete spectra. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 242(3), 455-461.
50. Ficaro, E. P., Fessler, J. A., Rogers, W. L., and Schwaiger, M. (1994). Comparison of americium-241 and technetium-99m as transmission sources for attenuation correction of thallium-201 SPECT imaging of the heart. *The Journal of Nuclear Medicine*, 35(4), 652-663.
51. Smith, N. B., and Webb, A. (2010). *Introduction to medical imaging: physics, engineering and clinical applications*. Cambridge: Cambridge University Press, 113-117.
52. Bushberg, J. T., and Boone, J. M. (2011). *The essential physics of medical imaging*. Philadelphia: Lippincott Williams & Wilkins, 63-68.
53. Hurton, B. F. (2002). Correction for attenuation and scatter in SPECT. *Alasbinn Journal*, 5(18).
54. Groch, M. W., and Erwin, W. D. (2000). SPECT in the year 2000: basic principles. *Journal of Nuclear Medicine Technology*, 28(4), 233-244.
55. Saha, G. B. (2012). *Physics and radiobiology of nuclear medicine*. Berlin: Springer Science & Business Media, 70-74.
56. Powsner, R. A., Palmer, M. R., and Powsner, E. R. (2013). *Essentials of nuclear medicine physics and instrumentation*. New Jersey: John Wiley & Sons, 181-186.
57. Wells, R. G., Soueidan, K., Timmins, R., and Ruddy, T. D. (2013). Comparison of attenuation, dual-energy-window, and model-based scatter correction of low-count SPECT to 82Rb PET/CT quantified myocardial perfusion scores. *Journal of Nuclear Cardiology*, 20(5), 785-796.
58. Hashimoto, J., Kubo, A., Ogawa, K., Amano, T., Fukuuchi, Y., Motomura, N., and Ichihara, T. (1997). Scatter and attenuation correction in technetium-99m brain SPECT. *The Journal of Nuclear Medicine*, 38(1), 157-162.
59. Ficaro, E. P., Fessler, J. A., Ackermann, R. J., Rogers, W. L., Corbett, J. R., and Schwaiger, M. (1995). Cardiac SPECT: effect of attenuation correction on myocardial tracer distribution. *The Journal of Nuclear Medicine*, 36, 921-931.
60. Noori Asl, M., and Sadremomtaz, A. (2014). Review of transmission scanning configurations in cardiac SPECT. *Iranian Journal of Nuclear Medicine*, 22(2), 77-88.
61. Duvall, W. L., Croft, L. B., Corriel, J. S., Einstein, A. J., Fisher, J. E., Haynes, P. S., Henzlova, M. J. (2006). SPECT myocardial perfusion imaging in morbidly obese patients: image quality, hemodynamic response to pharmacologic stress, and diagnostic and prognostic value. *Journal of Nuclear Cardiology*, 13(2), 202-209.
62. Almeida, C. D. d., Coutinho, C., Dantas, B. M., and Peixoto, J. E. (2009). Study of the attenuation coefficient of a breast phantom used in diagnostic radiology. *2009 International Nuclear Atlantic Conference*, Rio de Janeiro, Brazil.

63. Thompson, R. C., Heller, G. V., Johnson, L. L., Case, J. A., Cullom, S. J., Garcia, E. V., Bateman, T. M. (2005). Value of attenuation correction on ECG-gated SPECT myocardial perfusion imaging related to body mass index. *Journal of Nuclear Cardiology*, 12(2), 195-202.
64. Shah, A., Das, P., Subkovas, E., Buch, A. N., Rees, M., and Bellamy, C. (2015). Radiation dose during coronary angiogram: relation to body mass index. *Heart, Lung and Circulation*, 24(1), 21-25.
65. Gonzalez, R. C., Woods, R. E., and Eddins, S. L. (2004). *Digital image processing using MATLAB*. India: Pearson Education, 210-213.
66. Russ, J. C. (2016). Processing images in frequency space. In *The image processing handbook*. ABD: CRC Press, 355-412.
67. Electrical, I. O., and Engineers, E. (1990). IEEE Standards Glossary of Image Processing and Pattern Recognition Terminology. IEEE Std, 610(4), 7-14.
68. Ma, Z., Tavares, J. M., Jorge, R. N., and Mascarenhas, T. (2010). A review of algorithms for medical image segmentation and their applications to the female pelvic cavity. *Computer Methods in Biomechanics and Biomedical Engineering*, 13(2), 235-246.
69. Senthilkumaran, N., and Vaithegi, S. (2016). Image segmentation by using thresholding techniques for medical images. *Computer Science & Engineering: An International Journal*, 6(1), 1-13.
70. Abutaleb, A. S. (1989). Automatic thresholding of gray-level pictures using two-dimensional entropy. *Computer Vision, Graphics, and Image Processing*, 47(1), 22-32.
71. Liu, J., and Li, W. (1993). Automatic thresholding using the Otsu algorithm based on the two-dimensional gray image. *Acta Automatica Sinica*, 19(1), 101-105.
72. Gong, J., Li, L., and Chen, W. (1998). Fast recursive algorithms for two-dimensional thresholding. *Pattern Recognition*, 31(3), 295-300.
73. Jing, X.-j., Cai, A.-n., and Sun, J.-a. (2001). Image segmentation based on 2D maximum between-cluster variance. *Journal-China Institute of Communications*, 22(4), 71-76.
74. Fan, J.-L., Zhao, F., and Zhang, X.-F. (2007). Recursive algorithm for three-dimensional Otsu's thresholding segmentation method. *Dianzi Xuebao (Acta Electronica Sinica)*, 35(7), 1398-1402.
75. Tomita, F., and Tsuji, S. (2013). *Computer analysis of visual textures* (Vol. 102). Berlin: Springer Science & Business Media, 165-172.
76. Carlucci, L. (1972). A formal system for texture languages. *Pattern recognition*, 4(1), 53-72.

