



**Meme Manyetik Rezonans Görüntülemeye (MRG) Lezyon
Tespiti, Yalancı Pozitif Ve Yalancı Negatif Bulguların
Azaltılmasına Yönelik Yazılım Geliştirilmesi**

Program Kodu: 3001

Proje No: 118E201

Proje Yürütücüsü:
Dr. Öğr. Üyesi Gökçen ÇETİNEL

Araştırmacı:

Dr. Öğr. Üyesi Fuldem MUTLU

Bursiyer(ler):

**Öğr. Gör. Sevda GÜL
Samet YILDIZELİ**

ARALIK 2019
SAKARYA



ÖNSÖZ

Bu proje 15.07.2018 tarihinde TÜBİTAK tarafından desteklenerek 118E201 proje numarası ile başlatılmıştır. Proje ekibi proje başvurusunu hazırlamadan önce ve hazırlık aşamasında ön çalışmalara başlamıştır. Başvuru yapıldıktan sonra proje ekibi projenin amacı doğrultusunda projede belirtilen hedefleri gerçekleştirmek amacıyla düzenli olarak bir araya gelerek ilk verilerini projenin kabul tarihinde elde etmiştir.

Bu projenin konusu meme manyetik rezonans görüntülemeye lezyon tespiti, yalancı pozitif ve yalancı negatif bulguların azaltılmasına yönelik yazılım geliştirilmesidir. Bu amaçla proje öncesi ve proje süresi boyunca birçok araştırma yapılarak istenilen amaca ulaşılmasını sağlayacak en optimum yazılım elde edilmeye çalışılmıştır. Projede geliştirilen yazılımla yalancı pozitiflerin sayısı azaltılarak ek tetkiklerin sayılarının azaltılması ve yalancı negatiflerin sayısı azaltılarak hastalığın teşhis edilememesinden kaynaklanan tehditlerin ortadan kaldırılması projenin sosyal-ekonomik katkısıdır. Ayrıca, genç bilim insanları yetiştirmek projenin katkılarından biridir.

İÇİNDEKİLER

ÖNSÖZ.....	ii
İÇİNDEKİLER.....	iii
TABLolar LİSTESİ.....	v
ŞEKİLLER LİSTESİ.....	vi
ÖZET.....	ix
ABSTRACT.....	x
1. BÖLÜM: GİRİŞ.....	1
2. BÖLÜM: LİTERATÜR ARAŞTIRMASI.....	7
3. BÖLÜM: GEREÇ VE YÖNTEM.....	15
3.1. Veri Seti Oluşturma.....	15
3.2. Meme MRG Görüntülerinin Otomatik Segmentasyonu.....	22
3.2.1. Meme Bölgesi Segmentasyonu.....	23
3.2.2. Meme Lezyon Segmentasyonu.....	28
3.2.2.1. Otsu Segmentasyon Yöntemi.....	29
3.2.2.2. Bölge Büyütme Yöntemi.....	32
3.2.2.3. Bulanık C-Ortalama Yöntemi.....	34
3.2.2.4. k-Ortalama Yöntemi.....	36
3.2.2.5. Markov Rastgele Alanlar Yöntemi.....	37
3.2.2.6. Aktif Sınırlar Modeli.....	42
3.2.3. Lezyon Alanının Hesaplanması.....	44
3.2.3.1. Bölgesel ve Topolojik Tanımlayıcılar.....	47
3.2.3.2. Bit Dörtlüsü Yöntemi.....	47
3.2.4. Lezyon Renk Tabakası.....	49
3.2.5. Segmentasyon Sonuç.....	51
3.3. Özellik Çıkarma.....	53



3.3.1. Histogram Özellikleri.....	54
3.3.2. Doku Özellikleri.....	55
3.3.2.1. Gri-Seviye Eş Oluşum Matrisi.....	55
3.3.2.2. Komşu Gri-Ton Fark Matrisi.....	58
3.3.2.3. Gri Seviye Bağlılık Matrisi.....	60
3.3.3. Şekil Özellikleri.....	61
3.3.4. Dönüşüm Uzayı Özellikleri.....	62
3.3.4.1. Ayrık Fourier Dönüşümü.....	62
3.3.4.2. Shearlet Dönüşümü.....	64
3.4. Özellik Seçme.....	66
3.4.1. Fisher Skor.....	67
3.5. Sınıflandırma.....	68
3.5.1. KNN, WKNN Yöntemleri.....	69
3.5.2. SVM Yöntemi.....	70
3.5.3. Rastgele Orman Yöntemi.....	72
3.5.4. Naif Bayes Yöntemi.....	73
3.5.5. K-Kat Çapraz Doğrulama.....	74
4. BÖLÜM: BULGULAR VE TARTIŞMA/SONUÇ.....	76
4.1. Geliştirilen Hastane Otomasyon Sistemi.....	76
4.2. Lezyon Tespiti Adımının Başarımının Değerlendirilmesi.....	85
4.3. Sınıflandırma Aşamasının Başarımı.....	86
4.4. Sonuç.....	93
KAYNAKLAR.....	94

TABLO LİSTELERİ

Tablo 1.1. Meme Kanserinin Evreleri.....	3
Tablo 2.1. Literatür araştırması.....	11
Tablo 3.1. Lezyon alt türleri.....	16
Tablo 3.2. Lezyon alt türleri.....	17
Tablo 3.3. Kullanılan yöntemeler ile hesaplanan alan, çevre ve dairesellik değerleri.....	49
Tablo 3.4. Segmentasyon sürecinin lezyon tespiti başarımı.....	53
Tablo 3.5. GLCM özellikleri ve formülleri.....	57
Tablo 3.6. GLDM özellikleri ve formülleri.....	60
Tablo 3.7. Şekil özellikleri ve açıklamaları.....	61
Tablo 3.8. Meme lezyonlarının sınıflandırılması için oluşturulan özellik vektörü.....	64
Tablo 4.1. Segmentasyon sürecinin lezyon tespiti başarımı.....	86
Tablo 4.2 Hata matrisi.....	86
Tablo 4.3. Farklı durumlar için KNN ve SVM sınıflandırma performansları.....	88
Tablo 4.4. Performans karşılaştırma tablosu.....	88
Tablo 4.5. Sınıflandırıcı performansları.....	90
Tablo 4.6. Önerilen çalışmanın karşılaştırmalı analizi.....	91
Tablo 4.7. Dönüşüm uzayı özelliklerinin performansı.....	92
Tablo 4.8. Lezyon alt türlerinde sistem performansı.....	93

ŞEKİL LİSTELERİ

Şekil 1.1: Meme yapısının görünümü.....	2
Şekil 3.1. Meme lezyonlarının tespiti, sınırlarının belirlenmesi ve alanlarının hesaplanması için önerilen üç aşamalı segmentasyon süreci.....	23
Şekil 3.2. Meme ilgili bölge belirleme adımları.....	24
Şekil 3.3. Görüntüdeki merkez bir piksele ait 4 ve 8 komşuluk.....	25
Şekil 3.4. Basit bir bağlı bileşen etiketleme örneği.....	25
Şekil 3.5. (a) Orijinal görüntü, (b) Gürültü filtrelenmiş ve yerel adaptif eşikleme uygulanmış görüntü, (c) Bağlı bileşen analizi uygulanmış görüntü.....	26
Şekil 3.6. Meme bölgesi segmentasyonu, (a) orijinal görüntü, (b) yerel adaptif eşikleme işlemi sonucu, (c) bağlı bileşen analizi sonucu elde edilen iki seviyeli görüntü, (d) meme bölgesi, (e) sol meme bölgesi, (f) sağ meme bölgesi, (g) ve (h) orijinal sol ve sağ meme görüntüsü.....	27
Şekil 3.7. Kötü huylu lezyon bulunan meme MR görüntüsünün farklı seviyelerde Otsu eşikleme yöntemi ile bölütlenmesi.....	32
Şekil 3.8. Bölge büyütme algoritması uygulanmış görüntü.....	33
Şekil 3.9. Kötü huylu lezyon tespit edilmiş meme MR görüntüsünün FCM yöntemi ile kümelenmesi.....	35
Şekil 3.10. k-Ortalama algoritması uygulanmış görüntü (8 Seviye).....	37
Şekil 3.11. (a) Orijinal MR Görüntüsü, (b) MRF ile segmente edilmiş görüntü.....	41
Şekil 3.12. Kötü huylu oldukça küçük bir lezyon içeren bir MR görüntüsü için aktif sınırlar yöntemi (a) Orijinal görüntü, (b) Başlangıç alanı, (c) Tespit edilen bölge, (d) İki seviyeli lezyon görüntüsü.....	43
Şekil 3.13. Otsu ve FCM yöntemleri uygulanmış ve lezyon bölgeleri tespit edilmiş MR görüntüleri.....	44
Şekil 3.14. RG yöntemi uygulanmış MR görüntüsü, (a) Orijinal görüntü, (b) Segmentasyon uygulanmış görüntü, (c) Orijinal görüntüde lezyon bölgesi, (d) İki seviyeli lezyon bölgesi görüntüsü.....	45
Şekil 3.15. Kötü huylu oldukça küçük bir lezyon içeren bir MR görüntüsü için aktif sınırlar yöntemi (a) Orijinal görüntü, (b) Başlangıç alanı, (c) Tespit edilen bölge, (d) İki seviyeli lezyon görüntüsü.....	45
Şekil 3.16. (a) Orijinal meme MR görüntüsü, (b) Otsu 8 seviye eşikleme sonucu elde edilen görüntü, (c) Kötü huylu lezyonun ikili görüntüsü.....	46
Şekil 3.17. (a) Kötü huylu lezyonun iki seviyeli görüntüsü, (b) İki seviyeli görüntüye ait piksel değerleri.....	46

Şekil 3.18. Bit dörtlü desen kümesi.....	48
Şekil 3.19. Segmentasyon adımı tamamlanmış lezyonlar için renk tabakaları (a), (c) ve (e) renk tabakaları, (b), (d) ve (f) manuel olarak işaretlenmiş lezyon bölgeleri.....	50
Şekil 3.20. Segmentasyon adımı tamamlanmış lezyonlar için renk tabakaları (a) Okla işaretlenmiş T2-ağırlıklı yağ baskılı MR görüntüsü, (b) T1-ağırlıklı yağ baskılı kontrast sonrası görüntü, (c) Otsu ve MRF tabanlı hibrit segmentasyon sonucu, (d) segmente edilmiş görüntüye ait renk tabakası.....	51
Şekil 3.21. Segmentasyon adımı tamamlanmış lezyonlar için renk tabakaları (a) Birinci lezyon için okla işaretlenmiş T1-ağırlıklı yağ baskılı MR görüntüsü, (b) İkinci lezyon için T1-ağırlıklı yağ baskılı kontrast sonrası görüntü, (c) k-ortalamlar tabanlı segmentasyon sonucu, (d) segmente edilmiş görüntüye ait renk tabakası.....	52
Şekil 3.22. NGTDM hesaplama: a) 5-seviye segmente edilmiş görüntü, b) NGTDM parametreleri.....	58
Şekil 3.23. Bazı özelliklerin FS değerleri.....	68
Şekil 3.24. KNN yönteminin şekilsel gösterilimi.....	70
Şekil 3.25. SVM'de doğrusal ve doğrusal olmayan karar yüzeyleri.....	72
Şekil 3.26. RF yönteminde ağaç yapısı.....	73
Şekil 3.27. K-kat çapraz doğrulama süreci (k=3).....	75
Şekil 3.28. Karar verme adımı genel yapısı.....	75
Şekil 4.1. Geliştirilen hastane otomasyon sisteminin bütün tabloları.....	77
Şekil 4.2. Üç katmanlı mimari yapısı.....	78
Şekil 4.3. Kullanıcı başlangıç ekranı.....	79
Şekil 4.4. Doktorlar ekranı.....	79
Şekil 4.5. Doktor ekleme, silme ve güncelleme ekranı.....	80
Şekil 4.6. Bölümler ekranı.....	80
Şekil 4.7. Hastalar ekranı.....	81
Şekil 4.8. Hasta ekleme, silme ve güncelleme ekranı.....	81
Şekil 4.9. Randevular ekranı.....	82
Şekil 4.10 Hasta seçimi yapılmış tedaviler ekranı.....	84
Şekil 4.11 Otsu eşikleme ile örnek bir meme MR görüntüsünde lezyon tespiti.....	84
Şekil 4.12. İlk çalışmanın blok diyagram gösterilimi.....	87



Şekil 4.13 İkinci çalışmanın blok diyagramı.....	89
Şekil 4.14. 10-kat çapraz doğrulama için özellik seçme yokken elde edilen doğruluk değerleri.....	89
Şekil 4.15. 10-kat çapraz doğrulama için özellik seçme varken elde edilen doğruluk değerleri.....	90

ÖZET

Projenin amacı, meme kanserinin teşhisinde yaygın olarak tercih edilen manyetik rezonans görüntüleme sistemi üzerinden alınan görüntüleri kullanarak yazılım tabanlı bir meme lezyon tespit ve sınıflandırma sistemi geliştirmektir. Geliştirilen sistem uzmanlar için yazılım tabanlı bir karar destek sistemi olarak düşünülebilir. Belirtilen amaca ulaşmak için sistemde beş temel adım gerçekleştirilmiştir. Bu adımlardan her biri çeşitli işaret işleme ve görüntü işleme yöntemleri içermektedir.

Projede gerçekleştirilen beş temel adım sırasıyla veri tabanı oluşturulması, meme lezyonlarının tespit edilmesi, lezyon özelliklerinin çıkarılması, en etkili özelliklerin belirlenmesi ve karar adımlarıdır. Veri tabanı oluşturulması adımı uzman eşliğinde MRG cihazı ile yapılan çekimlerden en uygun görüntüler seçilmiştir. Ayrıca, görüntüde oluşabilecek bozunumları gidermek için filtre tabanlı bir ön işleme adımı uygulanmıştır. Daha sonra, meme lezyonlarının tespit edilmesi amacıyla iki aşamalı bir segmentasyon süreci uygulanmıştır. İlk aşama lezyon içerebilecek meme bölgesinin tespit edilmesi, ikinci aşama meme bölgesinden lezyonun bulunduğu bölgenin elde edilmesidir. Meme bölgesi tespitinde yerel adaptif eşikleme, bağlı bileşen analizi, yatay iz düşüm ve maskeleme teknikleri sırasıyla kullanılmıştır. Lezyon tespiti için Otsu, bölge büyütme, bulanık c-ortalamlar, k-ortalamlar, aktif sınırlar ve Markov rastgele alanlar yöntemleri görüntüleme uygulanmıştır. Lezyonlara ait özelliklerin çıkarılması adımı ise histogram, şekil, doku ve dönüşüm uzayı özellikleri hesaplanmıştır. Toplamda her bir lezyon için 108 özellik belirlenmiş ve özellik seçme adımı etkisi az olan özellikler Fisher skoru yöntemi ile özellik vektöründen atılmıştır. Projenin son adımı karar aşaması olan sınıflandırma adımıdır. Bu adımda k en yakın komşuluk, destek vektör makineleri, rastgele orman, naif Bayes teknikleri kullanılmıştır.

Elde edilen sonuçlara göre proje kapsamında hazırlanan yazılım meme lezyonlarının tespitinde $91 \pm 0,06$, iyi huylu kötü huylu lezyon ayrımında $90,36 \pm 0,069$, lezyon alt gruplarının ayrımında ise $84,3 \pm 0,24$ doğruluk sağlamıştır.

Anahtar Kelimeler: Meme kanseri, lezyon tespiti, segmentasyon, özellik çıkarma, özellik seçme, lezyon sınıflandırma.

ABSTRACT

The aim of the project is to develop a software-based breast lesion detection and classification system by using images taken from magnetic resonance imaging system that is a commonly preferred system for breast cancer diagnosis. The developed system can be referred as to a decision-support system for specialists. To reach the given target, five main steps are performed. Each of these steps includes several signal processing and image processing methods.

Five steps performed in the project are database construction, breast lesion detection, lesion feature extraction, selection of the most effective features and decision steps. In database construction step, the most appropriate images taken from the MRI device are selected together with the specialist. In addition, a filtering-based preprocessing step is applied to the images to eliminate the possible artifacts. Then, a two-stage segmentation process is applied for breast lesion detection. The first stage is to detect breast region that may include lesion, and the second step is to obtain the lesion region from the breast region. Local adaptive thresholding, connected component analysis, integral of horizontal projection and masking techniques are used for breast region detection. Otsu, region growing, fuzzy c-means, k-means, active contours, and Markov random fields methods are applied to images for lesion detection. In lesion feature extraction step, histogram, shape, texture, and transform domain features are calculated. Totally 108 features are determined for each lesion and the least effective features are discharged from the feature vector by using Fisher score method. The last step of the project is classification/decision step. In this step, k-nearest neighbor, support vector machines, random forest, naïve Bayes techniques are utilized.

According to the achieved results, the software developed in the project provides $91\pm 0,06\%$ accuracy for lesion detection, $90,36\pm 0,069\%$ accuracy for separation of benign and malignant lesions and, $84,3\pm 0,24\%$ accuracy for separation of lesion subgroups from each other.

Keywords: Breast cancer, lesion detection, segmentation, feature extraction, feature selection, lesion classification.



1. BÖLÜM: GİRİŞ

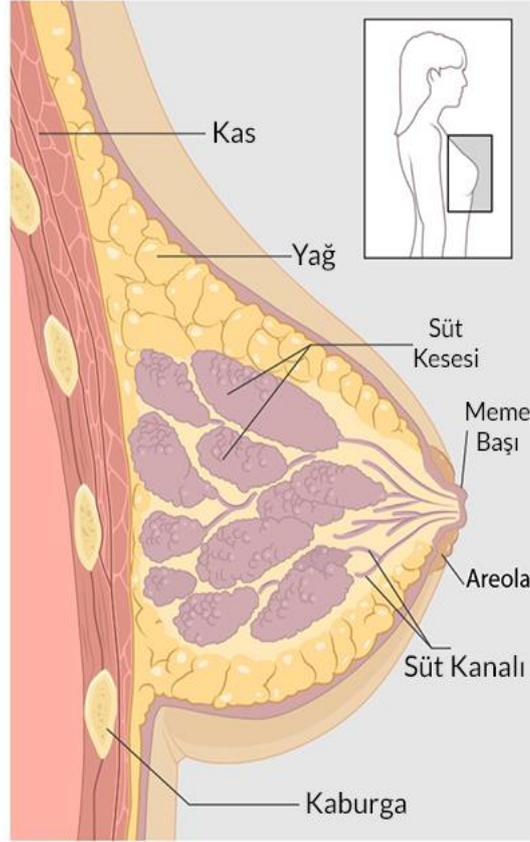
Kanser Araştırmaları Dünya Sağlık Örgütü Uluslararası Ajansı'nın elde ettiği verilere göre, meme kanseri tüm dünyada kadınlarda en yaygın olarak karşılaşılan bir kanser türüdür. Gelişmiş ülkelerde 636.000, gelişmekte olan ülkelerde ise yaklaşık 514.000 kadın meme kanserine yakalanmıştır [1, 2]. Ayrıca birçok ülkede kadınlarda kanserle ilgili ölümlerin en önemli nedeni meme kanseridir ve sayı yaklaşık olarak 519.000'dir. Türkiye'de ise T.C. Sağlık Bakanlığı, Türkiye Kanser İstatistikleri verisine göre kadınlarda en sık görülen kanser olan meme kanseri, her 4 kadından birinde görülmeye devam etmekte ve kadınlarda görülen tüm kanserlerin yaklaşık %30'unu oluşturmaktadır. Bir yıl içinde toplam 17.531 kadına meme kanseri teşhisi konulmuştur [2].

Meme kanserini tanımlamak gerekirse, meme hücrelerinin kontrolsüzce büyümesi olarak genel bir ifade kullanılabilir. Ancak meme kanserini daha iyi anlamak için bir kanser hücresinin nasıl geliştiğini öğrenmek bize daha fazla yarar sağlayacaktır. Kanser mutasyon, anormal değişiklikler, hücrelerin büyümesini düzenleyen ve onları sağlıklı tutan genlerde değişikliklerin meydana gelmesi ile oluşmaktadır. Genler, her hücrenin çekirdeğinde bulunmaktadır ve hücrelerin "kontrol odası" olarak işlev görmektedir. Normalde, vücudumuzdaki hücreler düzgün bir hücre büyümesi süreciyle, yaşlı hücreler ölürken sağlıklı yeni hücreler onların yerini alarak kendilerini yenileme düzenini takip etmektedir. Fakat zamanla, mutasyonlar bir hücrede bazı genleri oluşturabilir ya da yok edebilir boyuta gelmektedir. Bu değişen hücreler, kontrolü ve düzeni bozmadan bölünmeyi sürdürebilme yeteneği kazanır, tıpkı mevcut genler gibi daha fazla hücre üretebilir ve bir tümör oluşturabilir duruma gelmektedir.

Bir tümör, sağlık için tehlikeli olmayan iyi huylu "benign" veya potansiyel tehlike olan kötü huylu "malign" dan oluşabilmektedir. İyi huylu tümör kanser hücresi olarak düşünülmemektedir. Çünkü bu hücreler normal hücre görüntüsüne yakın bir görünüm sergilemekte, yavaş büyümekte ve bu hücreler yakın dokuları ele geçirmemekte veya vücudun başka bir bölümüne yayılmamaktadırlar. Kötü huylu tümör ise bir kanserdir. Kontrolsüz bırakıldıklarında, kötü huylu hücreler er geç mevcut bulunan tümörün ötesine geçerek vücudun diğer bölümlerine yayılabilmektedir.

Meme kanseri terimi, meme hücrelerinde gelişen kötü huylu tümöre karşılık gelmektedir. Genellikle meme kanseri ya süt üretme hücrelerinde ya da sütü, süt üretme bezesinden meme ucuna taşıyan bölüm de başlamaktadır. Daha az oranla da meme kanseri, göğsün yağlı ve lifli bağ dokularını içeren ana (stromal) dokularında da başlayabilmektedir.

Şekil 1.1: Meme yapısının görünümü [3]



Kanser hücreleri zamanla sağlıklı göğüs dokusuna ve vücuda dışarıdan gelecek yabancı maddeleri filtreleyen koltuk altı lenf düğümlerine (nodlarına) yayılabilmektedir. Eğer kanser hücreleri lenf düğümlerine bir giriş sağlarsa, daha sonra vücudun diğer kısımlarına doğru bir yol izleyebilmektedir. Meme kanseri evresi, kanser hücrelerinin mevcut tümörün ne kadar ötesine yayılmış olduğu tespit edilerek belirlenmektedir. Meme kanseri evreleri Tablo 1.1.'de gösterilmiştir [3].

Tablo 1.1. Meme Kanserinin Evreleri [4].