77. Zucker, S. W. (1976). Toward a model of texture. *Computer Graphics and Image Processing*, 5(2), 190-202.
78. Van Griethuysen, J. J., Fedorov, A., Parmar, C., Hosny, A., Aucoin, N., Narayan, V., Aerts, H. J. (2017). Computational radiomics system to decode the radiographic phenotype. *Cancer research*, 77(21), e104-e107.
79. Amadasun, M., and King, R. (1989). Textural Features Corresponding to Textural Properties. *Ieee Transactions on Systems Man and Cybernetics*, 19(5), 1264-1274.
80. Lorensen, W. E., and Cline, H. E. (1987). Marching cubes: A high resolution 3D surface construction algorithm. *ACM Siggraph Computer Graphics*, 21(4), 163-169.
81. Chandrashekar, G., and Sahin, F. (2014). A survey on feature selection methods. *Computers & Electrical Engineering*, 40(1), 16-28.
82. Osisanwo, F., Akinsola, J., Awodele, O., Hinmikaiye, J., Olakanmi, O., and Akinjobi, J. (2017). Supervised machine learning algorithms: classification and comparison. *International Journal of Computer Trends and Technology (IJCTT)*, 48(3), 128-138.
83. Ayodele, T. O. (2010). Types of machine learning algorithms. *New Advances in Machine Learning*, 3, 19-48.
84. Newsom, I. (2015). Data Analysis II: Logistic Regression. http://web.pdx.edu/~newsomj/da2/ho_logistic.pdf.
85. Kotsiantis, S. B. (2007). Supervised Machine Learning: A Review of Classification Techniques. *Emerging Artificial Intelligence Applications in Computer Engineering*, 160, 3-24.
86. Smola, A., and Vishwanathan, S. (2008). Introduction to machine learning. *Cambridge University, UK*, 32(34), 2008.
87. Schapire, R. (2015). *Machine learning algorithms for classification*. New Jersey: Princeton University, 10-18.
88. Neocleous, C., and Schizas, C. (2002). *Artificial neural network learning: A comparative review*. Paper presented at the Hellenic Conference on Artificial Intelligence.
89. Cheng, J., Greiner, R., Kelly, J., Bell, D., and Liu, W. (2002). Learning Bayesian networks from data: An information-theory based approach. *Artificial Intelligence*, 137(1-2), 43-90.
90. Refaeilzadeh, P., Tang, L., and Liu, H. (2009). Cross-Validation. In L. Liu and M. T. Özsu (Eds.), *Encyclopedia of Database Systems* (pp. 532-538). Boston, MA: Springer US.
91. Dietterich, T. G. (1998). Approximate statistical tests for comparing supervised classification learning algorithms. *Neural Computation*, 10(7), 1895-1923.

92. Kohavi, R. (1995). *A study of cross-validation and bootstrap for accuracy estimation and model selection*. Paper presented at the Ijcai (Vol. 14, No. 2), 1137-1145.
93. Vallières, M., Freeman, C. R., Skamene, S. R., and El Naqa, I. (2015). A radiomics model from joint FDG-PET and MRI texture features for the prediction of lung metastases in soft-tissue sarcomas of the extremities. *Physics in Medicine & Biology*, 60(14), 5471.
94. Haralick, R. M., Shanmugam, K., and Dinstein, I. H. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, (6), 610-621.
95. Galloway, M. M. (1975). Texture analysis using gray level run lengths. *Computer graphics and image processing*, 4(2), 172-179.
96. Thibault, G., Fertil, B., Navarro, C., Pereira, S., Cau, P., Levy, N., Mari, J.-L. (2013). Shape and texture indexes application to cell nuclei classification. *International Journal of Pattern Recognition and Artificial Intelligence*, 27(1), 1357002.
97. Hu, Z., Bao, Y., Xiong, T., and Chiong, R. (2015). Hybrid filter–wrapper feature selection for short-term load forecasting. *Engineering Applications of Artificial Intelligence*, 40, 17-27.
98. Whitney, A. W. (1971). A direct method of nonparametric measurement selection. *IEEE Transactions on Computers*, 100(9), 1100-1103.
99. Pudil, P., Novovicova, J., and Kittler, J. (1994). Floating Search Methods in Feature-Selection. *Pattern Recognition Letters*, 15(11), 1119-1125.
100. Devijver, P. A., and Kittler, J. (1982). *Pattern recognition: A statistical approach*. New Jersey: Prentice hall, 160-168.
101. Goldberg, D. E. (1989). *Genetic algorithms in search. Optimization, and Machine Learning*, Wesley: Addison, 187-192.
102. Sokolova, M., and Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427-437.
103. Isa, N. E. z. M., Amir, A., Ilyas, M. Z., and Razalli, M. S. (2017). *The performance analysis of K-nearest neighbors (K-NN) algorithm for motor imagery classification based on EEG signal*. Paper presented at the MATEC web of conferences.
104. Zhang, G. P. (2000). Neural networks for classification: a survey. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 30(4), 451-462.
105. Utku, A., and Doğru, İ. A. (2017). Android kötücül yazılımlar için izin tabanlı tespit sistemi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 32(4), 1015-1024.

106. Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., and Witten, I. H. (2009). The WEKA data mining software: an update. *ACM SIGKDD explorations newsletter*, 11(1), 10-18.
107. Chu, A., Sehgal, C. M., and Greenleaf, J. F. (1990). Use of gray value distribution of run lengths for texture analysis. *Pattern Recognition Letters*, 11(6), 415-41.





GAZİ GELECEKTİR..