Evre	Açıklama
Evre 0	Kanser hücreleri göğüs kanalının içinde, çevresindeki meme dokusuna girmeden kalmışsa
Evre 1A	Tümör boyutu 2 cm üzerindeyse ve kanser memenin dışına yayılmamışsa; lenf düğümü oluşmamışsa
Evre 1B	Memede tümör yoksa onun yerine 0.2 milimetreden daha büyük ve 2 milimetreden büyük olmayan, küçük kanser hücre grupları lenf düğümlerinde bulunursa / Memede 2 santimetreden büyük olmayan bir tümör varsa ve 0.2 milimetreden daha büyük ve 2 milimetreden büyük olmayan, küçük kanser hücre grupları lenf düğümlerinde bulunursa
Evre 2A	Memede tümör bulunmuyor ancak kanser hücreleri aksiler lenf düğümlerinde bulunuyorsa / Tümör 2 santimetre veya daha küçük ölçülüyor ve aksiler lenf düğümlerine yayılmışsa / Tümör 2 santimden büyük ancak 5 santimden küçük ve aksiler lenf düğümlerine yayılmamışsa
Evre 2B	Tümör 2 santimden büyük ancak 5 santimden küçük ve aksiler lenf düğümlerine yayılmışsa / Tümör 5 santimden büyük ancak aksiler lenf düğümlerine yayılmamışsa
Evre 3A	Memede tümör bulunmamaktadır. Kanser, birbirine yapışan aksiler lenf düğümlerinde veya başka yapılarda bulunuyorsa veya göğüs kemiğine yakın lenf bezlerinde kanser bulunuyorsa / Tümör herhangi bir boyuttadır. Kanser birbirine yapışan aksiler lenf düğümlerine veya diğer yapılara yayılmışsa veya göğüs kemiğine yakın lenf düğümlerinde kanser bulunuyorsa
Evre 3B	Tümör herhangi bir boyutta olabilir ve göğüs duvarına ve/veya memeye yayılmışsa ve kümelenmişse veya diğer yapılara yapışan aksiler lenf düğümlerine yayılmışsa veya kanser göğüs kemiğine yakın lenf düğümlerine yayılmışsa
Evre 3C	Memede kanser işaretçisi yoksa ya da tümör herhangi bir büyüklükte olup göğüs yüzeyine yayılmışsa / kanser köprücük kemiğinin altında ya da üstünde lenf düğümlerine yayılmışsa / kanser aksiler lenf düğümüne ya da göğüs kafesinin yakınlarındaki lenf düğümlerine yayılmışsa
Evre 4	Kanser vücudun diğer bölümlerine yayılmışsa (veya metastaz yapmışsa)

Meme kanseri genellikle genetik bozukluklardan meydana gelmektedir. Kanserin sadece %5-10'u anne veya babadan gelen kalıtsal bir anormallikten kaynaklanmaktadır. Meme kanseri riskini azaltmak için dengeli bir diyetle beslenme, vücut için uygun kiloyu sürdürebilme, sigara içmeme, alkolü sınırlandırma ve düzenli egzersiz yapma gibi vücudun olabildiğince sağlıklı kalmasına yardımcı olacak her bireyin atabileceği adımlar vardır. Bunlar, meme kanseri olma riski üzerinde bir etki sahibi olsa da, riski tamamen ortadan kaldıramazlar. Meme kanseri için risk faktörleri aşağıda açıklanmıştır:

- a. Cinsiyet: Kadın olmak meme kanserine yakalanma bakımından en büyük risk faktörüdür. Kadınlar ve erkeklerin meme kanserine yakalanma farklılıkları, kadınların meme hücrelerinin ilk doğuma kadar olan süreçte aktif durumda olmasından ve çalışma fonksiyonuna dışarıdan gelebilecek herhangi bir duruma karşı duyarlı olmasından kaynaklanmaktadır.
- b. Yaş: Yaş meme kanserine yakalanma riski açısından önem taşıyan faktörlerden biridir. Her insan zamanla yaşlanır ve diğer birçok hastalıkta olduğu gibi meme kanserinde de yaş ilerledikçe risk artar. Bunun nedeni ileri yaşlarda vücutta genetik hasar oluşması için daha fazla, hasarı tamir etme açısından daha az unsur oluşmasıdır.
- c. Akrabalık: Meme kanseri teşhisi konmuş yakın akrabaya sahip kişilerde meme kanserine yakalanma riski akrabalık derecesi arttıkça artmaktadır.
- d. Genetik: Meme kanserine yakalanma sebeplerinin %5-10'u ana-babadan gelen anormal genlerin yol açtığı kalıtsal sorunlar olarak görülmektedir. Genlerimizi, hücre büyümesi ve işlevi için bir kullanım kılavuzu olarak düşünürsek, genlerde oluşabilecek hatalar o işlevi gerçekleştiren hücrelerde önemli sorunlara neden olacaktır. Ana-babadan aktarılan genlerde de bir anormallik meydana geldiğinde bu bozukluk dünyaya gelen yeni bireye aktarılır ve bu şekilde devam eder.
- e. Kişisel Geçmiş: Birey göğüs kanseri tanısı aldıysa, diğer göğüste veya aynı göğsün diğer bölümlerinde de kanser oluşturma riski ile karşı karşıya kalabilir.
- f. Yüze veya Göğse Radyasyon: 30 yaşından önce akne tedavisi gibi yüze veya göğüs bölgesine radyasyon alan bireylerde meme kanserine yakalanma riski daha yüksektir.
- g. Göğüste Oluşan Değişimler: İyi huylu lezyon bulunan bazı bireylerde meme kanserine yakalanma riski diğer bireylere kıyasla daha yüksektir. İyi huylu lezyonların bazı türleri anormal büyüme göstererek zamanla tümör görünümü alabilmektedir.
- h. Irk/Etnik: Yapılan çeşitli araştırmalarla beyaz tenli kadınlarda meme kanserine yakalanma riskinin daha yüksek olduğu kanıtlanmıştır.

- i. Aşırı Kilo: Aşırı kilolu olmak kadınlarda meme kanseri riskini arttırabilir. Bunun sebebi yağ hücrelerinin östrojen üretmesinden kaynaklanmaktadır. Östrojen hormonu reseptörü meme kanseri oluşturabilmektedir.
- j. Hamilelik Geçmiş: Göğüs hücreleri ergenlik çağından, ilk hamile olana kadar geçen sürede olgunlaşmamıştır ve çok aktiftir. Olgunlaşmamış göğüs hücreleri, hormon bozucu kimyasalların yanı sıra östrojen hormonuna tepki verirler. İlk tam süreli hamilelik meme hücrelerini tamamen olgunlaştırır ve daha düzenli bir şekilde büyütür. Hamileliğin meme kanserine karşı korunmasında etkili olmasının temel nedeni budur. İlk tam süreli hamilelik dönemine kadar meme kanserine yakalanma riski daha yüksektir.
- k. Emzirme Geçmiş: Emzirme, meme kanseri riskini azaltır. Çünkü göğsün süt üretmesi, meme hücrelerinin yanlış işleyebilme durumunu sınırlamaktadır. Emzirirken çoğu kadının adet dönemleri daha azdır ve dolayısıyla östrojen hormonlarının seviyesi azalır.
- l. Adet Geçmiş: 12 yaşından küçük adet görmeye başlayan kadınlar hayatları boyunca meme kanseri açısından daha yüksek risk altındadırlar. Bu durum, 55 yaşından büyük menopoz geçiren kadınlar için de geçerlidir. Son 15 yılda kızlar genç yaşlarda ergenlik dönemine girmektedir. Bu nedenle, meme gelişimi adet dönemlerinden daha erken başlamıştır. Göğüs oluşumunun erken başlaması, vücut içindeki ve dışındaki hormonların yanı sıra hormon bozucu olan ürünlerdeki kimyasallarla etkileşimi de artırır. Bu hormonlar ve hormon bozucular ile uzun süreli etkileşim, meme kanseri riskini arttırabilmektedir.
- m. Hormon Değişim Terapisi: Hormon değişim terapisini, birçok kadın menopoz belirtilerini (sıcak basması, yorgunluk) hafifletmek ve kemik kaybını azaltmak için kullanmaktadır. Bu terapinin, östrojen ve progesteron hormonlarının ikisini veya sadece östrojen hormonunu kapsayan iki türü vardır. Bu terapiyi şimdi veya yakın geçmişte olan bireylerin kanseri tanısı alma riski yüksektir.
- n. Alkol Alımı: Alkollü içecekler kullanmanın meme kanseri riskini arttırdığı ispatlanmış bir gerçektir. Alkol, meme kanseri ile ilişkili olan östrojen ve diğer hormonların düzeylerini arttırabilmektedir. Ayrıca, hücrelerdeki DNA'ya zarar vermek suretiyle kanser oluşumunu tetiklemektedir.
- o. Dokusu Yoğun Göğüsler: Göğüs kanseri riski, meme yoğunluğunun yani meme dokusunun yağ dokusuna oranla artması ile ortaya çıkmaktadır. Mamografi ile değerlendirilen daha yoğun göğüslere sahip kadınlarda göğüs kanseri geliştirme riski 3-6 kat daha fazladır. Bu nedenle radyologlar tarafından kullanılan sistemler göğüs yoğunluğunun değerlendirilmesini de içermektedir. Meme görüntüleme, değerlendirme, raporlama ve izlemde standart oluşturmak için Amerika Radyoloji

Koleji (ACR) tarafından Breast Imaging and Reporting Data System sözcüklerinin ilk harflerinden oluşan BIRADS sistemi geliştirilmiştir. Bu sistem lezyon değerlendirme, iletişim ve arşivlemede büyük kolaylıklar sağlayarak radyologlar tarafından yaygın olarak kullanılmaktadır. BI-RADS meme yoğunluğunu dört gruba ayırır:

- Çoğunlukla yağlı: Göğüsler çoğunlukla yağdan oluşur ve az lifli, glandüler doku içeriyor ise mamografinin muhtemelen anormal bir şeyi göstereceği anlamına gelmektedir.
 - Dağılmış yoğunluk: Göğüslerde biraz yağ var, ancak birkaç lifli ve glandüler doku alanı bulunmaktadır.
 - Tutarlı yoğunluk: Göğüsler, meme yoluyla eşit olarak dağılan birçok lifli ve glandüler doku alanlarına sahiptir. Bu durum memedeki küçük kitlelerin görülmesini zorlaştırabilmektedir.
 - Aşırı yoğun: Göğüslerin lifli ve glandüler dokusu vardır. Kanseri, normal doku ile kaynaşabildiği için mamografide bir kanseri görmek zorlaşabilir.
- p. Egzersiz Eksikliği: Düzenli şekilde fiziksel olarak aktif olan kadınların, rutin hayat sürdüren kadınlarla kıyaslandığında hastalığa yakalanma riskinin daha düşük olduğu kabul edilmektedir. Düzenli olarak yapılan egzersiz, bir kadının ilk adet dönemini erteleyebilir, kilo kontrolünü kolaylaştırabilir veya düzenli adet döngüsü sıklığını azaltabilmektedir. Bu sayede bir kadının ömrü boyunca maruz kaldığı toplam östrojen miktarını azaltarak kansere yakalanma riskini azaltabilmektedir.
- q. Sigara: Sigara tüketimi birçok hastalığa neden olduğu gibi meme kanseri olma riskini de arttırmaktadır [4, 5].

Özetle, kadınlarda meme tümörüne neden olan risk faktörleri, hormonlar, genetik, ilk hamilelik yaşı, hamilelik sayısı, hormon tedavisi (HRT), meme yoğunluğu, yaş, obezite, sigara veya alkol kullanımı, gece çalışma, menopoza, ilk adet, kullanılan ilaçlar vb. şeklinde sıralanabilir. Bunların arasından, meme yoğunluğu meme kanserinin en önemli risk faktörü olarak düşünülür. Temel olarak meme yoğunluğu, memedeki fibroglandüler doku miktarının yağ dokusu miktarı ile bağlı karşılaştırılması ile elde edilir. Yoğun memeye sahip kadınların fibroz doku yüzdesi yüksek ve yağ dokusu düşüktür. Son zamanlarda, meme dokusu sınıflandırmak için geliştirilen birçok yaklaşım sunulmuştur. Yapılan araştırmalarda meme yoğunluğu ile meme kanser riski olasılığı arasında bir ilişki olduğu ortaya çıkmıştır [6].



2. BÖLÜM: LİTERATÜR ARAŞTIRMASI

Bu bölümde, Dinamik Kontrastlı Manyetik Rezonans Görüntüleme (Dynamic Contrast Enhanced Magnetic Resonance Imaging, DCE-MRI) kullanılarak meme kanseri analizi için geliştirilen ve uygulanan son teknoloji yöntemlerin sistematik bir literatür taraması yapılmıştır. Literatür taraması yapılırken, radyologları desteklemek amacıyla örüntü tanıma çerçevesinde geliştirilen çalışmalar dikkatle incelenmiştir. Her bir çalışma için meme lezyonu segmentasyonu (bölütleme), özellik çıkarma, özellik seçme ve sınıflandırma tekniklerinin kullanılıp kullanılmadığı kullanıldıysa hangi yöntemlerin uygulandığı tespit edilmiştir. Geçmişten günümüze kadar olan çalışmalar aşağıda verilen tabloda özetlenmiştir. Tablonun daha iyi anlaşılması şu açıklamalar yapılmıştır:

Segmentasyon adımı, meme lezyonu tespit ve tanı sistemlerinin ana basamağıdır. Bu adım, hareket bozunumlarının giderilmesi, gürültü azaltma ve ilgili olmayan dokunun elimine edilmesinden sonra tıbbi görüntüye uygulanmaktadır. Bu adımda amaç, lezyon bölgelerini olabildiğince net olarak belirlemektir. Tablo 2.1'de verilen segmentasyon incelemesi yapılırken öncelikle segmentasyon adımının uygulanıp uygulanmadığı incelenmiş uygulandıysa uygulanış şekli manuel, yarı otomatik ve otomatik olarak üç kategoriye ayrılmıştır.

Yapılan incelemelere göre, çalışmaların bir bölümünde segmentasyon adımı manuel olarak bir uzman tarafından gerçekleştirilmiştir. Yarı otomatik segmentasyon yöntemi, lezyon tespitini başlatmak için bir dış müdahaleye (çekirdek noktası belirleme gibi) ihtiyaç duymaktadır. Tam otomatik segmentasyon yöntemlerinde ise sisteme müdahale etmeye gerek yoktur. Çekirdek noktası veya bölgenin belirlenmesi segmentasyon yöntemi ile otomatik olarak elde edilmektedir. Lezyon tespiti veya lezyon sınıflandırması için gerekli segmentasyon tekniklerinden kısaca şu şekilde özetlenebilir: Lezyon bölgesini öne çıkarmanın en basit yolu eşiklemedir. Otsu yöntemi, tıbbi görüntü segmentasyonunda iyi sonuçlar veren adaptif eşikleme tabanlı yöntemlerden biridir. Literatürdeki çalışmaların bazıları, segmentasyon adımını meme bölgesini içeren ilgili bölge (Region of Interest, ROI) belirleyerek gerçekleştirir. Göğüs Duvarı Çizgisi (Chest Wall Line, CWL) ve En Şüpheli Bölge (Most Suspect Region, MSR) yöntemleri, otomatik ROI tespitine dayanan bir meme lezyonu bölgesi bulmayı amaçlamaktadır. Şablon Eşleştirme (Template Matching, TM), segmentasyon işlemine başlamadan önce bir uzman yardımı ile göğüs bölgesini segmente etmenin başka bir yoludur. Ancak, şablonları oluşturmak oldukça zaman alıcı bir işlemdir. Bu nedenle şablon eşleştirme tabanlı segmentasyon teknikleri çok fazla tercih edilmemektedir. Yinelemeli geometrik tabanlı algoritma kullanan teknikler, Bölge Büyütme (Region Growing, RG), Grafik Kesme (Graph Cuts, GC), Havza (Watershed, WS), Gradyan

Vektör Akışı (Gradient Vector Flow, GVF) ve Magnetostatik yılan (Magnetostatic snake model, M-snake) modelleridir. Diğer teknikler denetimli ve denetimsiz yöntemler olarak isimlendirilmektedir. Denetimsiz teknikler k-ortalamar (k-means) , Vektör Kuantalama (Vector Quantization, VQ), Bulanık C-ortalamar (Fuzzy C-means, FCM) ve Ortalama Kaydırma (mean shift). Regresyon ve sınıflandırma yöntemlerine göre gruplandırılabilen denetimli yöntemler ise, Lojistik Regresyon Analizi (Logistic Regression Analysis, LRA), Doğrusal Ayırıcı Analiz (Linear Discriminant Analysis, LDA), Yapay, Hüresel, Geri beslemeli, Darbe Bağlantılı ve Çok Katmanlı Geri Yayılımlı Sinir Ağları (Artificial, Cellular, Backpropagation, Pulse-Coupled and Multilayer Perceptron Neural Networks, ANN, CNN, BNN, PCNN, MLPNN), Karar Ağacı (Decision Tree, DT), Olasılık Artırıcı Ağaç (Probabilistic Boosting Tree, PBT), k-en yakın komşuluk (K-nearest neighborhood, k-NN), En Küçük Kareler Destek Vektör Makineleri (Least-Squares Support Vector Machines, LS-SVM), ve Markov Rastgele Alanlar (Markov Random Field, MRF) teknikleridir. Literatürde optimizasyona dayalı segmentasyon çalışmaları da yer almaktadır. Karınca ve arı sürüsü kolonisi optimizasyon teknikleri örnek olarak verilebilir. Ayrıca, son yıllarda derin öğrenmeye dayalı yaklaşımlar, çeşitli disiplinlerdeki çalışmalarda olduğu gibi bu alanda da dikkat çekmektedir. Ancak derin öğrenmeye dayalı yöntemler geniş bir veri tabanı gerektirdiğinden gerçekleştirmek zordur.

Sistemin ikinci ana basamağı, meme lezyonlarının mevcut özellikleri ile temsil edildiği özellik çıkarma adımıdır. Dinamik özellikler (Dynamic features, DYN), kontrast madde alımından sonraki zamana karşı sinyal yoğunluğu değerlerini gösteren zaman yoğunluğu eğrisinin zamansal kinetiğini temsil etmektedir. Dokusal özellikler (Textural features, TXT), bir görüntüyü segmente etmede ve segmente edilen görüntüyü sınıflandırmada kullanılmaktadır. Bu özellikler sınırlı bir bölgedeki bağıl homojenliği ölçen uzamsal özelliklerdir. Bazı çalışmalarda morfolojik veya şekil özellikleri olarak da isimlendirilen geometrik özellikler (Geometrical features, GEO), lezyonu teşhis etmek için yaygın olarak kullanılmıştır. Farmakokinetik özellikler (Pharmacokinetic features, PKF), ilgili bölgedeki dokunun kontrast madde alımını modellemektedir. Farmakokinetik modellerin fizyolojik parametreleri temel olarak doku perfüzyonu, vasküler geçirgenlik ve hücre dışı hacim fraksiyonu ile ilgilidir.

Özellik çıkarma adımından sonra uygulanabilen özellik seçme adımının amacı, hesap karmaşıklığını azaltırken, sınıflandırıcının karar performansını arttırmaktır. Bu nedenle, Tablo 2.1'de verilen çalışmaların bazıları özellik vektörünün etkisiz özelliklerini ortadan kaldırarak özellik vektörünün boyutunu azaltmak için özellik seçim yöntemlerini kullanmaktadırlar. Bu teknikler arasında, LDA ve LRA sınıflandırma için de kullanılmaktadır.

En popüler özellik seçim yöntemlerinden bazıları Korelasyona Dayalı Özellik Altkümesi Seçimi (Correlation-Based Feature Subset Selection, CBFS), Fisher Doğrusal Ayırmacılık (Fisher Linear Discriminant, FLD), Ortalama Korelasyon Katsayısı (Average Correlation Coefficient, ACC), Genetik Algoritma (Genetic Algorithm, GA), T-Testi, Sıralama Tabanlı (Ranking Based, RB) ve Ortak Bilgi (Mutual Information, MI) tekniklerdir. Bunların dışında, sınıflandırıcı ve özellik seçme süreci arasındaki geri bildirim mekanizmasını göz önünde bulunduran Sınıflandırma Hata Olasılığı (Probability of Classification Error, PCE) yöntemi de aynı amaç için kullanılabilir. Birkaç çalışmada ise özellik vektörüne birden fazla özellik seçim aşaması uygulanmıştır.

Örüntü tanıma çerçevesinde geliştirilen sistemlerin son aşaması, ayırt edici özellikleri belirlenen lezyonları sınıflandırmaktır. Sınıflandırma tekniklerinin çoğu segmentasyon ve özellik çıkarma bölümünde verilmiştir. Bunların dışında, Kuadratik Ayırıcı Analiz (Quadratic Discriminant Analysis, QDA), Naif Bayes (Naïve Bayes, NB), Temel Bileşen Analizi (Principal Component Analysis, PCA) ve Üç İyi-Seçilmiş Zaman Noktası (Three Well-Chosen Time Point, 3TP) teknikleri de sınıflandırma için kullanılmıştır. Bu tekniklere ek olarak, araştırmacılar tarafından bir ROCKIT yazılım paketi de kullanılmıştır.

Verilen tablodan ve yapılan açıklamalardan görüldüğü gibi, proje kapsamında oldukça detaylı bir literatür analizi yapılmıştır. Bu analiz sonucunda meme lezyonlarının teşhisi ve sınıflandırılması için geliştirilen sistemin sahip olması gereken özellikler belirlenmiştir. Buna göre, segmentasyon adımı mümkün olduğunca kullanıcı etkileşimi ortadan kalkacak şekilde otomatikleştirilmiş bir adım geliştirilmelidir. Lezyon sınırlarını en doğru şekilde belirleyecek ayrıca birden fazla lezyon olduğunda tüm lezyonları tespit edebilecek doğru yöntemler seçilmelidir. Lezyon tespitinde özellikle aksiyel görüntüler kullanıldığında karşımıza çıkan kalp, göğüs bölgesi, kollar gibi bölgelerin elimine edilmesi şarttır. Aksi durumda sistemin yalancı pozitif oranı yükselmektedir.

Özellik çıkarma adımı mevcut sistemin kullandığı özelliklere ek ayırt edici özellikler belirlenmelidir. Bu özellikler kolay hesaplanabilir ve sınıflandırma performansının yükselmesinde etkili özellikler olmalıdır. Özellik çıkarma adımı mümkünse özellik seçme adımı ile izlenmelidir. Özellik seçme adımı, amaç sınıflandırıcının performansını düşüren etkisiz özelliklerin belirlenerek özellik vektörünün boyutunun yeniden ayarlanmasını sağlamaktır. Bu sayede performans yükselirken sistemin hızının da artması beklenmektedir.



Son adım olan sınıflandırma adımında öncelikli hedef tespit edilen bölgelerin lezyon olup olmadığına karar vermektir. Daha sonra lezyonlar iyi huylu (benign) ve kötü huylu (malignant) olarak sınıflandırılırlar. Sunulan çalışmaların çoğu lezyonların iyi huylu kötü huylu ayrımının gerçekleştirilmesini hedeflemiştir. Ancak iyi huylu ve kötü huylu lezyonların sıklıkla karşılaşılan alt sınıflarının da belirlenmesi teşhis açısından önem taşımaktadır. Bu tespitler ışığında projenin aşamaları izleyen bölümlerde detayları ile açıklanmıştır.

Tablo 2.1. Literatür araştırması

Ref No	Yıl	Segmentasyon			Özellik Çıkarma		Özellik Seçme		Sınıflandırma	
		Hayır	Evet		Hayır	Evet	Hayır	Evet	Hayır	Evet
			M	SA						
[7]	2018			FCM	X		X		X	
[8]	2018	X				DYN	X			SVM
[9]	2017			FCM		DYN	X			SVM
[10]	2016			FCM	X		X		X	
[11]	2016	X				TXT	X			kNN
[12]	2016	X				TXT	X			LDA
[13]	2016		X			DYN, GEO	X			QDA
[14]	2016	X			X		X			Deep Learning
[15]	2015			ROI, FCM		PKF		GA		X
[16]	2015		WS, RG		X		X		X	
[17]	2015		X			DYN	X			SVM
[18]	2015		X		X		X			SVM
[19]	2015			Otsu		DYN, TXT		CBFS		NB, DT, SVM
[20]	2014			Ant-based		TXT, GEO	X			MLP NN
[21]	2014			FCM	X		X		X	
[22]	2014			Seeded RG	X		X		X	
[23]	2014			FCM		DYN, TXT, GEO	X			LRA
[24]	2014			FCM	X		X		X	

[25]	2014		FCM, GVF Snake		DYN, TXT, GEO		CBFS	SVM
[26]	2013			TM	X		X	X
[27]	2013	X			DYN		X	LDA
[28]	2013			CWL	X		X	X
[29]	2013			SVM	X		X	X
[30]	2013	X			GEO, TXT		T-test	SVM ANN
[31]	2013			SBC	TXT		T-test	ANN MLP LDA
[32]	2013			FCM	TXT		MI	SVM
[33]	2013			MS, GC	X		X	X
[34]	2013			MSR	DYN, GEO		X	DT
[35]	2012			RG	X		X	X
[36]	2012			FCM	TXT		MI	kNN SVM
[37]	2012			PCN N	DYN		X	SVM
[38]	2012	X			DYN, GEO		X	Bayes DT
[39]	2011			Otsu	X		X	X
[40]	2011			RFC M	X		X	X
[41]	2011	X			DYN, TXT, GEO		X	PBT SVM
[42]	2010			Otsu	X		X	X
[43]	2010			FCM	DYN, TXT		X	LS- SVM

[44]	2010	X		TXT		TFS	SVM
[45]	2010		FCM	DYN, TXT, GEO		LDA	Bayes
[46]	2010	X		DYN	X		SVM
[47]	2009		GC	DYN, TXT		RB	LDA FLD
[48]	2009		FCM	DYN, TXT, GEO	X		ANN
[49]	2009	X		TXT, GEO		LRA	ANN
[50]	2009		Otsu	DYN	X		LS- SVM
[51]	2009	X		DYN	X		PCA
[52]	2009		MAC	DYN, TXT, GEO	X		SVM
[53]	2008		FCM	DYN	X		SVM kNN
[54]	2008	X		TXT		Fisher, POE+ ACC	kNN ANN
[55]	2008		RG	DYN	X		3TP
[56]	2008		CNN , 3D - TM	X	X	X	
[57]	2007	X		TXT	X		NN
[58]	2007		RG	DYN, TXT, GEO		Tooldi ag Packa ge	BNN
[59]	2006		PCA	DYN, GEO	X		LRA

[60]	2006		RG		DYN	X		VQ
[61]	2006			FCM	DYN	X		ROCKI T
[62]	2005			k- Mea ns, MRF	X		X	X
[63]	2004		Thresho ld		GEO	X		BNN
[64]	2003	X			DYN, GEO	X		ANN
[65]	2003		Thresho ld		DYN, GEO, TXT	X		NN, Bayes
[66]	2002			ANN	X		X	ANN
[67]	2001	X			DYN	X		ANN
[68]	2001	X			X		X	BNN

* M: Manuel (Manual), SA: Yarı otomatik (Semi-automatic), A: Otomatik (Automatic).



3. BÖLÜM: GEREÇ VE YÖNTEM

Bu bölümde amacımız projenin ana gövdesini oluşturan teknikleri açıklamak, oluşturulan veri seti hakkında detaylı bilgi vermek ve projenin daha iyi anlaşılabilmesi için gerekli alt yapıyı oluşturmaktır.

3.1. Veri Seti Oluşturma

Projede kullanılan veri tabanı etik izin çerçevesinde Sakarya Üniversitesi Eğitim Araştırma Hastanesi Radyoloji Bölümü'nden alınmıştır. Çalışmamız radyoloji kliniğine meme MR istemiyle yönlendirilmiş, standart çekimleri yapılmış hastaların görüntülerinin retrospektif görüntüleme esasına dayanmaktadır. Uygun pozisyon verilmiş, hareket artefaktları olmayan veya minimum olan görüntüler çalışmaya dâhil edilmeye çalışılmıştır. MR görüntüleri hastanede kullanılan 1.5 Tesla GE Healthcare-Signa Voyager cihazı ile çekilen rutin sekanslardan kesit kalınlığı 4mm'yi geçmeyecek şekilde alınmıştır. 1.5 Teslalık MR cihazımızda standart alınan görüntüler yağ baskılı-baskısız T2 ağırlıklı axial-sagittal, T1 gradient echo, diffüzyon inceleme ve 6 fazlı dinamik gadolinyum kontrastlı incelemeleri ve iş istasyonunda oluşturulan kontrastlanma eğrilerini içermektedir. MR görüntüleme bulguları ile BIRADS sınıflandırmasına göre tanı konan lezyonlar çalışma sonucunda hastalardan yapılan histopatolojik inceleme sonuçları ile karşılaştırılmıştır.

Veri tabanı 74 kötü huylu 23 iyi huylu lezyondan oluşmaktadır. Lezyonların alt türleri Tablo 3.1'de gösterilmiştir. Hastalar, yaşları 30 ile 72 arasında değişen kadın hastalardır. Her bir hastadan uzman doktor eşliğinde T1-ağırlıklı yağ baskılı kontrast sonrası ve T2-ağırlıklı yağ baskılı MR görüntüleri alınmıştır. Histopatolojik olarak doğrulanan lezyon özellikleri Tablo 3.2'de detaylı bir şekilde verilmiştir.

Tablo 3.1. Lezyon alt türleri

Kötü Huylu	74
İnvasif Duktal Karsinom	49
İnvasif Duktal Karsinom + Lobüler Karsinom	3
Papiler Karsinom	3
Apokrin Karsinom	2
Mikst İnvasif Karsinom	1
İnvasif Lobular Karsinom	6
İnvasif Duktal Karsinom + Intraduktal Papilloma	2
Tübüler Karsinom	2
Komodo, kribriform ve solid tipte yüksek dereceli duktal karsinom in situ	1
Duktal Karsinom in Situ	3
Musinöz Kolloid Karsinom	1
Mixt İnvasif Duktal Karsinom + İnvasif Papiler Karsinom	1
Benign	23
Kist	10
Fibrokistik	4
Fibroadenom	7
Duktal Gland	2

Tablo 3.2. Lezyon alt türleri

	Erişim Numarası	Yaş	Türü	Açıklama
1	846726	46	Kötü huylu	İnvazif Duktal Karsinom
2	176468969	30	Kötü huylu	İnvazif Duktal Karsinom
3	1050609	55	Kötü huylu	İntroduktal popilon (Meme ucunda süt kanalının içerisinde kitle benzeri oluşum, Kontrast madde sonrası oluşan parlak kısımlar lezyon değil, kanal içerisindeki koyu kısımlar lezyon.)
4	861090	62	Kötü huylu	İnvazif Duktal Karsinom (Sağ memede operasyon olmuş ve operasyon sonrası nüks etmiş küçük bir lezyon.)
5	1191962	75	Ameliyat sonrası	Post-operatif sıvı toplanması (Operasyon sonrası lezyonun çıkarıldığı bölgede ödem oluşmuş ancak lezyon değil)
6	176732642	38	Kötü huylu	İnvazif Duktal Karsinom (Çok sayıda lezyon var.)
7	1016880	47	Kötü huylu	Koltuk altı lenf bezi (Patalojik kötü huylu)
8	723189	54	İyi huylu	Sklenezon adonisi (Kötü huylu şüphesiyle gitmiş ama iyi huylu çıkmış)
9	1348982	79	Kötü huylu, İyi huylu	İyi huylu ve kötü huylu lezyonlar var. İncelemede iyi huylu lezyon kullanıldı.
10	621077	66	Kötü huylu	İnvazif Duktal Karsinom
11	687921	76	Kötü huylu	İnvazif Duktal Karsinom
12	728483	36	Kötü huylu	İnvazif Duktal Karsinom
13	947349	63	İyi huylu	Fibradünom

14	1176419	55	Kötü huylu	İnvazif Lobüler Karsinom (Tanısı zor oluyor.)
15	1451228	53	Kötü huylu	İnvazif Duktal Karsinom
16	176474013	59	Kötü huylu	İnvazif Duktal Karsinom
17	949024	71	Kötü huylu	Duktal Karsinom in situ
18	855523	39	Kötü huylu	Duktal Karsinom in situ
19	1184410	58	İyi huylu	Fibradünom
20	15527621	40	Kötü huylu	İnvazif Duktal Karsinom
21	15527621	40	İyi huylu	İyi huylu
22	1557624	63	Kötü huylu	İnvazif Duktal Karsinom
23	1557624	63	İyi huylu	İyi huylu
24	1555609	45	Kötü huylu	İnvazif Duktal Karsinom + Lobüler Karsinom
25	1555609	40	İyi huylu	İyi huylu
26	1552720	36	İyi huylu	Fibradünom
27	1499300	48	Kötü huylu	Mikst İnvazif Duktal Karsinom +İnvazif papiller Karsinom
28	1545566	50	Kötü huylu	İnvazif Duktal Karsinom
29	1485299	40	Kötü huylu	Papiller neopilezi
30	1485299	36	Kötü huylu	Papiller neopilezi
31	15286532	46	Kötü huylu	İnvazif Duktal Karsinom + Lobüler Karsinom
32	1479759	50	Kötü huylu	İnvazif Lobüler Karsinom
33	1479759	48	Kötü huylu	İnvazif Lobüler Karsinom

34	15440524	48	Kötü huylu	İnvazif Duktal Karsinom
35	15440524	37	Kötü huylu	İnvazif Duktal Karsinom
36	1511777	38	Kötü huylu	Tubüler Karsinom
37	1511777	60	Kötü huylu	Tubüler Karsinom
38	15162227	46	İyi huylu	İnvazif duktal karsinomdan opere edilmiş.
39	1506327	39	Kötü huylu	İnvazif Duktal Karsinom
40	1506327	39	İyi huylu	İyi huylu
41	1515968	49	Kötü huylu	İnvazif Duktal Karsinom
42	1515968	49	İyi huylu	İyi huylu (Ödem)
43	1487569	51	Kötü huylu	İnvazif Duktal Karsinom
44	1487569	51	İyi huylu	İyi huylu (Kist)
45	1504695	31	Kötü huylu	İnvazif Duktal Karsinom
46	1504695	31	Kötü huylu	İnvazif Duktal Karsinom
47	1504695	31	Kötü huylu	İnvazif Duktal Karsinom
48	1504695	31	İyi huylu	İyi huylu Duktal Karsinom
49	1505696	51	Kötü huylu	İnvazif Duktal Karsinom)
50	1505904	50	Kötü huylu	Mist İnvazif Karsinom
51	1505904	50	İyi huylu	İyi huylu fibrokistik değişiklik reaktif lenf nodu
52	23918015324	38	Kötü huylu	İnvazif Duktal Karsinom
53	39661851188	34	Kötü huylu	İnvazif Lobüler Karsinom
54	39661851188	34	İyi huylu	Fibroadenom
55	39661851188	34	İyi huylu	Kist

56	39661851188	34	İyi huylu	Fibroadenom iki adet
57	12494307190	51	Kötü huylu	İnvazif Duktal Karsinom
58	10532820090	55	Kötü huylu	İnvazif Duktal Karsinom
59	10532820090	55	Kötü huylu	Patalojik Lenf Nodu
60	11558403120	52	Kötü huylu	İnvazif Duktal Karsinom T2
61	29024207950	68	Kötü huylu	Komodo, kribriform ve solid tipte yüksek dereceli duktal karsinom in situ
62	12059769302	65	Kötü huylu	İnvazif Duktal Karsinom
63	12059769302	65	Kötü huylu	İyi huylu (Koltukaltı patalojik lenf nodu)
64	43180731838	31	Kötü huylu	İnvazif Duktal Karsinom
65	43180731838	31	İyi huylu	İyi huylu Duktural Gland
66	43180731838	31	Kötü huylu	İnvazif Duktal Karsinom iki adet
67	23110289028	52	Kötü huylu	İnvazif Duktal Karsinom
68	23918015324	38	Kötü huylu	İnvazif Duktal Karsinom
69	37159627796	76	Kötü huylu	İnvazif Duktal Karsinom
70	46324353392	60	Kötü huylu	İnvazif Duktal Karsinom+İntraduktal Papillom (meme ucu)
71	11879387598	32	Kötü huylu	İnvazif Duktal Karsinom
72	11879387598	32	Kötü huylu	İnvazif Duktal Karsinom
73	27425259646	55	Kötü huylu	İnvazif Duktal Karsinom
74	46912118822	51	İyi huylu	Fibrokistik değişiklik

75	20156586104	62	Kötü huylu	İnvazif Duktal Karsinom
76	19664046394	50	Kötü huylu	İnvazif Duktal Karsinom
77	19664046394	50	İyi huylu	Fibrokistik
78	49027147992	52	Kötü huylu	İnvazif Lobüler Karsinom
79	33238492026	70	Kötü huylu	İnvazif Duktal Karsinom
80	19355143102	30	İyi huylu	Fibrokistik
81	16005246624	62	Kötü huylu	Apokrin Karsinom
82	36041104728	47	Kötü huylu	Duktal Karsinom in situ
83	31954717782	68	Kötü huylu	İnvazif Duktal Karsinom
84	23429392150	68	Kötü huylu	İnvazif Duktal Karsinom
85	41089803700	38	Kötü huylu	İnvazif Duktal Karsinom
86	13364336234	46	Kötü huylu	İnvazif Duktal Karsinom
87	20299907064	67	Kötü huylu	Papiller Karsinom
88	58834212328	33	Kötü huylu	İnvazif Duktal Karsinom
89	28264841016	47	Kötü huylu	İnvazif Apokrin Karsinom
90	36673951066	40	Kötü huylu	İnvazif Lobüler Karsinom
91	38617886120	45	Kötü huylu	İnvazif Duktal Karsinom (üç adet)
92	24979950364	68	Kötü huylu	İnvazif Duktal Karsinom
93	46099245908	68	Kötü huylu	Musinöz Kolloid Karsinom

94	49126086208	55	Kötü huylu	İnvazif Duktal Karsinom
95	10430434290	60	Kötü huylu	İnvazif Karsinom (Duktal+Lobüler)

3.2. Meme MRG Görüntülerinin Otomatik Segmentasyonu

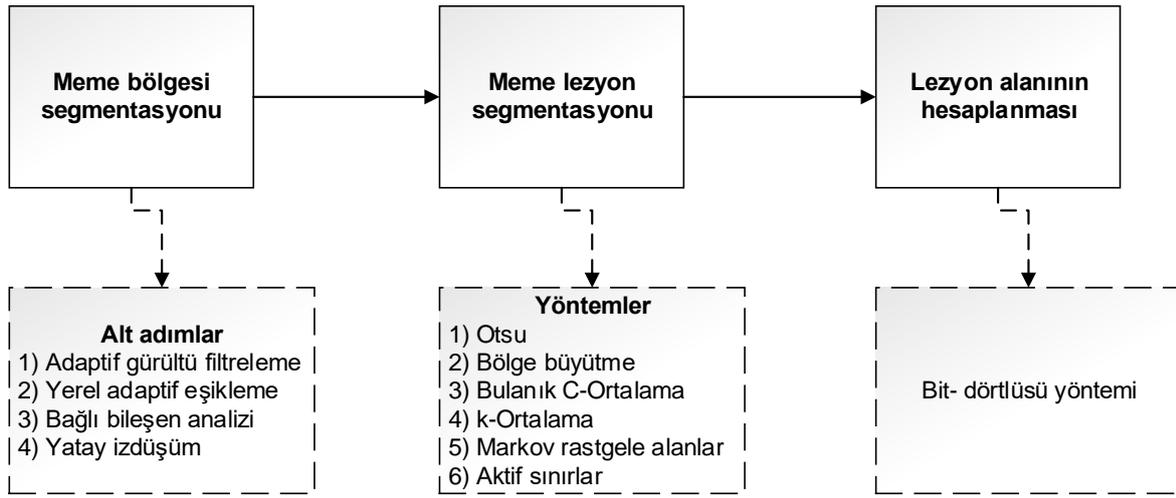
Segmentasyon (bölütleme) işlemi, bir görüntüyü benzer özelliklere sahip bölgelere ayırma işlemidir. Segmentasyon için en temel özellik monokrom görüntüler için görüntü parlaklığının genliği, renkli görüntüler için ise renk bileşenleridir. Ayrıca görüntünün kenar ve doku özellikleri de segmentasyon için faydalı bilgiler sağlamaktadır.

Görüntü segmentasyonu için temel bir teori yoktur. Bunun bir sonucu olarak, görüntü segmentasyonunda kullanılan tek bir yöntem de yoktur. Ancak, probleme göre geliştirilen (ad-hoc) ve popülerlik kazanmış birçok yöntem mevcuttur. Yöntemler probleme göre geliştirildiğinden, performanslarını belirlemek için bazı uygulamalar yapmak gerekmektedir. Haralick ve Saphiro [69] iyi bir segmentasyon için şu ifadeyi kullanmışlardır: “Bir görüntü segmentasyonu bölgeleri grilik seviyesi ya da doku gibi bazı karakteristikler açısından düzenli ve homojen olmalıdır. Bölgelerin iç kısımları basit olmalıdır ve çok sayıda küçük delik içermemelidir. Segmentasyonda art arda gelen bölgeler oldukça farklı değerlere sahip olmalıdır. Her bir bölütün sınırları belirgin ve uzamsal olarak düzgün olmalıdır”. Haralick ve Saphiro tarafından belirlenen ölçütleri ölçen herhangi bir niteliksel görüntü segmentasyon performans metriği maalesef henüz geliştirilmemiştir. Ancak, manuel segmentasyon sonuçları ile otomatik segmentasyon sonuçlarını kıyaslamak için kullanılan ölçütler mevcuttur [70]. Segmentasyon işlemi, görüntü işlemedeki temel adımlardan biri olarak düşünülmektedir. Sayısal görüntüleri analiz etmek için görüntüyü birden fazla bölgeye ayırmak ve bölgeleri sınıflandırmak için kullanılır. Görüntü segmentasyonu için genel birçok yöntem sunulmuştur [71].

Projede meme lezyonlarının tespit edilmesi ve sınırlarının belirlenmesi üç aşamalı bir süreç şeklinde gerçekleştirilmiştir. Bu üç aşamalı süreç projenin başarımını doğrudan etkilemektedir. İlk aşama meme lezyonlarının oluşacağı bölgenin tüm MR görüntüsünden seçilmesidir. Bu aşama ilgili bölge tespiti olarak düşünülür ve projede *meme bölgesi segmentasyonu* olarak adlandırılmıştır. İkinci aşamanın amacı sağ ve sol meme için ayrı ayrı belirlenmiş meme bölgelerinde lezyonların tespit edilmesidir. Bu aşama *meme lezyon segmentasyonu* olarak adlandırılmıştır. Son aşama ise tespit edilen lezyonlar için alan hesabının yapılmasıdır.

Birinci aşamada yerel adaptif eşikleme, bağlı bileşen analizi, yatay iz düşüm algoritması ve maskeleyme teknikleri kullanılarak meme bölgeleri tespit edilmiştir. İkinci aşama için, eşikleme tabanlı, bulanık mantık tabanlı, bölge büyütme tabanlı, kümeleme tabanlı ve istatistik tabanlı olmak üzere beş farklı segmentasyon algoritması kullanılmıştır. Son aşamada ise bit-dörtlüsü yöntemi kullanılarak lezyonların kapsadığı alan hakkında bir değer elde edilmiştir. Projenin üç aşamalı segmentasyon süreci Şekil 3.1’de gösterilmiştir. Segmentasyon işlemi için gerçekleştirilen üç aşama ve bu aşamalarda kullanılan teknikler izleyen kısımlarda açıklanmıştır.

Şekil 3.1. Meme lezyonlarının tespiti, sınırlarının belirlenmesi ve alanlarının hesaplanması için önerilen üç aşamalı segmentasyon süreci

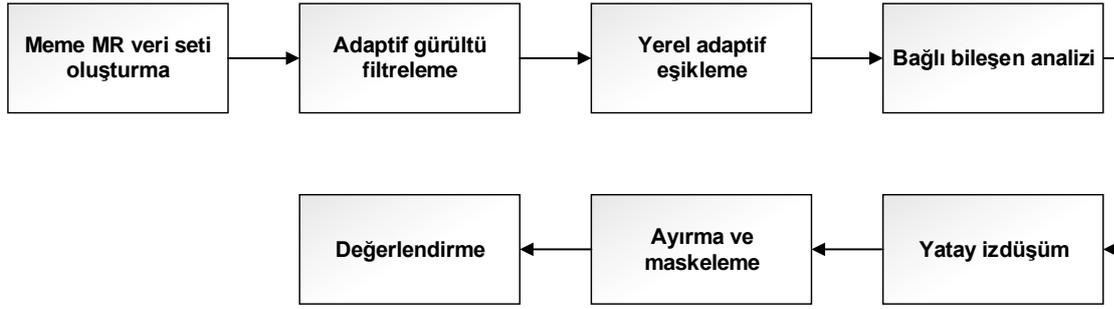


3.2.1. Meme Bölgesi Segmentasyonu

Memede bulunan lezyonların tespiti için ilk yapılması gereken işlem, memeler ve lenf bezlerini içeren koltuk altı bölgesinden oluşan meme bölgesinin tespit edilmesidir. Aksiyel kesitten alınmış orijinal bir MR görüntüsünde göğüs bölgesi, kalp, kollar gibi meme lezyonlarının bulunmayacağı bölgeler de mevcuttur. Segmentasyon adımının başarı ile tamamlanması ve yalancı pozitiflerin önlenmesi için lezyon içermeyen bu bölgelerin görüntüden atılması gerekir. Bu işlem projede meme bölgesi segmentasyonu olarak adlandırılmıştır.

Meme bölgesinin tespiti için literatürde birçok çalışma mevcuttur [REF eklenecek]. Bu çalışmalardan büyük bir kısmı ilgili bölge seçimini manuel olarak gerçekleştirirken, bir kısmı da otomatik olarak gerçekleştirmektedir. Projede, Şekil 3.2’de verilen adımlardan oluşan bir ilgili bölge seçimi yani projedeki adıyla meme segmentasyon adımı uygulanmıştır.

Şekil 3.2. Meme ilgili bölge belirleme adımları



Şekil 3.2’de görüldüğü gibi ilk adım, çekim esnasında oluşan gürültüyü temizlemektir. Görüntüde oluşan bu bozunumlar çekim esnasında istemli ya da istemsiz olarak yapılan hareketlerden veya nefes tutulması gereken zamanlarda nefes alınmasından dolayı gerçekleşen göğüs kafesi hareketlerinden kaynaklanmaktadır. Projede gürültü giderme aşamasında uzamsal filtreleme tekniklerinden faydalanılmıştır.

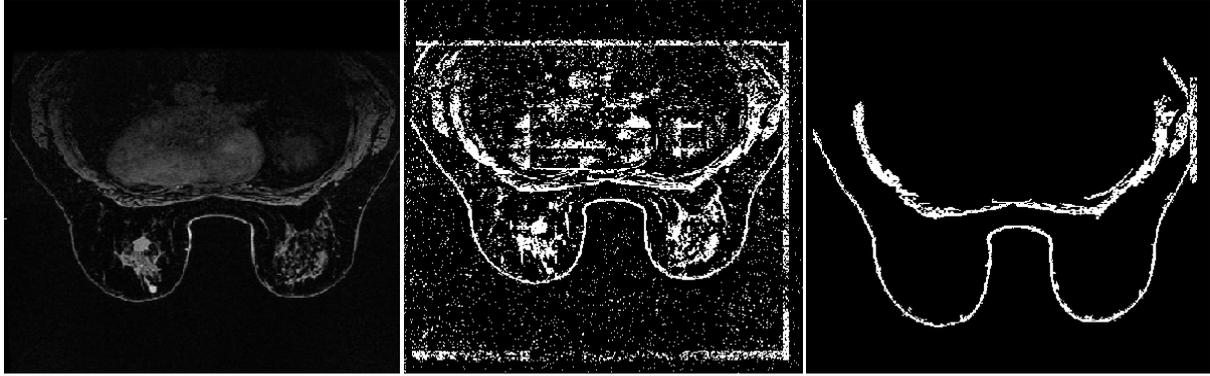
Gürültü filtreleme adımından sonra yerel adaptif eşikleme işlemi gerçekleştirilir. Eşikleme, görüntüleri iki seviyeli yapmak için kullanılan en yaygın ve en basit yöntemlerden biridir. Eşikleme yöntemleri kabaca global eşikleme yöntemleri ve yerel eşikleme yöntemleri olarak ikiye ayrılır. Global eşikleme yöntemlerinde istatistiksel yaklaşımlar kullanarak görüntü için tek bir eşik değeri belirlenir. Yerel eşikleme yöntemlerinde ise görüntü üzerinde seçilen pencereler için ayrı ayrı eşik değerler hesaplanır. Global eşikleme yöntemleri homojen piksel yeğinliklerine sahip görüntülerde kabul edilebilir sonuçlar verirken yerel eşikleme yöntemleri homojen olmayan görüntülerde daha iyi sonuçlar vermekte ve görüntüdeki detayları nispeten daha iyi korumaktadır.

Yerel eşik değerlerini hesaplamak için sunulan birçok formül mevcuttur. Bunlara örnek olarak Niblack formülü, Sauvola formülü, Bernsen formülü verilebilir [72]. Formüllerin başarımı tamamen veri tabanına bağlıdır. Bu nedenle, verilen formüller kullanılarak projedeki tüm görüntüler için yerel eşikleme işlemi yapılmış ve en uygun formül Niblack formülü olarak seçilmiştir. Niblack formülü görüntünün ortalama değerini ve varyansını dikkate alan bir formüldür. Denklem 3.1’de Niblack tarafından önerilen eşik değeri verilmiştir.

$$T(i, j) = m(i, j) + k\sigma(i, j) \quad \text{Denklem (3.1)}$$

Denklem 3.1’de $m(i, j)$ ve $\sigma(i, j)$, (i, j) konumundaki bir pikselin etrafında tanımlanan penceredeki piksellerin yeğinlik değerlerinin ortalaması ve standart sapmasıdır. Standart

Şekil 3.5. (a) Orijinal görüntü, (b) Gürültü filtrelenmiş ve yerel adaptif eşikleme uygulanmış görüntü, (c) Bağlı bileşen analizi uygulanmış görüntü

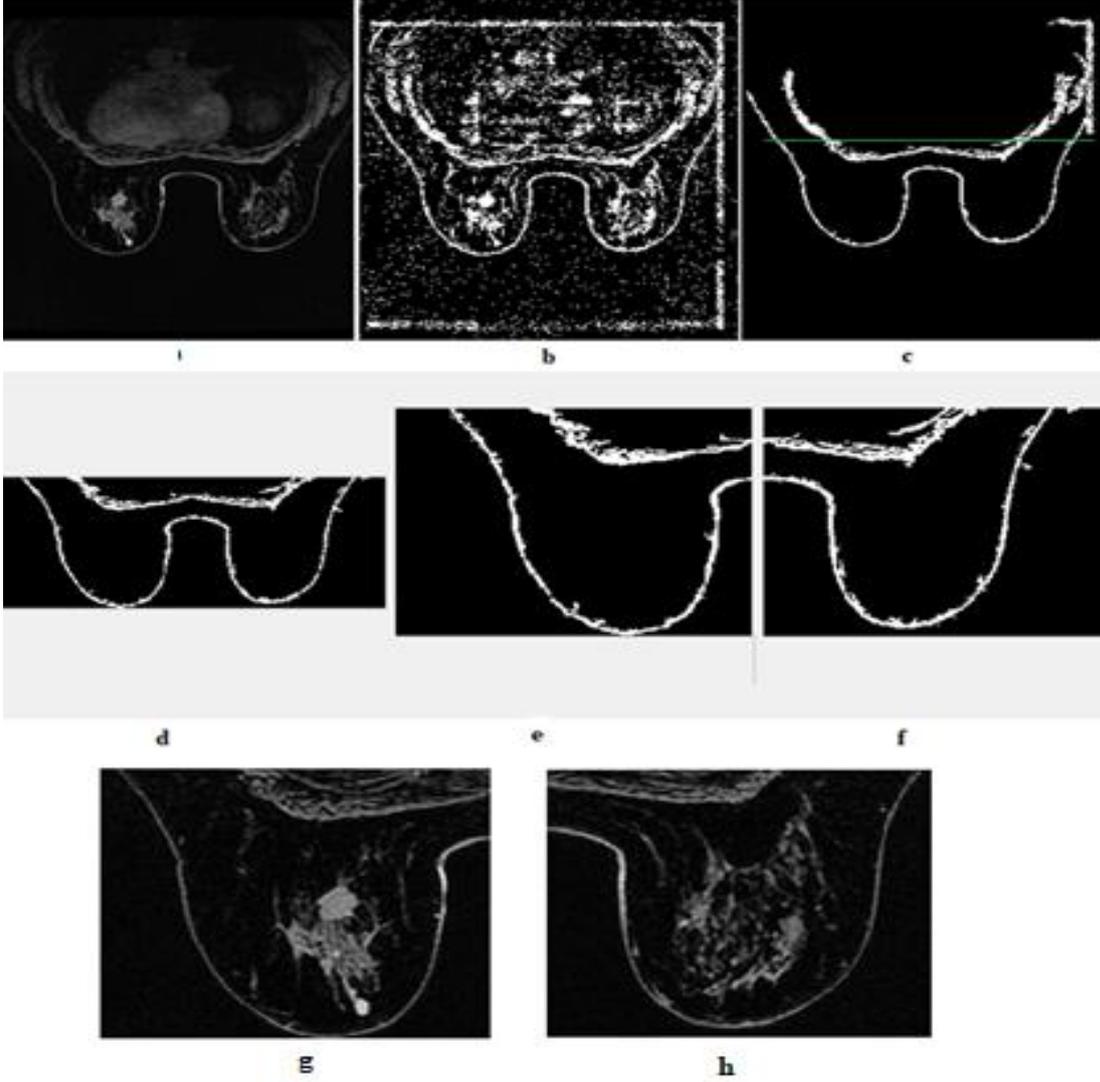


Şekil 3.5'de görüldüğü gibi, etiketleme işlemi sonucu istenilen bölgenin ana hatları neredeyse belirlenmiştir. Bu bölge sağ ve sol meme ile lenf nodlarını içermektedir. Sonraki adım sağ ve sol memeyi ayırmak, görüntüyü tam istenile bölgeyi seçecek şekilde kırpmaktır. Bu amaçla, bağlı bileşen analizinden sonra yatay iz düşüm algoritması uygulanır. Yatay iz düşüm algoritmasında, bağlı bileşen analizi uygulanmış görüntünün yatay iz düşüm vektörü hesaplanır. Hesaplama iki seviyeli görüntünün piksel değerleri satır satır toplanır. Sonuç olarak görüntünün satır sayısı ile aynı uzunlukta bir vektör elde edilir. Bu vektörün maksimum değerine karşılık gelen satır göğüs kafesi hattının konumudur. Lenf nodlarını da içerecek şekilde bir sınır belirlemek için Denklem 3.2'de verilen eşitlik kullanılır.

$$cl = f + \frac{g - f}{2} \quad \text{Denklem (3.2)}$$

Denklem 3.2'de f ve g yatay iz düşüm vektörünün ilk ve son sıfırdan farklı elemanıdır. Meme bölgesi g noktasından yani meme uçlarından başlar. Meme uçları ile cl arasındaki bölge lezyon içermeye potansiyeli olan hedef bölgedir. Şekil 3.6. (c)'de gösterilen yeşil çizgi cl ile elde edilen satıra karşılık gelen çizgidir. Elde edilen hedef bölge Şekil 3.6. (d)'de gösterilmiştir. Hedef bölge elde edildikten sonra yapılması gereken işlem sağ ve sol memeyi birbirinden ayırmaktır. Bu amaçla, iki meme arasında kalan bölgenin orta nokta tespit edilir ve görüntü bu noktadan ikiye ayrılır. Son olarak, sağ ve sol meme için elde edilen bölgenin gerçek meme MR görüntüsündeki karşılıkları maskeleyiş işlemi ile tespit edilir. Şekil 3.6. baştan sona meme bölgesi tespiti işlemini görsel olarak açıklamaktadır.

Şekil 3.6. Meme bölgesi segmentasyonu, (a) orijinal görüntü, (b) yerel adaptif eşikleme işlemi sonucu, (c) bağlı bileşen analizi sonucu elde edilen iki seviyeli görüntü, (d) meme bölgesi, (e) sol meme bölgesi, (f) sağ meme bölgesi, (g) ve (h) orijinal sol ve sağ meme görüntüsü



Meme ilgili bölgesinin tespitini içeren makalelerin birçoğunda ilgili bölge manuel olarak belirlenmiştir. Projenin katkılarından biri hiçbir müdahale olmadan meme bölgesinin ve sağ-sol meme bölgelerinin ayrı ayrı tespit edilebilmesidir. İlgili bölgenin doğru bir şekilde tespit edilip edilmediğinin belirlenmesi için uzman tarafından manuel olarak belirlenen bölge ile otomatik olarak belirlenen bölge birbiri ile karşılaştırılmıştır. Zar benzerlik katsayısı (Dice similarity coefficient, DSC) ve Jaccard katsayısı (JC) ölçütleri otomatik ve manuel segmentasyon sonuçlarını kıyaslamak için kullanılan ortalama ve birleşik örtüşme oranlarıdır. Bu ölçütler Denklem 3.3 ve 3.4 eşitlikler ile verilebilir.

$$DSC = \frac{A \cap M}{(A + M) \setminus 2} \quad \text{Denklem (3.3)}$$



$$JC = \frac{A \cap M}{A \cup M}$$

Denklem (3.4)

Denklem 3.3 ve 3.4'te A ve M sırasıyla otomatik ve manuel olarak elde edilen toplam meme hacmini temsil etmektedir. Bu ölçütlerin değeri bire yakınsa otomatik segmentasyon sonuçları ile manuel segmentasyon sonuçlarının birbiri ile oldukça yakın olduğu söylenebilir. Projemizde DSC ve JC yüzdeleri sırasıyla %91±0.06 ve %85±0.08 olarak elde edilmiştir. Elde edilen sonuçlar meme bölgesi tespitinin başarılı bir şekilde gerçekleştirildiğini göstermektedir. Ayrıca, meme bölgesinin belirlenmesi sistemin hesap yükünü oldukça azaltmaktadır.

3.2.2. Meme Lezyon Segmentasyonu

Bu aşamada amaç, her bir meme için lezyonun bulunduğu bölgenin tespit edilip sınırlarının belirlenmesidir. Daha önce de belirtildiği gibi, bu amaçla farklı yöntemler kullanılmıştır. Eşikleme yöntemleri istenilen sınıfları ayırmak için eşik olarak adlandırılan bir şiddet (intensity) değeri belirlemeyi amaçlayan yöntemlerdir. Segmentasyon, eşik üzerindeki şiddete sahip olan pikselleri bir gruba diğer tüm pikselleri başka bir gruba atayarak gerçekleştirilir. Eşikleme görüntü işleme uygulamalarında genellikle ilk adımdır. En önemli sınırlaması çok kanallı görüntülere uygulanamamasıdır. Ayrıca, eşikleme görüntünün uzamsal özelliklerini dikkate almaz. Bu da MR görüntülerinde meydana gelebilen gürültü ve homojen dağılmayan görüntü şiddetlerine karşı hassasiyetin artmasına dolayısıyla histogramın bozulup ayrıştırma işleminin zorlaşmasına neden olmaktadır. Sonuç olarak, medikal görüntü segmentasyon işlemi için klasik eşikleme yöntemlerine ilave parametreler eklenmelidir. Bu kısıtlamalar dikkate alınarak projede uyarlamalı bir eşikleme yöntemi olan Otsu yöntemi kullanılmıştır.

Bölge Büyütme (Region Growing, RG), daha önceden tanımlanmış bir takım ölçütlerle bağlanmış bir bölgeyi görüntüden çıkarmak için kullanılır. Ölçüt, şiddet bilgisine ve/veya görüntüdeki kenarlara bağlıdır. En basit haliyle bölge büyütme, operatör tarafından manuel olarak seçilen bir çekirdek noktadan başlayarak bu başlangıç noktasıyla aynı şiddette olan tüm pikselleri bağlayıp giderek büyüyen bir bölge oluşturmaktır. Bölge büyütme özellikle tümör ve lezyonlar gibi yapıların nitelendirilmesinde başarılı sonuçlar sağlamaktadır. RG yöntemine ek olarak projemizde aktif sınırlar modeli (Snake) yöntemi de uygulanmıştır.

Kümeleme yöntemleri eğitilmiş veri dışında sınıflandırma yöntemleri ile aynı fonksiyonu gerçekleştirirler. Bu nedenle denetimsiz (unsupervised) yöntemler olarak adlandırılırlar. Eğitim verisi olmayışını dengelemek amacıyla kümeleme yöntemleri, görüntüyü bölme ve her bir sınıfın özelliklerini karakterize etme arasında bir yinelenme yapar yani kendi kendini eğitir. En yaygın olarak kullanılan yöntemler k-ortalamlar (k-means, ISODATA), bulanık c-

ortalamalar (Fuzzy c-means, FCM) ve beklenti-maksimizasyon (Expectation Maximization, EM) algoritmalarıdır. Kümeleme algoritmaları bir başlangıç parametresi gerektirir. EM algoritması diğerlerine göre başlangıç parametre değerine karşı daha hassastır. Kümeleme algoritmaları MR görüntülerde çok tercih edilir ve iyi sonuçlar verir. Gürültüye karşı dayanıklılık, istatistik tabanlı Markov rastgele alanlar (Markov Random Fields, MRF) yöntemi kullanılarak artırılabilir. MRF yöntemi genellikle öncü bir segmentasyon yönteminin performansını artırmak amacıyla kullanılır. Sunulan projede MRF yöntemi Otsu yöntemi ile hibrit olarak da kullanılmıştır. Bu genel bilgiler ışığında, projede tercih edilen segmentasyon teknikleri aşağıda detayları ile tartışılmıştır.

3.2.2.1. Otsu Segmentasyon Yöntemi

Sezgisel özellikleri, uygulama yönteminin basitliği ve hızı gibi sebeplerle eşikleme yöntemleri görüntü işlemede Segmentasyon uygulamalarında önemli bir yere sahiptir. Görüntüye ait tek bir eşik değeri belirleyerek bu eşik altında kalan piksellere sıfır, üzerinde kalan piksellere bir değerinin atayarak yapılan en basit eşikleme işlemi görüntüde homojen tek bir nesnenin bulunmasında iyi sonuç vermektedir. Ancak görüntü içerisindeki nesne sayısı arttıkça eşikleme işlemindeki sınır değerlerinin sayısı artırılmalıdır. Eşik değeri görüntünün uzamsal koordinatlarına bağlı ise değişken eşikleme yerine uyarlamalı eşikleme olan Otsu yöntemini tercih etmek daha iyi sonuçlar vermektedir. Meme MR görüntülerinde gözlemlenen lezyonların sayısı bir veya birden çok ve heterojen yapıda olabildiğinden, Otsu yöntemi projemizde tercih edilen yöntemlerden biridir. Tüm meme MR görüntüleri için geçerli tek bir eşik değeri mevcut değildir. Geçmiş deneyimlere dayalı olarak bir eşik seviyesi belirlenir ancak bu durumda da yapılan işlemin bilimsel bir dayanağı olmamaktadır. Bu sebeple uyarlamalı eşikleme yöntemi olan Otsu eşikleme yöntemi önem kazanmaktadır.

Otsu eşikleme yöntemi, istatistiksel ayırt etme analizinde de kullanılan bilinen bir ölçüm olan varyansı maksimum yapma amacıyla gerçekleştirilen en uygun yöntemlerden biridir. $M \times N$ piksel boyutlu sayısal bir görüntüde L farklı yağınlik seviyesi $\{0, 1, \dots, L-1\}$ ile ifade edilsin. n_i 'de i . yağınlik seviyesine sahip piksellerin sayısını gösterebilir. Görüntüdeki piksellerin toplam sayısı $MN = n_0 + n_1 + n_2 + \dots + n_{L-1}$ olarak hesaplanır. P_i , i . yağınlik seviyesine sahip piksellerin olasılıkları olmak üzere Denklem 3.5'teki eşitlik geçerlidir.

$$\sum_{i=0}^{L-1} P_i = 1, P_i \geq 0 \quad \text{Denklem (3.5)}$$

Verilen bir görüntüyü ikili bir eşikleme işlemine tabi tutmak istediğimizi varsayalım. İlk olarak, giriş görüntüsü c_1 ve c_2 gibi iki sınıfa eşiklemek için eşik değerleri belirlenir. Örneğin, c_1 görüntüde $[0, k]$ aralığındaki yeşinlik seviyelerine sahip pikselleri ve c_2 'de $[k+1, L-1]$ arasındaki yeşinlik seviyeli piksel değerine karşılık gelsin. Belirlenen eşik seviyesini kullanarak, bir pikselin c_1 sınıfına atanma olasılığı $P_1(k)$ ile temsil edilmektedir. $P_1(k)$ Denklem 3.6'da ifade edilir:

$$P_1(k) = \sum_{i=0}^k P_i \quad \text{Denklem (3.6)}$$

Denklem (3.6), c_1 sınıfı için oluşan olasılıktır. c_2 sınıfı için oluşan olasılık ise Denklem (3.7)'de verilmiştir.

$$P_2(k) = \sum_{i=k+1}^{L-1} P_i = 1 - P_1(k) \quad \text{Denklem (3.7)}$$

c_1 sınıfına atanan piksellerin ortalama yeşinlik değerleri Denklem 3.8'de ifade hesaplanmıştır:

$$m_1(k) = \sum_{i=0}^k iP\left(\frac{i}{c_1}\right) = \sum_{i=0}^k i(c_1/i)(P(i)/P(c_1)) = \frac{1}{P_1(k)} \sum_{i=0}^k iP_i \quad \text{Denklem (3.8)}$$

$P(c_1), P_1(k)$ 'ya eşit olduğu bilinen c_1 sınıfının olasılığıdır. c_2 sınıfına atanan piksellerin ortalama yeşinlik değeri benzer şekilde hesaplanabilir:

$$m_2(k) = \sum_{i=0}^{L-1} iP(i/c_2) = \frac{1}{P_2(k)} \sum_{i=k+1}^{L-1} iP_i \quad \text{Denklem (3.9)}$$

k seviyesine kadar olan kümülatif yeşinlik ortalamasını hesaplamak için

$$m(k) = \sum_{i=0}^k iP_i \quad \text{Denklem (3.10)}$$

kullanılır. Yukarıda verilen eşitliklerden faydalanarak görüntünün tamamı için ortalama yeşinlik,

$$m_G = \sum_{i=0}^{L-1} iP_i \text{ veya } P_1 \cdot m_1 + P_2 \cdot m_2 = m_G, P_1 + P_2 = 1 \quad \text{Denklem (3.11)}$$

ile verilir. Belirlenen eşiklerin doğruluğunu değerlendirmek için aşağıda η ile gösterilen ölçüt kullanılır. Denklem (3.12)'de verilen η ayırt edicilik kriteri olarak adlandırılmaktadır. Q_G^2 sabit tutulduğunda, Q_B^2 'yi artırmak ayırt etme özelliğini maksimuma taşımaktadır.

$$\eta = \frac{Q_B^2}{Q_G^2} \quad \text{Denklem (3.12)}$$

Denklem (3.12)'de, Q_B^2 , sınıflar arası varyansı ve Q_G^2 global varyansı ifade etmektedir. Varyans değerleri aşağıda verilen denklemde hesaplanmıştır:

$$Q_B^2 = P_1 P_2 (m_1 - m_2)^2 = \frac{(m_G \cdot P_1 - m)^2}{P_1(1 - P_1)}, Q_B^2 > 0, Q_G^2 = \sum_{i=0}^{L-1} (i - m_G)^2 \cdot P_i \quad \text{Denklem (3.13)}$$

Elde edilen eşik değerinin görüntüyü istenildiği gibi bölgelere ayıramaması durumunda eşik değerleri güncellenmelidir. Segmentasyon yöntemlerinden beklendiği gibi, sınıf arası varyansı maksimum yapan k eşik değerinin güncellenmesi için,

$$\eta(k) = \frac{Q_B^2}{Q_G^2} \quad \text{Denklem (3.14)}$$

$$Q_B^2(k) = \frac{[m_G \cdot P_1(k) - m(k)]^2}{P_1(k)[1 - P_1]} \quad \text{Denklem (3.15)}$$

kullanılır. Denklem (3.15)'deki ifadeyi maksimum yapan k^* değeri şu şekilde belirlenir:

$$Q_B^2(k^*) = \max Q_B^2(k), 0 < k < L - 1 \quad \text{Denklem (3.16)}$$

Denklem (3.16)'de k^* bulmak için k 'nin bütün tamsayı değerleri için $0 < P_1(k) < 1$ aranır ve $\max Q_B^2(k)$ 'yi veren k değeri tespit edilir. Seçilen k değeri için giriş görüntüsü $f(x, y)$ Denklem (3.17)'deki işlem uygulanarak eşiklenir.

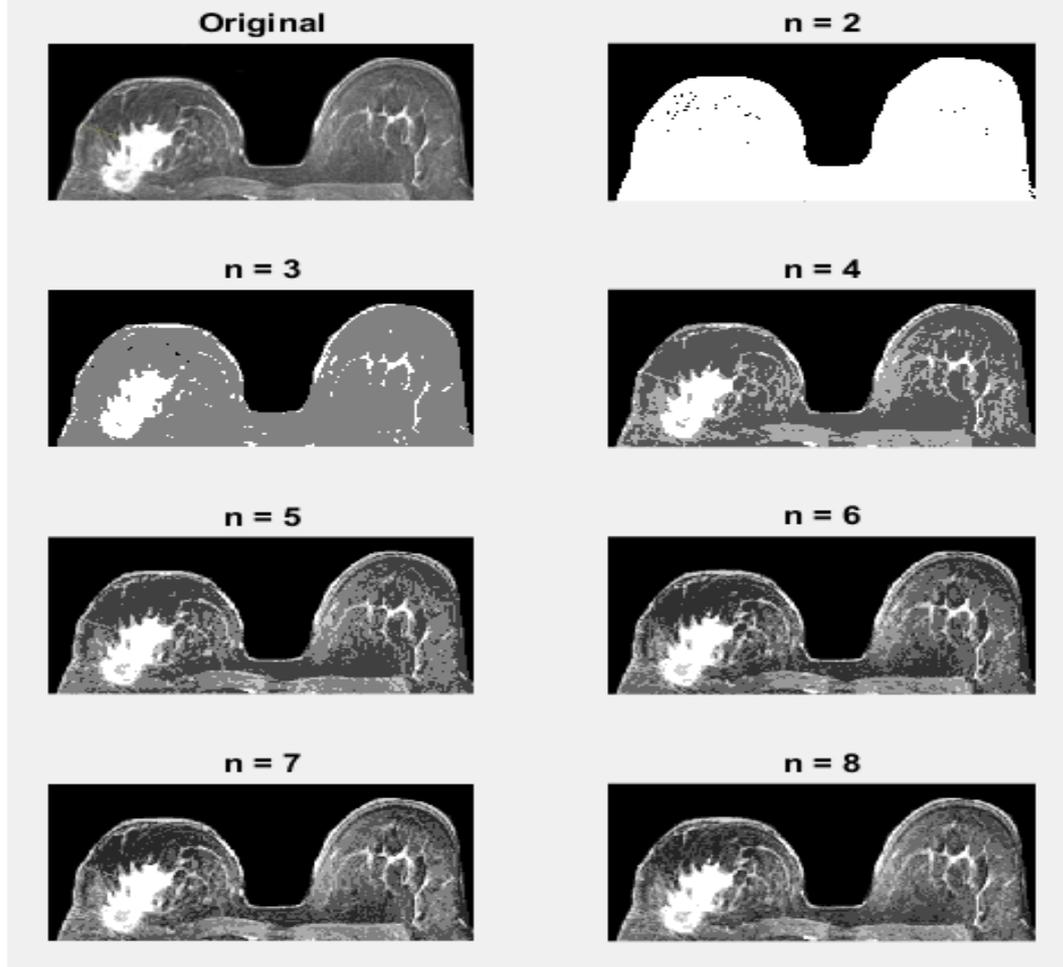
$$g(x, y) = \begin{cases} 1, f(x, y) > k^* \\ 0, f(x, y) < k^* \end{cases} \quad \text{Denklem (3.17)}$$

Eşikleme işleminden sonra elde edilen görüntü $g(x, y)$ ile gösterilmiştir [73]. Yukarıda anlatılan adımlar iki sınıf Otsu eşikleme yöntemi için verilmiştir. Projede, maksimum sınıf sayısı 32 olana kadar kullanıcının istediği eşikleme işlemi yapabilecek bir uygulama gerçekleştirilmiştir [74]. Yukarıda verilen adımlarda eğer sınıf sayısını arttırmak istersek adımlar sınıf sayısına göre tekrar uyarlanmalıdır. Örneğin, üç sınıf için eşikleme yapılırsa, $1 \leq k_1 < k_2 < L$ iki eşik seviyesi belirlemek gereklidir. Bu değerler görüntüye uygulandığında $c_1 = [1, 2, \dots, k_1]$, $c_2 = [k_1 + 1, \dots, k_2]$ ve $c_3 = [k_2 + 1, \dots, L]$ olmak üzere üç sınıf elde edilir. Ayırt ediciliği ölçmek için $Q_B^2(k)$ kriteri k_1 ve k_2 değerlerine sahip bir fonksiyon olacaktır. Dolayısıyla, $Q_B^2(k)$ 'yi maksimum yapan k_1^* ve k_2^* eşikleme seviyesi belirlenir. Son olarak, en uygun eşik seviyeleri kullanılarak görüntü istenilen yeğlilik sınıfına ayrıştırılır [75].

Şekil 3.7'de Otsu eşikleme yönteminin iki eşik değerinden sekiz eşik değerine kadar olan görüntüleri verilmiştir. Birinci satır birinci sütunda orijinal görüntü yer almaktadır. Şekilde n sembolü ile ifade edilen eşik sayısıdır. Örneğin, $n=2$ olarak seçildiğinde görüntüde $n-1$ eşik değeri atanarak görüntü bir ve sıfır içeren iki kısma ayrılmaktadır. Diğer adımlarda da bu işlem tekrarlanarak farklı görüntüler elde edilmiştir. Her görüntüde en iyi görüntülemeyi sağlayan tek bir eşik değeri yoktur. Bu nedenle, yazılımsal olarak radyoloji uzmanının istediği gibi sınıf sayısı değiştirilebilmektedir. Bu seçenek, lezyon sınırlarının daha net

olarak belirlenmesini sağlamaktadır. Lezyon sınırları gerçeğe yakın olarak belirlendiğinde, meme kanserinin teşhis ve tedavisi için uzmanlara ek bilgi sağlanmaktadır.

Şekil 3.7. Kötü huylu lezyon bulunan meme MR görüntüsünün farklı seviyelerde Otsu eşikleme yöntemi ile bölütlenmesi



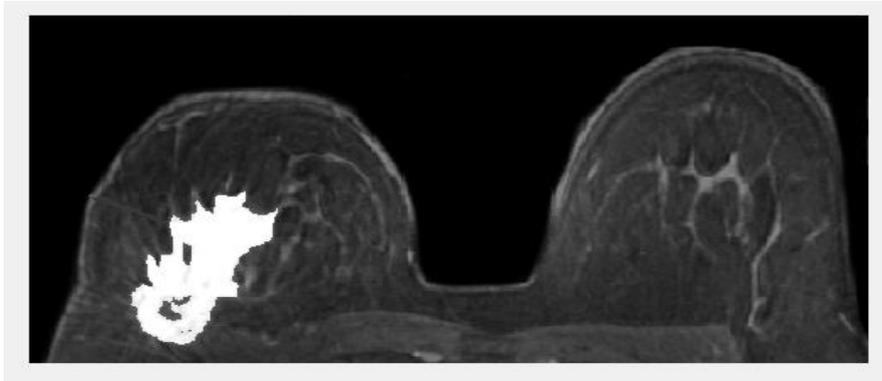
3.2.2.2. Bölge Büyütme Yöntemi

Bölge büyütme (Region growing, RG) tabanlı segmentasyon yöntemi, büyütme için önceden belirlenmiş ölçütler doğrultusunda piksel veya alt bölgeleri daha büyük bölgelere genişletip gruplamayı amaçlayan bir yöntemdir. Temel olarak çalışma mantığını şu şekilde açıklayabiliriz; Başlangıçta bir nokta kümesi belirlenir ve bu noktalardan başlayarak benzer özelliklere sahip olan komşu pikseller gruba dâhil edilir. Böylece bölge giderek büyür ve istenen gruplama sağlanınca işlem sona erer. Şimdi yöntemin nasıl uygulandığını temel adımları ile açıklayalım. $f(x, y)$ giriş görüntüsü ve $S(x, y)$ başlangıç noktaları olan yerlerde piksel değeri 1 olan ve diğer yerlerde piksel değeri 0 olan bir başlangıç nokta kümesini ifade etsin. Q ise her bir (x, y) noktasında sağlanması gereken koşulu temsil etsin. 8-bağlılığa dayalı temel bir bölge büyütme segmentasyon yönteminin temel adımları şu şekilde verilebilir:

- i. $S(x, y)$ içerisinde 8-bağılılığı olan bileşenler belirlenir ve her bağlı olan bileşen bir gruba atanır. Bağlılığı olan piksel değerleri 1 olarak temsil edilirken, diğer pikseller 0 ile temsil edilmektedir.
- ii. Görüntüde (x, y) koordinatında bir fQ görüntüsü oluşturulur. Eğer giriş görüntüsü bu koordinatlarda verilen Q koşulunu sağlarsa $fQ(x,y)=1$ olarak görüntü değeri atanır. Diğer durumlarda $fQ(x,y)=0$ olarak belirlenmektedir.
- iii. Belirlenen nokta kümesine 8-bağı bulunan fQ içinde yer alan bütün 1 değerli pikseller S içerisindeki her bir başlangıç noktasına ilave ederek bir g görüntüsü elde edilmektedir.
- iv. g içerisinde gruplanan bölgelere her nokta kümesi için 1,2,3...vb. gibi etiketler verilerek bölge büyütme kümeleri belirlenip yeni görüntü elde edilmektedir [73].

Bölge büyütme yöntemi tümörler ve lezyonlar gibi küçük veya basit yapıların belirlenmesinde tek başına kullanılmamaktadır. Çünkü bölge büyütme işleminin gerçekleştirilmesi için başlangıç nokta kümelerinin manuel olarak belirlenmesi gerekmektedir. Projede gözle görülen büyüklükteki lezyon sınırlarını belirlemek için bölge büyütme tekniğinden faydalanılmıştır. Başlangıç noktaları manuel olarak lezyonun bulunduğu tahmin edilen bölgedeki konumlar olarak seçilmiştir. Bölge büyütme yöntemi görüntüyü bütün olarak taramak yerine belirlenen bölgeden başlayarak taradığı için süre olarak avantaj sağlamaktadır. Daha önce verilen segmentasyon yöntemleri ile kıyaslamak amacıyla aynı görüntü için bölge büyütme tekniği uygulanmıştır. Şekil 3.8’de bölge büyütme yöntemi uygulanmış MR görüntüsü verilmiştir.

Şekil 3.8. Bölge büyütme algoritması uygulanmış görüntü



3.2.2.3. Bulanık C-Ortalama Yöntemi

Kümeleme tabanlı segmentasyon yöntemleri, sınıflandırma yöntemlerinin tersine eğitim verilerini kullanmadan segmentasyon işlemi gerçekleştiren yöntemlerdir. Bu nedenle küme yöntemlerine, denetimsiz yöntemler de denilmektedir. Eğitim verisinin eksikliğini gidermek için kümeleme yöntemleri, görüntünün sınıflara ayrılması ve her sınıfın özelliklerini karakterize edilmesi arasında bir yineleme işlemi yapmaktadır. Kümeleme yöntemleri bir bakıma, mevcut verileri kullanarak kendini geliştirmektedir.

FCM yöntemi, tıbbi görüntüler için başarılı segmentasyon sonuçları veren denetimsiz öğrenme yöntemlerinden biridir [76]. Bu yöntemde bir amaç fonksiyonu vardır ve bu amaç fonksiyonuyla ilgili bazı ölçütler tespit edilmiştir. FCM yöntemindeki amaç fonksiyonu genel olarak, rastgele atanan başlangıç değerlerine ait kümeler oluşturulmakta ve aynı kümedeki benzer veri değerleri gruplanmaktadır. Fonksiyon, belirlenen hata değerine veya iterasyon sayısına ulaşıncaya kadar gruplama işlemi devam etmektedir. FCM algoritmasının ana adımları şu şekilde açıklanabilir. İlk adımda Ek ile gösterilen amaç fonksiyonu elde edilmektedir.

$$E_k = \sum_{j=1}^D \sum_{i=1}^N \mu_{ij}^k \|X_i - C_j\| \quad \text{Denklem (3.18)}$$

Denklem (3.18)'de, D ve N sırasıyla X_i 'nin veri noktaları ve kümeleridir. k, bulanık örtüşme derecesini kontrol etmek için bulanık bölüm matris üssü olarak tanımlanmaktadır. Ayrıca, c_j , j. kümenin merkezini, ise j. kümedeki üyeliğinin derecesini belirtmektedir. İkinci adımda kümeleme adımı başlar. Başlangıçta μ üyelik matrisi rastgele atanır. Kümelerin merkezleri Denklem (3.19)'de verilen ifade ile hesaplanır.

$$C_i = \frac{\sum_{j=1}^D \mu_{ij}^k x_j}{\sum_{j=1}^D \mu_{ij}^k} \quad \text{Denklem (3.19)}$$

Denklem (3.19)'de hesaplanan merkez değerleri kullanılarak, aşağıda ifade ile μ_{ij} değeri güncellenir.

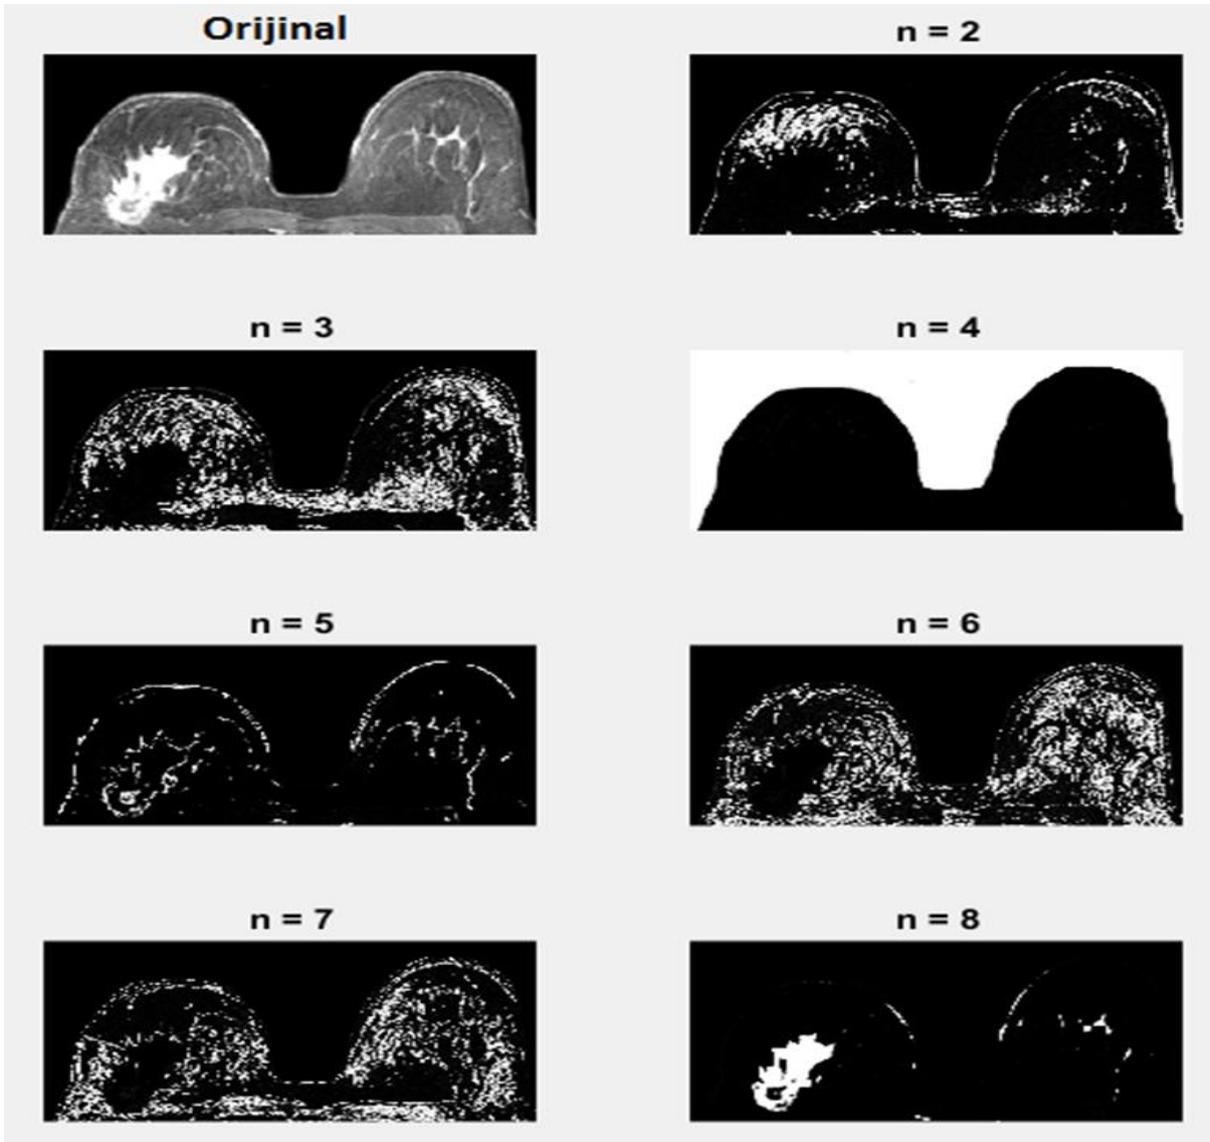
$$\mu_{ij} = \frac{1}{\sum_{m=1}^c \left(\frac{\|x_j - c_i\|}{\|x_j - c_m\|} \right)^{2/k-1}} \quad \text{Denklem (3.20)}$$

Son adımda, önceki μ matrisi yeni μ matrisi ile karşılaştırılır ve belirlenen hata değerine ulaşıncaya kadar bu işlem adımları tekrar edilir.

FCM algoritması tıbbi görüntülerde etkili bir şekilde kullanılmaktadır. Gürültüye maruz kalmış görüntüler olması halinde bile etkili sonuçların üretilmesinde yararlı olduğu kanıtlanmıştır [76]. MR görüntüleri için hızlı ve güvenilir sonuçlar ürettiği için projede FCM yöntemi de kullanılmıştır. Otsu yöntemi ile kıyaslayabilmek için Şekil 3.7'de verilen görüntü tekrar FCM yöntemi ile de bölütlenmiştir. Sonuçlar Şekil 3.9'da gösterilmiştir.

Şekil 3.9 'da birinci satır birinci sütunda orijinal görüntü yer almaktadır. n sembolü sınıf sayısını belirtmektedir. Sınıf sayısı ikiden başlayarak sekize kadar artırılmaktadır. n=8 olan görüntüde kötü huylu lezyon sınırlarının net bir şekilde ortaya çıktığı görülmektedir. Burada, FCM her iterasyonda pikselleri kümeleyerek görüntüdeki ilgisiz piksellere direk olarak sıfır değerini atamaktadır. Lezyon bulunan piksellere bir değerini atayarak iki seviyeli görüntüde lezyonun sınırlarını net bir şekilde ortaya çıkarmaktadır.

Şekil 3.9. Kötü huylu lezyon tespit edilmiş meme MR görüntüsünün FCM yöntemi ile kümelenmesi



3.2.2.4. k-Ortalama Yöntemi

Projede, k-ortalama segmentasyon yöntemi de meme MR görüntülerinde lezyon tespiti ve sınırlarının belirlenmesi amacıyla kullanılmaktadır. Bu yöntemin temel çalışma prensibi, her sınıf için tekrarlı bir ortalama yoğunluk hesaplayıp sınıf içindeki her pikseli en yakın ortalamasına göre sınıflandırarak görüntüyü kümelemektir [77]. Diğer bir ifade ile görüntüyü k adet parçaya ayırarak, parça içi varyansı en küçük, parçalar arası varyansı en büyük yapmak amaçlanmaktadır. k-ortalama yönteminde başlangıçta bir k değeri belirlenir ve segmentasyon sonucu k-1 kümeyle sahip bir görüntü elde edilir. Şimdi yöntemi açıklayalım.

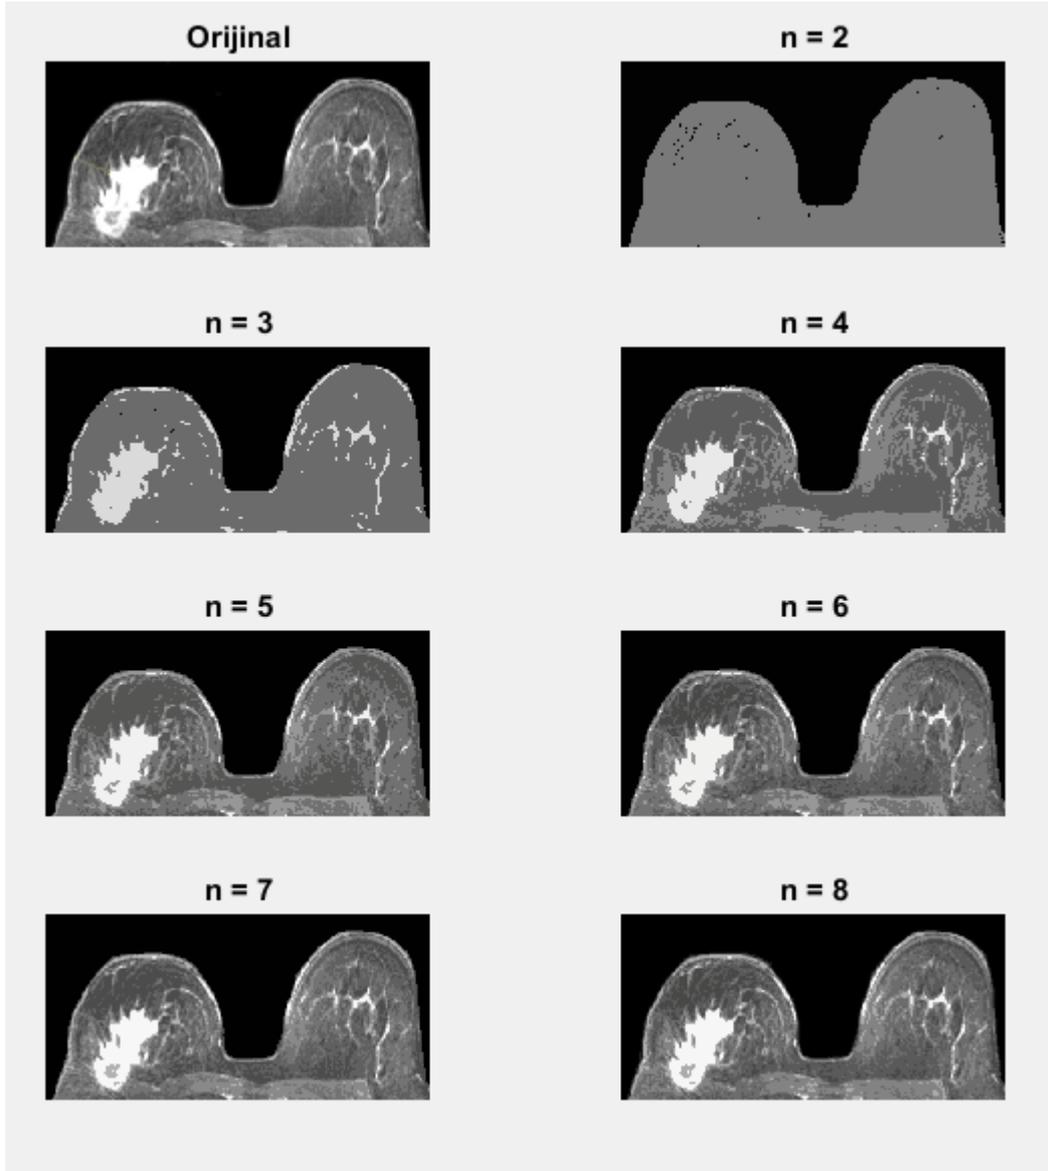
Segmentasyon varyansı σ_w^2 Denklem 3.21'deki gibi tanımlansın

$$\sigma_w^2 = \sum_{i=0}^{k-1} h_i \sigma_i^2 \quad \text{Denklem (3.21)}$$

burada $h_i = \sum_{v \in S_i} h(v)$ rasgele bir pikselin segmentasyonunda i kümesine ait olma olasılığıdır. S_i aralığındaki değerler gri renk içermektedir. $\sigma_i^2 = \sum_{v \in S_i} (v - \mu_i)^2 h(v)$ i . kümenin grilik değerinin varyansı ve $\mu_i = \sum_{v \in S_i} v h(v)$ i . kümenin ortalama grilik değeridir. İlk olarak, $k-1$ adet eşik histogram üzerinde dağıtılmaktadır. Diğer bir ifade ile grilik seviyeleri eşit uzunlukta k parçaya bölünmektedir. Buna göre görüntü, belirlenen eşik değerlerine göre kümelere ayrılmaktadır. Her k küme bölümü için küme merkezleri ve kümeyi oluşturan iki eşik arasındaki yarıçap hesaplanmaktadır. İkinci adımda her küme için ortalama değer μ_i hesaplanır. Küme merkezleri hesaplanan μ_i değerlerine sıfırlanır. Daha sonra, belirlenen değerler merkez olarak seçilerek görüntü parçalara ayrılır. Yinelemeli olarak μ_i tekrar hesaplanarak aynı işlemler tekrar edilir. Küme merkezleri artık hareket etmeyecek düzeye geldiğinde işlem sonlandırılır [78].

Diğer yöntemlerden farklı olarak k-ortalama yönteminde üç kanallı (R, G, B) görüntü kullanılmaktadır. Elde edilen sonuçlar doğrultusunda diğer üç yönteme kıyasla gerçek değerlere en yakın olan sonuçların k-ortalama yöntemi ile elde edildiği gözlemlenmiştir. Şekil 3.10'de k-ortalama kümeleme yöntemi uygulanmış görüntü verilmiştir. Önceki yöntemlerle kolay kıyas yapılabilmesi amacı ile aynı MR görüntüsü kullanılmıştır. Şekil 3.10'de görüldüğü gibi lezyon sınırları oldukça belirgindir.

Şekil 3.10. k-Ortalama algoritması uygulanmış görüntü (8 Seviye)



3.2.2.5. Markov Rastgele Alanlar Yöntemi

MRF tek başına bir segmentasyon yöntemi değildir ancak başka bir segmentasyon yöntemi ile birlikte kullanılan istatistiksel bir modeldir. MRF yakındaki pikseller arasındaki uzamsal korelasyonu modeller. Bu yerel korelasyonlar çeşitli görüntü özelliklerinin modellenmesi için bir mekanizma sağlar. Medikal görüntüleme bu yöntem, aynı sınıfa ait pikselleri komşu pikseller olarak değerlendirmek amacıyla kullanılır. MRF modellerinde karşılaşılan zorluk, uzamsal etkileşimlerin gücünü kontrol eden parametrelerin uygun seçilmesidir. MRF'ler MR görüntülerinde ve doku özelliklerinde oluşan heterojenliklerin modellenmesinde de yaygın olarak kullanılmaktadır.

MRF yöntemini görüntü segmentasyon için kullanmak çeşitli avantajlar sağlamaktadır. Bu avantajların ilki, uzamsal ilişkilerin sorunsuz bir şekilde segmentasyon işlemine dâhil edilebilmesidir. İkincisi ise, MRF segmentasyon modelinin birçok farklı görüntü türlerinde kullanılan Bayes çerçevesinde sonuçlar üretebilmesidir. Sonuncusu ise, MRF modelindeki olasılıklar maksimum yapılarak etiket dağılımının elde edilebilmesidir. MRF yönteminin görüntüye uygulanabilmesi için geliştirilen birçok algoritma vardır. Bunlar arasında en başarılı sonuçlar üreten ve hesap yükü az olan bir algoritma belirlemek oldukça önemlidir.

Bu projede detayları aşağıda açıklanan bir algoritma seçilmiştir. Algoritma, bölge etiketleme bileşeni ve özellik modelleme bileşeni olmak üzere iki bileşen içermektedir. Bölge etiketleme bileşeni görüntü segmentasyon işlemine bir homojenlik kısıtı koyarken özellik etiketleme bileşeni özellik verisine uygunluğu garanti eder. Bu iki bileşenin ağırlıkları ve parametreleri, eğitim verisi ile elde edilir [79].

Segmentasyon problemi Bayes kuralı çerçevesinde ifade edilmektedir. $(X=x)$ şeklinde rastgele bir görüntüden çıkarılan özellik vektörü $F=f$ şeklinde gösterilsin. Burada F bir rastlantı değişkeni ve f , F değişkeninin aldığı bir değerdir. $Y=y$, $F=f$ özellik vektörüne bağlı olarak değer alan segmentasyon sonucunu ifade etmektedir. Bayes kuralına göre, segmentasyon problemi Denklem 3.22'deki gibi formüle edilmektedir.

$$P(Y = y \mid F = f) = \frac{p(F = f \mid Y = y) P(Y = y)}{p(F = f)} \quad \text{Denklem (3.22)}$$

Burada $P(Y=y \mid F=f)$, $F=f$ koşulu altında $Y=y$ 'nin sonsal olasılığını, $p(F=f \mid Y=y)$ $Y=y$ koşulu altında $F=f$ 'in önsel olasılığını ve $p(F=f)$ ise $F=f$ 'in olasılık dağılımını göstermektedir. Basit bir MRF tabanlı segmentasyon modeli elde etmek için yapılması gereken birkaç kabul vardır. İlk kabul, $F=f$ 'in her bir bileşeninin $Y=y$ koşulu altında diğer bileşenlerden bağımsız olmasıdır (koşullu bağımsızlık). Özellik vektöründe K adet bileşen olduğunu varsayalım, $f = \{f^k \mid k = 1, 2, \dots, K\}$. Bu durumda Denklem (3.22) şu şekilde ifade edilir:

$$P(Y = y \mid F = f) = \frac{\prod_{k=1}^K [p(f^k \mid Y = y)] P(Y = y)}{p(F = f)} \quad \text{Denklem (3.23)}$$

Burada $p(f^k \mid Y = y)$, segmentasyon sonucu $Y=y$ koşulu altında çıkarılan özellik bileşeni f^k 'nin olasılık dağılımını göstermektedir.

$F=f$ bilindiğinde, $p(F=f)$ 'nin aldığı değer $Y=y$ 'nin aldığı değere göre değişmez dolayısıyla $P(Y=y \mid F=f)$ olasılığı maksimum yapılırken bu olasılık ihmal edilebilir. $P(Y=y)$ sadece bir segmentasyon sonucunun etiket dağılımını gösterir ve genellikle bölge etiketleme bileşeni olarak adlandırılır. MRF segmentasyon modellerinin çoğu, etiketleme dağılımını modellemek için MLL (multi-level-logistic, çok seviyeli lojistik) modelini kullanır. Genel olarak, bir segmentasyon işlemi için, ikinci dereceden ikili MLL modeli tercih edilir ve ikili

olmayan tüm kliklerin potansiyelleri sıfır olarak tanımlanır. İkili MLL modelinin enerjisi Denklem 3.24'de verilmiştir.

$$E_R(y) = \sum_s \left[\beta \sum_{t \in N_s} \delta(y_s, y_t) \right] \quad \text{Denklem (3.24)}$$

Burada, $y_s = y_t$ ise $\delta(y_s, y_t) = -1$, $y_s \neq y_t$ ise $\delta(y_s, y_t) = 1$ 'dir. β ise önsel olarak belirlenen bir sabittir. $E_R(y)$ görüntü bölgelerine ilişkin enerjidir. Denklem (3.22)'deki bölge etiketleme bileşeni olarak bu ikili MLL modeli seçilirse, $P(Y = y)$ için Gibbs rastgele alanı (Gibbs Random Field, GRF) şu şekilde ifade edilir.

$$P(Y = y) = \frac{1}{Z_R} \exp \left[-\frac{1}{T} E_R(y) \right] \quad \text{Denklem(3.25)}$$

Denklem 3.25'de $Z_R = \sum_{y \in \Omega_Y} \left(\frac{1}{Z_R} \right) \exp \left[-\left(\frac{1}{T} \right) E_R(y) \right]$ normalizasyon sabitidir. Ω_Y , S üzerinde mümkün tüm $Y=y$ kümesini temsil eder.

En son durumda sadece $p(f^k \setminus Y = y)$ bilinmeyedir. Özellik çıkarma algoritmalarının çoğu sınıf içerisindeki piksellerin tamamı için düzgün bir cevap çıkarmak için tasarlansa da, çıkarılan görüntü özellikleri sıklıkla görüntüde gürültü olmasından ve/veya aynı içerikli bölgelerde piksel dağılımlarının durağan olmamasından dolayı değişmektedir. Bir sınıf için özellik verisi, normal dağılımlı olarak kabul edilebilir. Özellik verisinin dağılımı Gauss dağılımı olmasa bile, Gauss fonksiyonu yaklaşık olarak kullanılabilir. İkinci kabul, özellik verisinin tümünün μ_m^k ortalama değerli ve σ_m^k varyanslı Gauss fonksiyonu olduğudur. Bu durumda;

$$p(f_s^k | Y_s = m) = \frac{1}{\sqrt{2\pi\sigma_m^k}} \exp \left[-\frac{(f_s^k - \mu_m^k)^2}{2\sigma_m^{k2}} \right] \quad \text{Denklem (3.26)}$$

Burada μ_m^k ve σ_m^k sırasıyla m. sınıftaki k. özelliğin ortalama değeri ve standart sapmasıdır. $p(f_s^k | Y_s = m)$ değerlerinin çarpımı bir görüntü için özellikleri tanımlar ve genellikle Eşitlik 3.22'de verilen özellik modelleme bileşeni olarak kabul edilir. Bu çarpımın enerjisi Denklem 3.27'deki eşitlikle hesaplanır:

$$E_F = \sum_{s, m=Y_s} \left\{ \sum_{k=1}^K \left[\frac{(f_s^k - \mu_m^k)^2}{2(\sigma_m^k)^2} + \log(\sqrt{2\pi}\sigma_m^k) \right] \right\} \quad \text{Denklem(3.27)}$$

Son olarak, $P(Y = y \setminus F = f)$ 'nin enerjisi,

$$E = E_R + \alpha E_F \quad \text{Denklem (3.28)}$$

olur. Denklem 3.28'de α , E_R ve E_F 'nin toplam enerji E üzerindeki etkisinin ne kadar olduğunu belirler. Bu son eşitlik MRF eşitliği olarak kullanılır.

MRF modellerinin gerçekleştirilmesinde en önemli ölçütlerden biri maksimum sonsal olasılık (maximum a posteriori, MAP) ölçütüdür. Denklem (3.28) ile verilen model için, MAP aşağıdaki Denklem 3.29'daki eşitliklerden herhangi biri ile ifade edilebilir.

$$\begin{aligned}\hat{y} &= \arg \max_{y \in \Omega_Y} P(Y = y | F = f) \\ &= \arg \max_{y \in \Omega_Y} \frac{1}{Z} \exp\left(-\frac{1}{T} E\right) \\ &= \arg \min_{y \in \Omega_Y} E\end{aligned}\quad \text{Denklem(3.29)}$$

Denklem (3.29), sonsal koşullu olasılık dağılımının maksimum yapılması anlamına gelmektedir. Bu, aynı zamanda modelin enerjisinin minimum yapılmasına eşdeğerdir. Enerji fonksiyonu konveks ise, deterministik algoritmalarla enerji fonksiyonun global minimumunu bulmak kolaydır. Ancak, birçok durumda, enerji fonksiyonu konveks değildir. Bu nedenle algoritmaların bir kısmı yerel minimuma yakınsar. Bu projede global minimumu garanti etmek için benzetimli tavlama (simulated annealing, SA) metasezgisel optimizasyon yöntemi kullanılmıştır. En yaygın olarak kullanılan SA yöntemi [80] ile verilen logaritmik SA yöntemidir.

$$T(t) = \frac{C}{\log(t + 1)}, C \text{ sabit ve } t \geq 1 \quad \text{Denklem (3.30)}$$

Nümerik uygulamalar logaritmik yöntemin, sonlu iterasyonlarda optimal olmayan sonuçlar verdiğini göstermektedir. Bu nedenle logaritmik SA yöntemi, MRF modelini optimize etmek ve segmentasyon sonuçlarını üretmek için kullanılmıştır.

MRF algoritmasının gerçekleştirilmesi için, β , α , μ ve σ olmak üzere dört parametre kestirilmelidir. μ ve σ 'nin her bir sınıf için kestirilmesi için eğitim verisi gerekir. Ancak, denetimli olmayan uygulamalarda eğitim verisi mevcut değildir. Beklenti-maksimizasyon (expectation-maximization, EM) algoritması μ ve σ 'nin kestiriminde ve bir segmentasyon haritası elde etmek için kullanılır. Basit bir MRF modeli için EM algoritması şu şekilde verilir:

- i. Başlangıçta rastgele bir segmentasyon gerçekleştirilir.
- ii. Segmente edilmiş görüntüye göre, $F=f$ özellik verisinden μ ve σ kestirilir. Bu amaçla aşağıdaki eşitlikler kullanılır.

$$\mu_m^k = \frac{1}{N} \sum_{s, Y_s=m} f_s^k \quad \text{Denklem (3.31)}$$

$$\sigma_m^k = \left[\frac{1}{N-1} \sum_{s, Y_s=m} (f_s^k - \mu_m^k)^2 \right]^{1/2} \quad \text{Denklem (3.32)}$$

- iii. μ ve σ kestirimleri, Eşitlik (3.32)'i minimum yapmak için, yeni bir görüntü segmentasyonu elde etmede kullanılır. Minimumlaştırma için benzetimli tavlama yönteminden yararlanır.
- iv. Durma ölçütü sağlanana kadar yukarıdaki üç adım tekrarlanır.

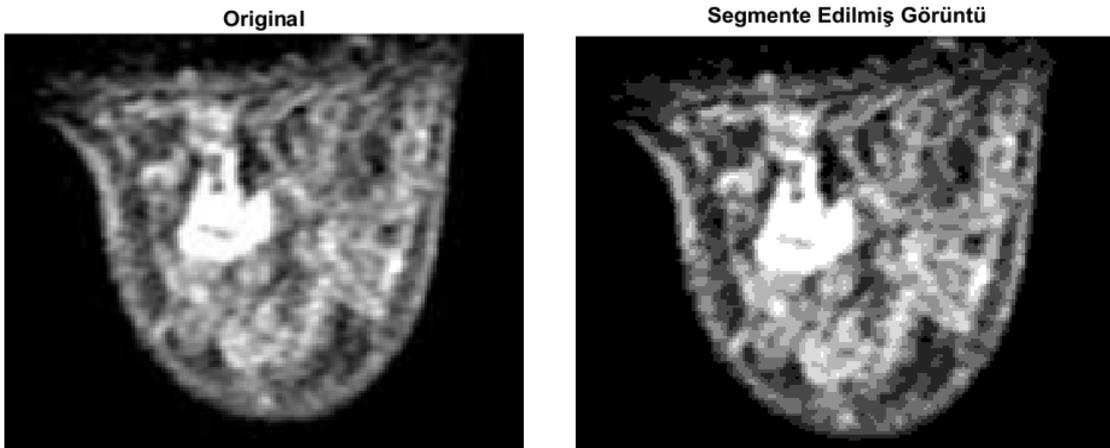
Görüldüğü gibi EM algoritmasında β ve α parametrelerini elde etmek için kapalı formda bir çözüm bulunmamaktadır. Bu parametrelerin değerlerini belirlemek için kullanılan en yaygın yöntem EM algoritmasını uygulamadan önce deneysel olarak β ve α değerlerinin atanmasıdır. Her iki parametre de enerji bileşenlerinin ağırlıklarını belirlediğinden bu parametrelerden biri sabit tutulabilir. Projemizde $\beta=1$ seçilmiştir dolayısıyla sadece α parametresi ayarlanmalıdır.

Denetimsiz segmentasyon boyunca α parametresi değiştirilmiştir. Bu parametrenin belirlenmesi hem özellik modelleme bileşeninin global öğrenmek için segmentasyon modelini etkinleştirir hem de etiket dağılımlarında uzamsal homojenlik kısıtını sağlar. Bu amaçla, parametre tavlama işleminde uygun olarak değişmelidir. Projemizde ağırlıklandırma parametresi α Denklem 3.33'deki gibi belirlenmiştir.

$$\alpha(t) = c_1 0.9^t + c_2 \quad \text{Denklem (3.33)}$$

Burada c_1 ve c_2 sabittir. Veritabanına uygun olarak belirlenmelidir. K segmentasyon için kullanılan özelliklerin sayısı olmak üzere $c_1 = 80$ ve $c_2 = 1/K$ olarak seçilir. Geliştirilen model sayesinde özellik modelleme bileşeni ilk olarak MRF modelinin global parametreleri öğrenmesini sağlayacak daha sonra bölge etiketleme bileşenleri ile etkileşimde bulunarak segmentasyon sonuçlarını güncelleyecektir.

Şekil 3.11. (a) Orijinal MR Görüntüsü, (b) MRF ile segmente edilmiş görüntü



3.2.2.6. Aktif Sınırlar Modeli

Aktif sınırlar ya da yılanlar ilk olarak Kass ve arkadaşları tarafından tanıtılmıştır ve model daha sonra Cohen tarafından geliştirilmiştir [81]. Yılanlar enerji minimumlaştırma eğrileri olarak bilinirler. Yılanların enerjileri iç ve dış kuvvetler vasıtasıyla belirlenir. Genellikle dâhili kuvvetler eğrinin düzgün olmasını sağlarken dış kuvvetler yılanı sınırlar gibi ilgi (çekim) bölgelerine doğru çeker. Sınırların belirlenebilmesi için dış kuvvetlerin görüntünün gradyanına göre oluşturulması gereklidir. Zamana göre değişen aktif bir sınır, Denklem (3.34)'deki gibi ifade edilebilir.

$$v(s, t) = (x(s, t), y(s, t)), 0 \leq s \leq 1 \quad \text{Denklem (3.34)}$$

Burada s, orantılı çizgi uzunluğu, t şimdiki zaman, x ve y ise görüntü üzerindeki koordinatlardır. Zaman ilerledikçe aktif sınır algoritması konumunu ve şeklini kendini etkileyen kuvvetlere göre değiştirir. Aktif sınır algoritması, toplam yılan enerjisini minimum yapacak biçimde yılanı deforme eder. Yılan enerjisi iç ve dış enerjilerin toplamı olarak Denklem (3.35)'de verilmektedir.

$$E_{top} = \int_0^1 E\{v(s, t)\}ds = \int_0^1 E_{int}\{v(s, t)\}ds + \int_0^1 E_{ext}\{v(s, t)\}ds \quad \text{Denklem (3.35)}$$

Burada E_{int} , iç enerjiyi E_{ext} ise dış enerjiyi temsil eder. İç enerji, yılanın seklinde dolayı sahip olduğu enerjidir. Bu enerji türü sayesinde yılan sınırları yakalamak için sert kavisler çizmez, yumuşak bir eğri sekline sahip olur. İç enerji, Denklem (3.37)'de verildiği gibi hesaplanabilir.

$$E_{int} = \int_0^1 \frac{1}{2} [\alpha |x'(s)|^2 + \beta |x''(s)|^2] ds \quad \text{Denklem (3.37)}$$

$x'(s)$ ve $x''(s)$ birinci ve ikinci türevleri belirtirken α ve β yılanın elastikliğini ve katılığını düzenleyen değerlerdir. Elastiklik kuvveti yılanın uzamasına karşı bir kuvvettir. Katılık ise yılanın bükülmesine karşı bir kuvvettir. Yalnızca iç kuvvetler tarafından yönlendirildiğinde yılanın denge durumundaki şekli bir nokta olacaktır. Dış enerji, görüntüden elde edilir. Yılanın görüntü üzerinde sınırlar gibi ilgilenilen bölgelere yönelmesini sağlar. Genel olarak kullanılan dış enerji fonksiyonu Denklem (3.38) 'de verilmiştir.

$$E_{ext}(x, y) = -|\nabla[G_\sigma(x, y) * I(x, y)]| \quad \text{Denklem (3.38)}$$

Burada $G_\sigma(x, y)$, iki boyutlu Gaussian operatörü olup standart sapması σ 'dir. ∇ ise gradyen operatörüdür. Gaussian operatörü sayesinde görüntü bulanıklaşacak, böylece gradyen ile aranan görüntü sınırları daha çok yayılacaktır. Bu işlem kenar noktalarını arayan yılanın kapsama alanını artıracaktır. Denklemdaki – işareti, sınırlarda enerjinin minimum olması gerektiği için kullanılmaktadır.

Denge durumunda bir yılanın iç ve dış enerji toplamı 0 olacaktır. Kuvvet dengesi aşağıdaki biçimde ifade edilebilir:

$$F_{int} + F_{ext} = 0 \quad \text{Denklem (3.39)}$$

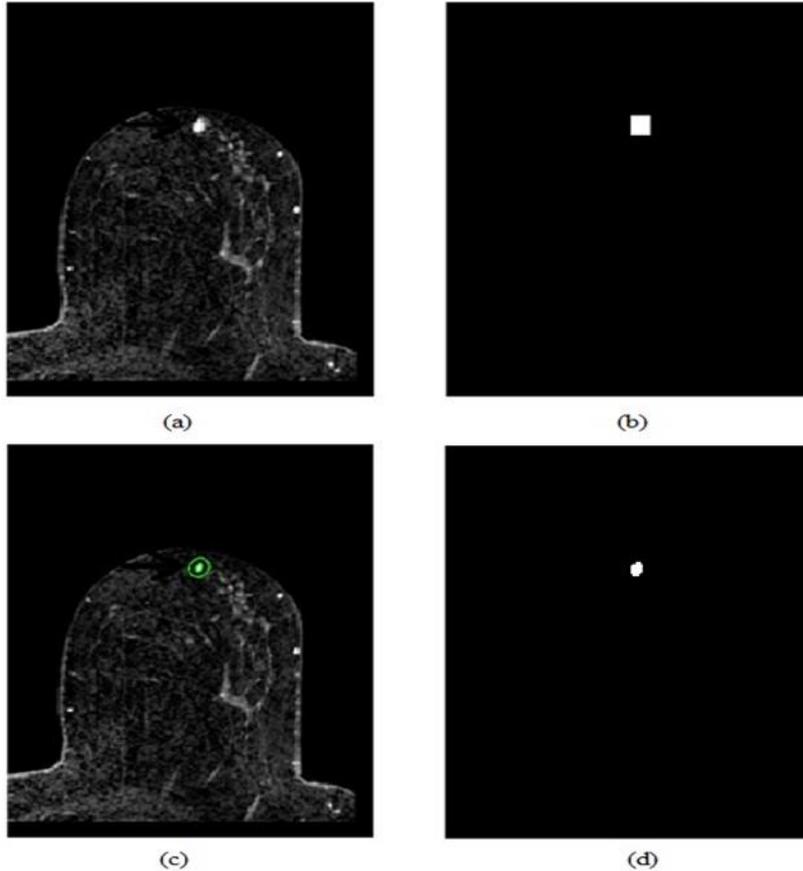
Dış ve iç kuvvetler Denklem (3.40)'de belirtilmiştir.

$$F_{int} = \alpha x''(s) - \beta x''(s), F_{ext} = -\nabla E_{ext} \quad \text{Denklem (3.40)}$$

İç kuvvetler yılanın gerilip büzülmesini engellerken dış kuvvetler yılanın sınırlara doğru yönelmesini sağlayacaktır. Aktif sınırlar ile görüntüde bir nesnenin kenarlarını çıkarmak için aranan nesne yakınlarına kapalı bir eğri yerleştirilmelidir. Daha sonra tekrarlı bir şekilde her defasında enerjisi azaltılmak üzere yılan kenar koordinatları güncellenir.

Aktif sınırların temel avantajları, kapalı eğriler oluşturmaları ve iç enerjilerinden dolayı (düzgün bir şekle sahip olacağından) gürültüye karşı duyarsız oluşlarıdır. Aktif sınırlar medikal görüntü işlemede popüler bir yöntem olmasına karşın düzgünlük ve katılık parametrelerinin uygun seçilmesi gerekliliği ve (kapsama alanı probleminden ötürü) ilgilenilen nesneye yakın yerlerde başlatılmaları zorunluluğu aktif sınırların başlıca kısıtlamalarındandır. Bunların yanında aktif sınırlar iç enerjilerinin kısıtlamalarından dolayı konkav bölgeleri bölütleyememektedirler.

Şekil 3.12. Kötü huylu oldukça küçük bir lezyon içeren bir MR görüntüsü için aktif sınırlar yöntemi (a) Orijinal görüntü, (b) Başlangıç alanı, (c) Tespit edilen bölge, (d) İki seviyeli lezyon görüntüsü.



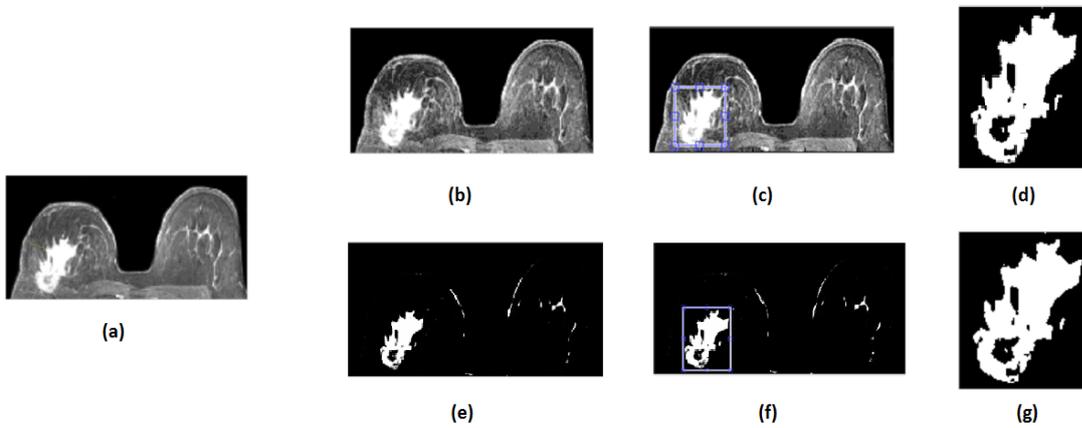
3.2.3. Lezyon Alanının Hesaplanması

Bir görüntüde nesnelerin şeklini karakterize etmek için birçok niceliksel ve niteliksel teknik geliştirilmiştir. Bu teknikler, bir görüntü tanıma sisteminde nesnelere sınıflandırmak için ve bir görüntü anlama sisteminde nesneyi sembolik olarak tanımlamak için oldukça faydalıdır. Tekniklerden bazıları sadece iki seviyeli görüntülere uygulanırken diğerleri grilik seviyeli görüntüler için de uygulanabilir hale getirilebilir.

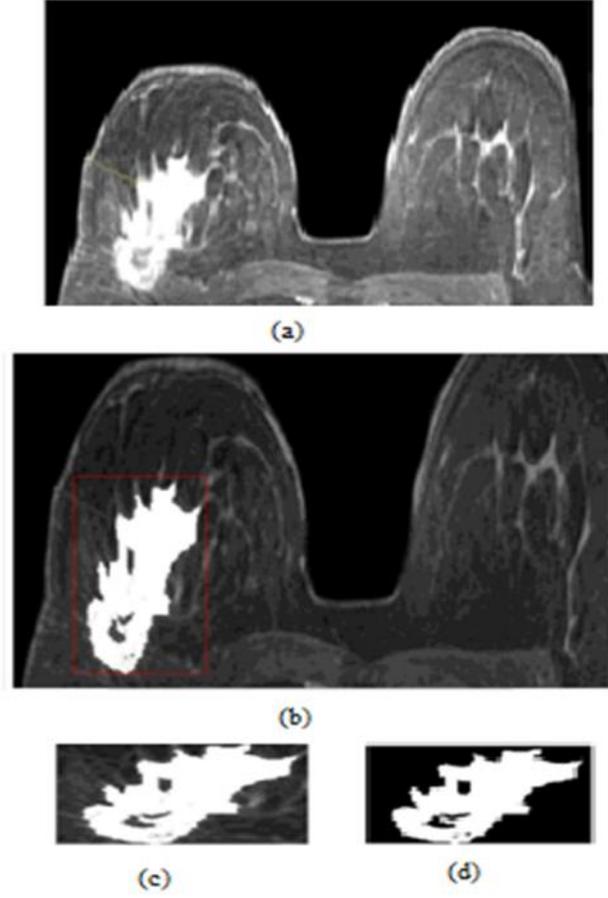
Önceki bölümde meme MR görüntülerinde lezyonun tespit edilmesi ve sınırlarının belirlenmesi amacıyla kullanılan segmentasyon teknikleri tartışılmıştı. Bu bölümde amacımız sınırları belirlenen lezyonun kapladığı alanı bulmaktır. Segmentasyon adımından sonra elde edilen görüntülerdeki verileri değerlendirmek meme kanseri teşhis ve tedavisi için büyük önem arz etmektedir. Meme kanserinde lezyonun çevresi, alanı ve şekil bilgileri hastaya uygulanacak tedavi yönteminin belirlenmesinde kullanılmaktadır. Dolayısıyla bu bölümde yapılacak işlemler ve elde edilen sonuçlar meme kanseri değerlendirmelerinde radyologlar için oldukça değerlidir.

Şekil 3.13. (a)'da kötü huylu lezyon bulunan orijinal bir MR görüntüsü verilmiştir. Lezyon sınırlarının belirlenmesi amacıyla görüntüye uygulanan segmentasyon yöntemi üst kolda Otsu, alt kolda ise FCM'dir. Otsu 'da sınıf sayısı bu görüntü için sekiz olarak seçilmiştir. Üst ve alt kol için, segmentasyon yöntemi uygulanmış görüntü, lezyonun bulunduğu bölge ve iki seviyeli lezyon görüntüsü sırayla verilmiştir.

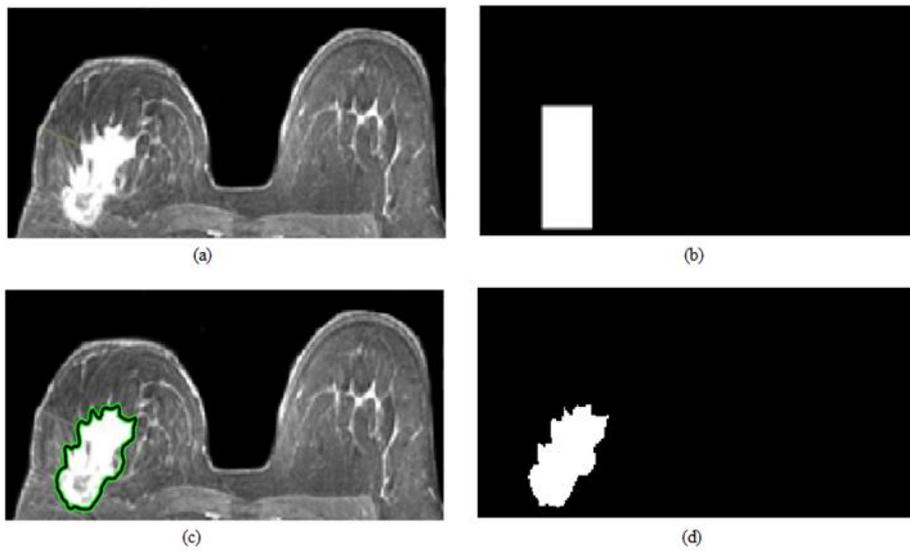
Şekil 3.13. Otsu ve FCM yöntemleri uygulanmış ve lezyon bölgeleri tespit edilmiş MR görüntüleri



Şekil 3.14. RG yöntemi uygulanmış MR görüntüsü, (a) Orijinal görüntü, (b) Segmentasyon uygulanmış görüntü, (c) Orijinal görüntüde lezyon bölgesi, (d) İki seviyeli lezyon bölgesi görüntüsü



Şekil 3.15. Kötü huylu oldukça küçük bir lezyon içeren bir MR görüntüsü için aktif sınırlar yöntemi (a) Orijinal görüntü, (b) Başlangıç alanı, (c) Tespit edilen bölge, (d) İki seviyeli lezyon görüntüsü



Bir görüntüdeki nesneyi tanımlarken temel olarak üç yaklaşım ele alınmaktadır. Bunlar: sınır tanımlayıcılar, bölgesel tanımlayıcılar ve ilişkisel tanımlayıcılardır. Şekil 3.13'deki görüntüler dikkate alındığında kötü huylu lezyonun bölgesel bir alan kapladığı görülmektedir. Bu çalışmada bölgesel ve topolojik tanımlayıcılar kullanılarak lezyonun alanı, çevresi ve daireselliği hesaplanmıştır. Aşağıda bölgesel tanımlayıcılar ayrıntılı olarak açıklanmıştır.

3.2.3.1. Bölgesel ve Topolojik Tanımlayıcılar

Görüntüde bir bölgenin alanı, kapsadığı pikseller ve çevresi o bölgenin sınırının uzunluğu olarak ifade edilmektedir. Görüntüde alan ve çevre hesabı, ilgilenilen (araştırılan) bölgenin değişken olması durumunda tercih edilmektedir. Çevre ve alan ikilisi ilgilenilen bölgenin daireselliği hakkında da bilgi vermektedir. Dairesellik oranı,

$$R = \frac{4\pi A}{P^2} \quad \text{Denklem (3.41)}$$

ile hesaplanır. Denklem (3.41)'da A ilgilenilen bölgenin alanını, P'de çevresini temsil etmektedir. İlgilenilen bölge veya nesne tam dairesel olduğunda değeri 1 çıkar. İlgilenilen bölge veya nesne bir kare ise değerinin sonucunun olmaktadır. Bölge tanımlayıcılar olarak adlandırılan çeşitli parametreler mevcuttur. Bunlar; yeğlilik seviyelerinin ortalaması, ortancası, minimum ve maksimum değerleri gibi parametrelerdir [76].

Topolojik tanımlayıcılar, görüntü üzerinde belirlenen bölgelerin global tanımlamaları için kullanılmaktadır. Topoloji genel olarak, görüntüdeki geometrik cisimlerin nitel özelliklerini ve bağıl konumlarını biçimlerinden ve büyüklüklerinden ayrı olarak ele alan bir bilim dalıdır. Meme MR görüntülerinde her hastaya ait veriler farklı boyut, çevre ve biçime sahip olduğundan, çalışmada topolojik yapılardan da yararlanılmaktadır. Elde edilen sonuçlar her hastaya göre değerlendirilip gerekli tedavi yöntemlerinin seçilmesi aşamasında verileri anlamlı hale getirmek için topolojik tanımlayıcılar büyük önem taşımaktadır.

Projenin bu aşamasında topolojik ve bölgesel tanımlayıcılardan faydalanılarak geliştirilen alan, çevre ve dairesellik hesabı için kullanılan iki seviyeli bit-dörtlüsü tekniği uygulanmıştır. Bit-dörtlüsü tekniği alt bölümde açıklanmaktadır.

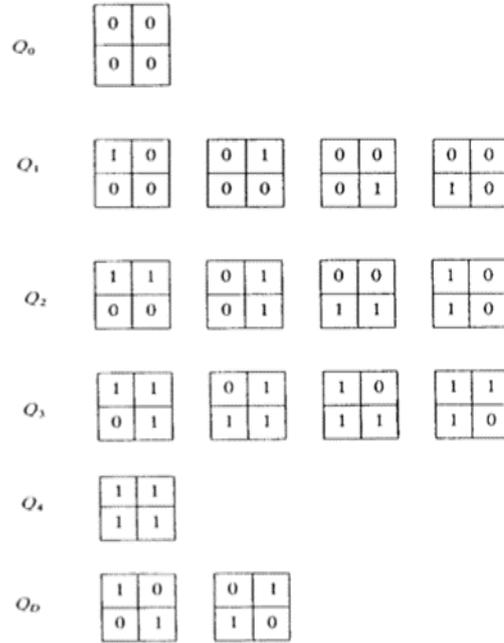
3.2.3.2. Bit Dörtlüsü Yöntemi

Grilik seviyeli, bir görüntüdeki bölgelere atanmış mantıksal değerlerin (1 veya 0) belirli yapılarla eşleştirmesine dayalı olarak, iki seviyeli görüntülerde nesnelere alan ve çevresini hesaplamak amacıyla sistematik bir yöntem geliştirmiştir. Bu amaçla, her biri 0 veya 1 değerinde olan görüntü karelerinde dörtlü bit hücreleri aranmaktadır. Bir bit dörtlüsü,

2x2 boyutlarında bir dizi veri hücresinden meydana gelmektedir. Bit dörtlüleri olarak adlandırılan piksel desen kümesi Şekil 18'de verilmektedir.

Sunulan sistemde, meme MR görüntülerinde lezyon alanı belirlenen ve iki seviyeli görüntüye dönüştürülen verinin Şekil 3.18'da belirtilen her bit dörtlüsü deseni ile eşleştirilmesi yapılarak lezyon alanı, çevresi ve daireselliği hesaplanmaktadır. Öncelikle, her bir bit dörtlü deseni elde edilen iki seviyeli görüntü üzerinde gezdirilerek eşleşen dörtlülerin sayısı kaydedilmektedir. Daha önce de bahsedildiği gibi segmentasyon işlemi ile lezyon sınırları tespit edilmiş ve lezyonun bulunduğu bölge seçilmiş görüntüde 0 olan pikseller siyah 1 olan pikseller beyaz bölgeleri temsil eder. Lezyon, kontrast tutulumundan dolayı beyaz pikseller içermektedir.

Şekil 3.18. Bit dörtlü desen kümesi [82]



Şekil 3.18'da verilen desenlerden de görüldüğü gibi deseni tamamen siyah piksellerden oluşmuştur. Dolayısıyla lezyon bölgesinde değildir ve alan için bir anlam ifade etmez. Desenleri her farklı köşesinde 1 değeri bulunan desenlerdir. Alan için bir birimlik katkı sağlayacakları açık olarak anlaşılmaktadır. Benzer şekilde ve desenleri de yorumlanabilir. Bu yorumlardan faydalanarak alan ve çevre hesabı için anlamlı ifadeler elde etmek mümkündür. Eşleşen verilerden yararlanarak belirlenen nesnenin alanı Denklem (3.42), çevresi ise Denklem (3.43) kullanılarak hesaplanabilir.

$$A_0 = \frac{1}{4} [n\{Q_1\} + 2n\{Q_2\} + 3n\{Q_3\} + 4n\{Q_4\} + 2n\{Q_D\}] \quad \text{Denklem (3.42)}$$

$$P_0 = n\{Q_1\} + 2n\{Q_2\} + n\{Q_3\} + 2n\{Q_D\} \quad \text{Denklem (3.43)}$$

Bu formüller Duda tarafından geliştirilmiştir. Son olarak, elde edilen lezyon alan ve çevresinden faydalanarak Denklem 3.44 ile lezyon daireselliği hesaplanmaktadır.

$$C_0 = \frac{4\pi A_0}{P_0^2} \quad \text{Denklem (3.44)}$$

Bit dörtlüsü yöntemi kullanılırken dikkat edilmesi gereken husus şudur. Eğer görüntünün boyutları uygun değilse bit dörtlüsünün tam olarak görüntüde gezdirilmesi için görüntünün boyutları ayarlanmalıdır [82]. Şekiller 3.13, 3.14 ve 3.15’de verilen görüntü için bit dörtlüsü yöntemi kullanılarak elde edilen alan, çevre ve dairesellik değerleri Tablo 3.3’de verilmiştir.

Tablo 3.3. Kullanılan yöntemler ile hesaplanan alan, çevre ve dairesellik değerleri

Yöntem	Otsu	FCM	Aktif Sınırlar	RG
Alan	3592	3495	4990	3410
Çevre	562,75	594,84	435	589,095
Dairesellik	0,14	0,12	0,33	0,41

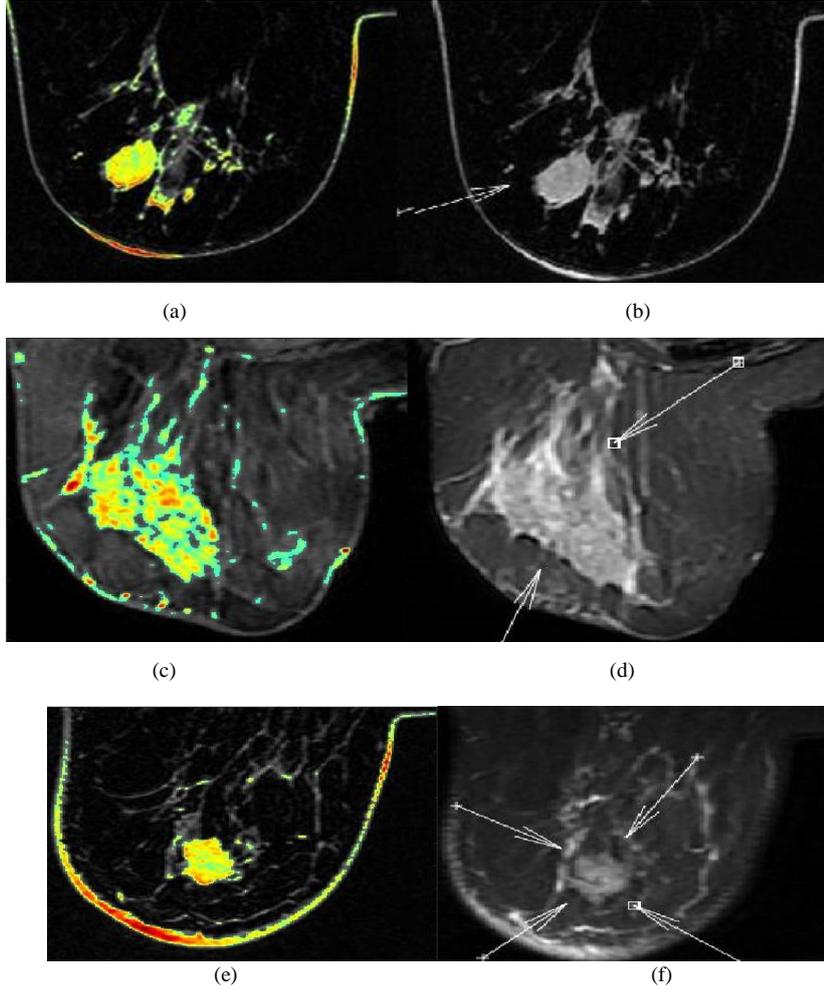
3.2.4. Lezyon Renk Tabakası

Projenin segmentasyon adımı son olarak segmentasyon adımı tamamlanmış lezyonların renk tabakaları (color overlay) elde edilmiştir. Lezyonların renk tabakaları lezyonun iyi ya da kötü huylu oluşları hakkında bilgi vermektedir. Renk tabakalarında renk dağılımı kırmızıya doğru gittikçe lezyonu n kötü huyluluk düzeyi de artmaktadır. Şekil 3.14’de Otsu ve MRF yöntemleri uygulanmış üç farklı özellikte meme görüntülerine ait renk tabakaları gösterilmiştir. Şekil 3.14 (a), (c) ve (e)’de lezyonlara ait renk tabakaları verilmiştir. Şekil 3.14 (b), (d) ve (f) ise uzman tarafından oklarla işaretlenmiş lezyon bölgelerini göstermektedir. Bazı memelerde kötü huylu lezyonlar meme duvarında kalınlaşma ve bozulmaya sebep olduğundan bu bölgelerde de kırmızılıklar elde edilmiştir. Bu sayede segmentasyon adımının tüm meme alanında meydana gelen bozuklukların tespitinde oldukça faydalı olduğu da söylenebilir.

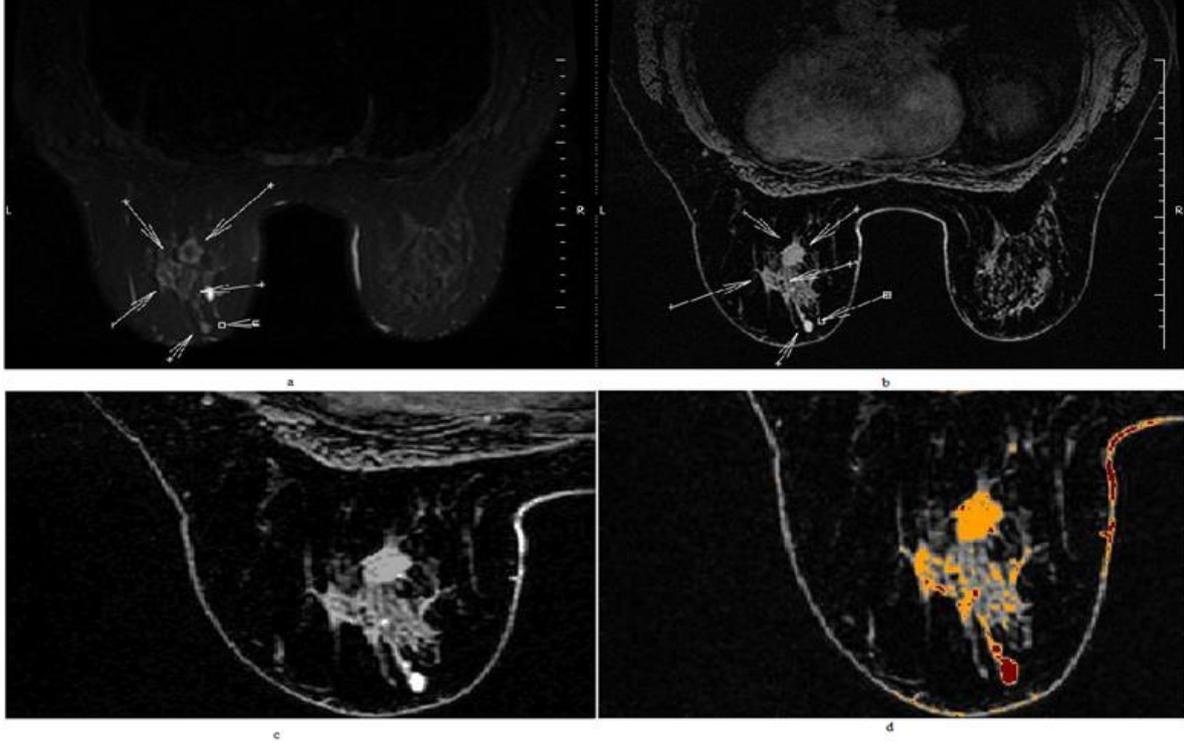
Projede segmentasyon başarımını artırmak amacıyla iki yöntemin ardarda kullanıldığı hibrit segmentasyon adımı da gerçekleştirilmiştir. Şekil 3.15’de Otsu eşikleme yöntemi ile MRF yönteminin ardarda uygulandığı segmente edilmiş bir görüntü verilmektedir. Şekil 3.15 (a) Okla işaretlenmiş T2-ağırlıklı yağ baskılı MR görüntüsünü, (b) T1-ağırlıklı yağ baskılı kontrast sonrası görüntüyü, (c) Otsu ve MRF tabanlı hibrit segmentasyon sonucunu ve (d) segmente edilmiş görüntüye ait renk tabakasını göstermektedir. Bu örneğin bir diğer özelliği de hem T2 hem de T1 ağırlıklı görüntünün kullanılmasıdır.

Bir diğer şekilde iki ayrı lezyon içeren bir görüntü için segmentasyon sonucu verilmiştir. Şekil 3.16 (a) Birinci lezyon için okla işaretlenmiş T1-ağırlıklı yağ baskılı MR görüntüsünü, (b) İkinci lezyon için T1-ağırlıklı yağ baskılı kontrast sonrası görüntüyü, (c) k-ortalamalar tabanlı segmentasyon sonucunu ve (d) segmente edilmiş görüntüye ait renk tabakasını göstermektedir. Şekilden de görüldüğü gibi önerilen üç aşamalı segmentasyon süreci meme bölgesini belirlemede, lezyon bölgesini tespit etmede ve lezyonun tipi hakkında bilgi vermede oldukça etkili olmaktadır.

Şekil 3.19. Segmentasyon adımı tamamlanmış lezyonlar için renk tabakaları (a), (c) ve (e) renk tabakaları, (b), (d) ve (f) manuel olarak işaretlenmiş lezyon bölgeleri



Şekil 3.20. Segmentasyon adımı tamamlanmış lezyonlar için renk tabakaları (a) Okla işaretlenmiş T2-ağırlıklı yağ baskılı MR görüntüsü, (b) T1-ağırlıklı yağ baskılı kontrast sonrası görüntü, (c) Otsu ve MRF tabanlı hibrit segmentasyon sonucu, (d) segmente edilmiş görüntüye ait renk tabakası



3.2.5. Segmentasyon Sonuç

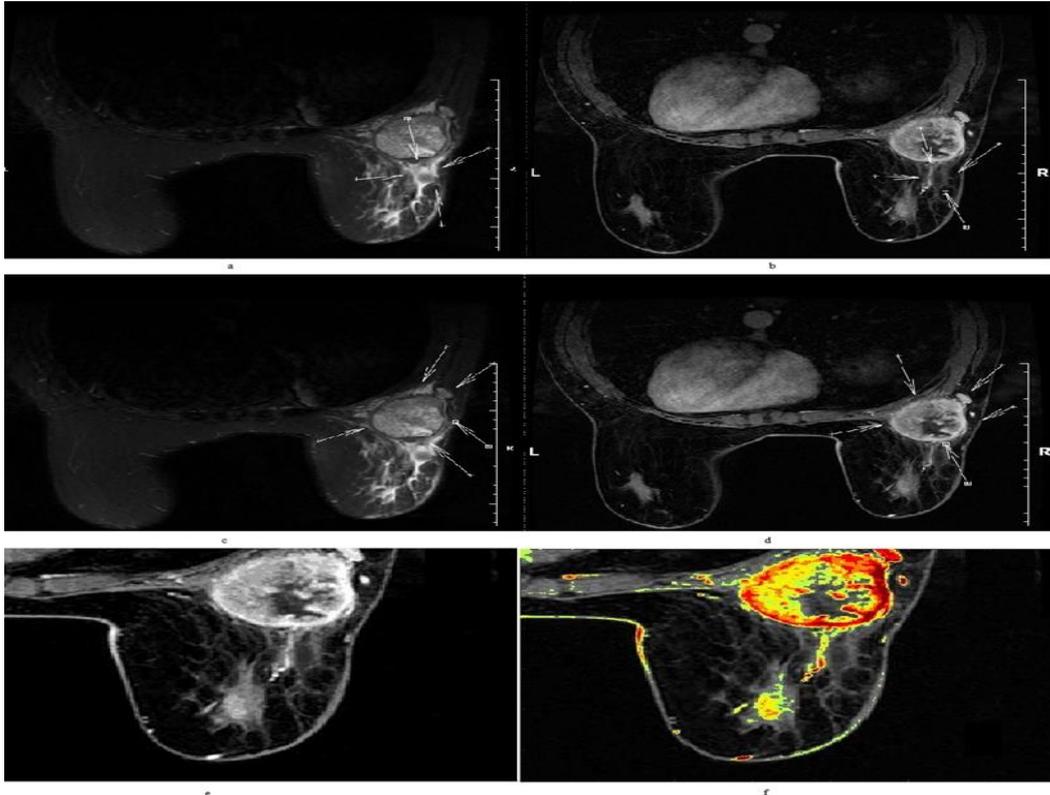
Projenin segmentasyon adımı ve elde edilen bulgular yukarıda detayları ile açıklanmıştır. Segmentasyon adımının hedefi memede bulunan lezyonların tespit edilmesi, lezyon bölgesinin ve sınırlarının doğru bir şekilde belirlenebilmesidir.

Projenin katkılarından biri hiçbir müdahale olmadan meme bölgesinin ve sağ-sol meme bölgelerinin ayrı ayrı tespit edilebilmesidir. İlgili bölgenin doğru bir şekilde tespit edilmediğinin belirlenmesi için uzman tarafından manuel olarak belirlenen bölge ile otomatik olarak belirlenen bölge birbiri ile karşılaştırılmıştır. DSC ve JC ölçütleri otomatik ve manuel segmentasyon sonuçlarını kıyaslamak için kullanılan ortalama ve birleşik örtüşme oranlarıdır. Projemizde DSC ve JC yüzdeleri sırasıyla 91 ± 0.06 ve 85 ± 0.08 olarak elde edilmiştir. Elde edilen sonuçlar meme bölgesi tespitinin başarılı bir şekilde gerçekleştirildiğini göstermektedir. Ayrıca, meme bölgesinin belirlenmesi sistemin hesap yükünü oldukça azaltmaktadır.

Projenin bir diğer katkısı, önerilen üç aşamalı segmentasyon süreci küçük lezyonlar da dâhil olmak üzere lezyonların büyük bir oranını tespit edebilmesidir. Lezyon tespitinde T1 ve T2 ağırlıklı görüntüler kullanılmıştır. Tablo 3.4’de projemizin segmentasyon süreci sonucu lezyon tespiti başarımını göstermektedir. Literatürdeki çalışmalarla kıyasla verilen bu tabloya göre, geliştirilen segmentasyon sürecinin lezyon tespiti hedefine ulaştığı, yalancı pozitif oranının oldukça düşük olduğu söylenebilir.

Lezyon tespiti doğru bir şekilde yapıldıktan sonra lezyon sınırlarının yani lezyonun kapladığı bölgenin de en yüksek doğrulukla tespit edilmesi gerekmektedir. Bu amaçla uzman tarafından manuel olarak işaretlenen lezyon bölgesi otomatik olarak belirlenen bölge ile kıyaslanmıştır. Bu kıyaslama proje ekibinde yer alan radyoloji uzmanı tarafından yapılmıştır. Radyoloji uzmanının incelemelerine göre otomatik olarak elde edilen lezyon bölgesi manuel olarak belirlenen bölge ile oldukça yakındır. Ayrıca, segmente edilmiş lezyonların renk tabakaları da uzman tarafından kontrol edilmiştir. Daha önce de belirtildiği gibi, renk kırmızıya doğru yaklaştıkça lezyonun kötü huyluluğu derecesi de artmaktadır. Radyolog tarafından bildirildiğine göre, renk tabakaları meme lezyonlarının sınıflandırılmasında oldukça faydalı bir bilgi sağlamaktadır.

Şekil 3.21. Segmentasyon adımı tamamlanmış lezyonlar için renk tabakaları (a) Birinci lezyon için okla işaretlenmiş T1-ağırlıklı yağ baskılı MR görüntüsü, (b) İkinci lezyon için T1-ağırlıklı yağ baskılı kontrast sonrası görüntü, (c) k-ortalamlar tabanlı segmentasyon sonucu, (d) segmente edilmiş görüntüye ait renk tabakası



Tablo 3.4. Segmentasyon sürecinin lezyon tespiti başarımı

Metot	Belirleme Oranı	Yalancı pozitif belirleme	Veri seti
Önerilen yöntem	1	0,14/durum	97 durum (74 kötü huylu ve 23 iyi huylu)
Shokouhi vd. [2017]	0,94	5,29/durum	76 durum (107 iyi huylu ve 63 kötü huylu)
Ertaş [2008]	1	0,64/durum	19 durum (19 iyi huylu ve 20 kötü huylu)
Chang [2014]	0,93	6,15/durum	54 durum (28 iyi huylu ve 67 kötü huylu)

3.3. Özellik Çıkarma

Görüntüden özellik çıkarma işlemi, görüntünün ayırt edici temel karakteristiklerini ya da niteliklerini belirleme işlemidir. Bazı özellikler doğrudan fark edilirken bazı özellikler görüntüye özel işlemler uygulandıktan sonra elde edilir ve yapay özellikler olarak adlandırılır. Doğal özellikler, bir bölgedeki piksellerin ışık şiddeti ve görüntünün grilik seviyeli dokusal yapısı olabilirken, görüntünün genlik histogramı ve uzamsal frekans spektrumu yapay özelliklere örnek olarak verilebilir. Özellik çıkarma adımında hedef hızlı hesaplanabilen, faydalı, ayırt edici bilgi veren, doğru sınıflandırma yapılabilmesini sağlayan özellikler tanımlamaktır. Özellik çıkarma işlemi gerçekleştirilirken atılan bilgiye dikkat edilmelidir. Eğer bu bilgi problemin çözümü için önemli ise tüm sistemin doğruluğu bundan etkilenir. Meme MR çekimleri esnasında kontrast öncesi ve sonrası evrelerden oluşan farklı ağırlıklarda yaklaşık yirmi dakikalık bir video kaydı alınmaktadır. Projenin özgün yönlerinden biri uzman doktor ile ortak incelemeler yapılarak hangi görüntülerin dikkate alınması gerektiğinin tespit edilmesidir. Bu işlem proje başarımını doğrudan etkileyen bir adımdır.

Projenin segmentasyon bölümünde açıklanan adımlar uygulanarak, her bir lezyon bölgesi tek tek elde edilmiştir. Özellik çıkarma aşamasında amacımız lezyonların kendilerine özgü bazı özelliklerini belirleyerek ayırt edilebilmelerini sağlamaktır. Bu sayede meme kanserinin teşhisinde önemli bir adım atılmış olur. Projemizde meme lezyonlarına ait histogram, şekil, doku ve frekans özellikleri elde edilmiştir. Bu özelliklerin tanımları ve nasıl elde edildikleri izleyen kısımlarda açıklanmıştır.

3.3.1. Histogram Özellikleri

Bilindiği gibi histogram, görüntüde nesne ya da örüntü tanıma uygulamalarında orijinal görüntünün birinci dereceden istatistiklerinden çok daha yararlı bilgiler sağlamaktadır. Bir görüntünün birinci dereceden histogramı basit olarak şu şekilde tanımlanabilir

$$P(b) \approx \frac{N(b)}{M} \quad \text{Denklem (3.45)}$$

Denklem (3.45)'de M toplam piksel sayısını, N(b) ise genlik değeri r_b olan piksellerin sayısını göstermektedir. Histogramın şekli görüntünün karakteri hakkında birçok ipucu vermektedir. Örneğin, dar bir aralık kaplayan histogram görüntünün düşük kontrastlı olduğunu gösterir. İki-şekilli (bimodal) histogram ise görüntünün farklı genlikli arka plana göre dar bir genlik aralığına sahip bir nesne içerdiği anlamı taşır. Aşağıdaki ölçütler birinci dereceden bir histogram için nicel şekil tanımlayıcılar olarak ifade edilmektedirler.

i. Ortalama

$$S_M = \bar{b} = \sum_{b=0}^{L-1} b \cdot P(b) \quad \text{Denklem (3.46)}$$

ii. Standart Sapma

$$S_D = \sigma_b = \left[\sum_{b=1}^{L-1} (b - \bar{b})^2 \cdot P(b) \right]^{\frac{1}{2}} \quad \text{Denklem (3.47)}$$

iii. Eğrilik (Skewness)

$$S_s = \frac{1}{\sigma_b^3} \sum_{b=0}^{L-1} (b - \bar{b})^3 \cdot P(b) \quad \text{Denklem (3.48)}$$

iv. Basıklık (Kurtosis)

$$S_K = \frac{1}{\sigma_b^4} \sum_{b=0}^{L-1} (b - \bar{b})^4 \cdot P(b) - 3 \quad \text{Denklem (3.49)}$$

v. Enerji

$$S_N = \sum_{b=0}^{L-1} [P(b)]^2 \quad \text{Denklem (3.50)}$$

vi. Entropi



$$S_E = - \sum_{b=0}^{L-1} P(b) \cdot \log_2(P(b)) \quad \text{Denklem (3.51)}$$

Denklem (3.49)'de verilen basıklık formülündeki 3 faktörü S_K değerini sıfır ortalamalı, Gauss şekilli bir histograma normalize etmek için kullanılır. Projede lezyonlara ait histogram özelliklerini hesaplamak için yukarıda verilen eşitlikler kullanılmış ve toplamda altı adet histogram özelliği hesaplanmıştır.

3.3.2. Doku Özellikleri

Doku, bir görüntüdeki bölgeleri ya da nesneleri algılamak ve tanımlamak için kullanılan en önemli ayırt edicilerden biridir. Doku özelliklerini elde etmek için geliştirilen mevcut birçok yöntem olmakla birlikte projede ikinci ve daha yüksek dereceden istatistikler kullanılarak elde edilen doku özellikleri kullanılmıştır [71]. Bu amaçla gri-seviye eş oluşum matrisi (Gray Level Co-occurrence Matrix, GLCM), gri-seviye koşu uzunluğu matrisi (Gray Level Run Length Matrix, GLRLM), komşu gri-seviye fark matrisi (Neighboring Gray Tone Difference Matrix, NGTDM) ve gri-seviye bağıllık matrisi (Gray Level Dependence Matrix, GLDM) tabanlı özellikler kullanılmıştır.

3.3.2.1. Gri-Seviye Eş Oluşum Matrisi

GLCM, bir görüntünün doku özelliklerini çıkarmak için kullanılan en popüler istatistiksel metotlardan biridir. Haralick tarafından geliştirilen bu yöntemde Tablo 3.5'de verilen on dört doku özelliği tanımlanmaktadır. Bu özelliklerin hesaplanması için öncelikle gri-seviye eş oluşum matrisinin oluşturulması gerekmektedir. Projede, GLCM özelliklerinin hesaplanmasına başlanmadan önce, meme MR görüntülerine önceki bölümde anlatılan segmentasyon adımları uygulanmıştır. Meme lezyon segmentasyonu aşamasında 32-seviye Otsu yöntemi kullanılmıştır. Buna göre aşağıda verilen eşitliklerde N_g ile gösterilen grilik seviyelerinin sayısı 32 olarak belirlenmiş olur. GLCM'ler genellikle farklı açılarda hesaplanmaktadır. Projede dört farklı açı için GLCM hesaplanmıştır. Bu açılar 0° , 45° , 90° ve 135° olarak seçilmiştir.

$P(i,j)$, GLCM matrisinin (i,j) . elemanı, $p(i,j)$ Eşitlik (4.8)'de verilen normalize edilmiş matris olsun.

$$p(i,j) = \frac{P(i,j)}{\sum_i \sum_j P(i,j)} \quad \text{Denklem(3.52)}$$

Tablo 3.5'de kullanılan p_x ve p_y notasyonları $p(i,j)$ matrisinin satırları ve sütunları toplanarak elde edilen marjinal olasılık matrisleridir. Bu matrisler aşağıda verilen eşitlik ile hesaplanmaktadır.



$$p_x = \sum_{j=1}^{Ng} P(i, j) , p_y = \sum_{i=1}^{Ng} P(i, j) \quad \text{Denklem (3.53)}$$

μ_x, μ_y ve σ_x, σ_y sırasıyla p_x ve p_y olasılık dağılımlarının ortalama değerleri ve varyanslarıdır. $p_{x+y}(k)$ ve $p_{x-y}(k)$ değerleri ise şu şekilde hesaplanır:

$$p_{x+y}(k) = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i, j), \quad k = 2, 3, \dots, 2Ng, \quad \text{for } i + j = k. \quad \text{Denklem (3.54)}$$

$$p_{x-y}(k) = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i, j), \quad k = 0, 1, \dots, Ng - 1, \quad \text{for } |i - j| = k. \quad \text{Denklem (3.55)}$$

Tablo 3.5'de verilen 12. ve 13. özellikler korelasyon hakkında bilgi vermektedir. $HXY1$, $HXY2$ ve HXY değerleri aşağıda verilen eşitlikler kullanılarak hesaplanır.

$$HXY1 = - \sum_i \sum_j p(i, j) \log\{p_x(i)p_y(j)\} \quad \text{Denklem (3.56)}$$

$$HXY2 = - \sum_i \sum_j p_x(i)p_y(j) \log\{p_x(i)p_y(j)\} \quad \text{Denklem (3.57)}$$

$$HXY = - \sum_i \sum_j p(i, j) \log(p(i, j)) \quad \text{Denklem (3.58)}$$

Tablo 3.5'de gösterilen on ikinci özellikte (f_{12}), HX ve HY sırasıyla p_x ve p_y olasılık dağılımlarına sahip X ve Y rastlantı değişkenlerinin entropileridir. Eşitliklerde karşımıza çıkan logaritma operatöründe $\log(0)$ değeri ile karşılaşmamak için $\log(p(i, j))$ yerine $\log(p(i, j) + \varepsilon)$ ifadesi kullanılır. Burada ε pozitif değerler alan küçük bir sabittir. Son olarak, f_{14} ile verilen özellikte karşımıza çıkan Q değeri şu şekilde hesaplanır:

$$Q(i, j) = \sum \frac{p(i, k)p(j, k)}{P_x(i)P_y(k)} \quad \text{Denklem (3.59)}$$

Korelasyon ile ilgili ölçütler 12,13 ve 14 nolu özellikler ile temsil edilmektedir. Bu özellikler üç nolu özellikle temsil edilmeyen parametreler içermektedir. Bu yüzden ayrı ayrı hesaplanmaları gerekir. GLCM işleminin sonucunda her bir açı için 14 özellik hesaplanmış olur. Yani elimizde toplam $14 \times 4 = 56$ özellik vardır. Bu özelliklerinin tamamını kullanmak yerine, ortalama değerlerini ve maksimum-minimum değerleri arasındaki farkı kullanmak daha faydalı sonuçlar sağlamaktadır. Dolayısıyla projede GLCM sonucu 28 özellik belirlenmiştir.

Tablo 3.5. GLCM özellikleri ve formülleri

No	Özellik	Formül
1	Açısal ikinci moment	$f_1 = \sum_i \sum_j \{p(i, j)\}^2$
2	Kontrast	$f_2 = \sum_{n=0}^{Ng-1} n^2 \left\{ \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i, j) \right\}, i - j = n$
3	Korelasyon	$f_3 = \frac{\sum_i \sum_j (ij)p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y}$
4	Varyans	$f_4 = \sum_i \sum_j (i - \mu)^2 p(i, j)$
5	Ters fark momenti	$f_5 = \sum_i \sum_j \frac{1}{1 + (i - j)^2} p(i, j)$
6	Toplam ortalama	$f_6 = \sum_{i=2}^{2Ng} i p_{x+y}(i)$
7	Toplam entropi	$f_7 = - \sum_{i=2}^{2Ng} p_{x+y}(i) \log\{p_{x+y}(i)\}$
8	Toplam varyans	$f_8 = - \sum_{i=2}^{2Ng} (i - f_7)^2 p_{x+y}(i)$
9	Entropi	$f_9 = - \sum_i \sum_j p(i, j) \log(p(i, j))$
10	Fark varyansı	$f_{10} = p'_{x-y} \text{nin varyansı}$
11	Fark entropisi	$f_{11} = - \sum_{i=0}^{Ng-1} p_{x-y}(i) \log\{p_{x-y}(i)\}$
12	Korelasyon bilgi ölçütü	$f_{12} = \frac{HXY - HXY1}{\max\{HX, HY\}}$
13	Korelasyon bilgi ölçütü	$f_{13} = (1 - \exp[-2(HXY2 - HXY)]^{1/2}$
14	Maksimal korelasyon ölçütü	$f_{14} = (Q' \text{ nun en büyük ikinci özdeğeri})^{1/2}$

3.3.2.2. Komşu Gri-Ton Fark Matrisi

NGTDM tabanlı özellik çıkarma piksel yeğliliklerinde meydana gelen uzamsal değişiklikleri temsil etmek için kullanılan bir yöntemdir. Örneğin, 4x4 boyutlu 5-seviye segmente edilmiş bir görüntünün etiket değerleri ve NGTDM parametreleri Şekil 3.22'de verilmiştir.

Şekil 3.22. NGTDM hesaplama: a) 5-seviye segmente edilmiş görüntü, b) NGTDM parametreleri

$I = \begin{bmatrix} 1 & 2 & 4 & 5 \\ 3 & 1 & 2 & 4 \\ 1 & 1 & 1 & 2 \\ 1 & 5 & 5 & 3 \end{bmatrix}$	(a)
--	-----

i	n_i	p_i	s_i
1	6	0.375	14.78
2	3	0.1875	2.7
3	2	0.125	2.13
4	2	0.125	2.4
5	2	0.125	5.8

(b)

Şekilde n_i , i etiketlerinin sayısını, p_i ise bu etiketlerin olasılıklarını göstermektedir. Tabloda verilen s_i değerlerinin hesaplanması Denklem (3.60)'da verilmiştir.

$$s_i = \begin{cases} \sum_{n_i} |i - \bar{A}_i|, n_i \neq 0 \\ 0, n_i = 0 \end{cases} \quad \text{Denklem (3.60)}$$

Eşitlikte \bar{A}_i , i . etiketin komsularının etiket numaralarının toplamıdır. s_i değerinin hesaplanması şu şekilde gösterilebilir:

$$s_1 = \left| 1 - \frac{6}{3} \right| + \left| 1 - \frac{15}{8} \right| + \left| 1 - \frac{11}{5} \right| + \left| 1 - \frac{19}{8} \right| + \left| 1 - \frac{23}{8} \right| + \left| 1 - \frac{7}{3} \right| = 14.78$$

NGTDM parametreleri bir kez oluşturulduktan sonra, beş adet NGTDM özelliği kolayca hesaplanabilir. Bu özellikler kabalık (coarseness), kontrast (contrast), işlevsellik (busyness), karmaşıklık (complexity) ve doku kuvveti (texture strength) özellikleridir.

- i. **Kabalık (COA):** Bir görüntünün en temel doku özelliklerinden biridir ve merkez bir piksel ile komşu pikseller arasındaki farkın ortalamasını ifade eder. Uzamsal değişikliği en az olan ve doku olarak yerel düzenliliği fazla olan görüntülerde bu değer yüksektir. Kabalık aşağıdaki eşitlik ile hesaplanır:

$$COA = \frac{1}{\sum_{i=1}^{N_g} p_i s_i + \varepsilon} \quad \text{Denklem (3.61)}$$

Eşitlikte N_g segmente edilmiş görüntünün etiket sayısıdır. Eğer görüntü tamamen homojen ise $\sum_{i=1}^{N_g} p_i s_i$ değeri sıfır olmaktadır. Kabalık değerinin sonsuza gitmesi problemini önlemek amacıyla paydaya küçük pozitif bir ϵ sabiti eklenir.

- ii. **Kontrast (CNT):** Bu özellik uzamsal yeğlilik değişimin ölçer ve tüm grilik seviyelerinin dinamik aralığına bağlıdır. Eğer farklı yeğlilik seviyelerine sahip bölgeler görünür ise, görüntünün kontrastı yüksektir. Kontrast özelliğine ait matematiksel eşitlik aşağıda verilmiştir:

$$CNT = \left(\frac{1}{N_{g,p}(N_{g,p} - 1)} \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p_i p_j (i - j)^2 \right) \left(\frac{1}{N_{v,p}} \sum_{i=1}^{N_g} s_i \right), p_i \text{ ve } p_j \neq 0. \text{ Denklem (3.62)}$$

Burada, $N_{g,p}$, $p_i \neq 0$ olan grilik seviyelerinin sayısı ve $N_{v,p}$ bölgedeki toplam piksel sayısıdır.

- iii. **İşlevsellik (BSY):** İşlevsel bir görüntüde bir pikselden komşu piksele geçişte yeğlilik seviyeleri arasında büyük bir değişim vardır. Bu durumda, yeğlilik değişimlerinin uzamsal frekansı oldukça yüksektir. Bu özellik görüntüde şu şekilde hesaplanır:

$$BSY = \frac{\left(\sum_{i=1}^{N_g} p_i s_i \right)}{\left(\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} |i \cdot p_i - j \cdot p_j| \right)}, p_i \text{ ve } p_j \neq 0. \text{ Denklem (3.63)}$$

- iv. **Karmaşıklık (CMP):** Bu özellik bir görüntünün bilgi içeriğini temsil eder. Karmaşıklık değeri yüksek ise görüntünün birçok parça ve ilkel doku içerdiği anlaşılmaktadır. Karmaşıklık değeri şöyle hesaplanır:

$$CMP = \frac{1}{N_{v,p}} \sum_{i=1}^{N_p} \sum_{j=1}^{N_p} |i - j| \frac{p_i s_i + p_j s_j}{p_i + p_j}, p_i \text{ ve } p_j \neq 0. \text{ Denklem (3.64)}$$

- v. **Kuvvet (STR):** Doku kuvveti kabalık ve kontrast özellikleri ile ilişkili olarak değerlendirilebilir. Kabalık değeri yüksek görüntülerde küçük değerler alırken, işlevsel görüntülerde büyük değerler alır. Kuvvet özelliği aşağıdaki eşitlik ile hesaplanır:

$$STR = \left(\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (p_i + p_j) (i - j)^2 \right) / \sum_{i=1}^{N_g} s_i, \quad p_i \text{ ve } p_j \neq 0. \text{ Denklem (3.65)}$$

3.3.2.3. Gri Seviye Bağlılık Matrisi

GLDM bir görüntüdeki gri seviye bağlılıklar hakkında bilgi verir. Bu bağlılık merkez bir pikselin tanımlanmış komşuluklarındaki bağlı piksellerin sayısı olarak tanımlanır. GLDM'den yararlanarak projede altı özellik çıkarılmıştır. Bu özellikler ve matematiksel karşılıkları Tablo 3'de verilmiştir. Küçük bağlılık vurgusu (small dependence emphasis, SDE), geniş bağlılık vurgusu (large dependence emphasis, LDE), sırasıyla küçük ve büyük bağlılıkların dağılım ölçütleridir. Eğer SDE daha büyükse görüntünün dokusu daha az homojendir denir. LDE daha büyükse görüntü dokusunun daha homojen olduğu anlaşılır. Grilik seviyesi düzensizliği (gray level non-uniformity, GLN) görüntüdeki grilik seviyesi şiddetlerinin benzerliğini gösterirken bağlılık düzensizliği (dependence non-uniformity, DN) görüntü üzerindeki bağlılık benzerliğinin bir ölçütüdür. Eğer bu değerler düşük ise yeğlilik değerlerindeki benzerlik düşüktür ve görüntüdeki bağlılıklar daha homojen dağılmıştır. Gri seviye varyansı (gray level variance, GLV) ve bağlılık varyansı (dependence variance, DV) sırasıyla görüntüdeki grilik seviyelerinin ve bağlılıkların değişimini temsil eder.

Tablo 3.6. GLDM özellikleri ve formülleri

No	Özellik	Formül
1	Küçük bağlılık vurgusu (Small dependence emphasis)	$SDE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_d} \frac{P(i,j)}{i^2}}{N_Z}$
2	Büyük bağlılık vurgusu (Large dependence emphasis)	$LDE = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_d} P(i,j) \cdot j^2}{N_Z}$
3	Grilik seviyesi düzensizliği (Gray level non-uniformity)	$GLN = \frac{\sum_{i=1}^{N_g} \left(\sum_{j=1}^{N_d} P(i,j) \right)^2}{N_Z}$
4	Bağlılık düzensizliği (Dependence non-uniformity)	$DN = \frac{\sum_{i=1}^{N_g} \left(\sum_{j=1}^{N_d} P(i,j) \right)^2}{N_Z^2}$
5	Grilik seviyesi varyansı (Gray level variance)	$GLV = \sum_{i=1}^{N_g} \sum_{j=1}^{N_d} p(i,j)(i - \mu)^2, \mu = \sum_{i=1}^{N_g} \sum_{j=1}^{N_d} i \cdot p(i,j)$
6	Bağlılık varyansı (Dependence variance)	$DV = \sum_{i=1}^{N_g} \sum_{j=1}^{N_d} p(i,j)(j - \mu)^2, \mu = \sum_{i=1}^{N_g} \sum_{j=1}^{N_d} j \cdot p(i,j)$

3.3.3. Şekil Özellikleri

Memede tespit edilen lezyonların iyi huylu ya da kötü huylu olduğuna hatta daha alt türlere ait olup olmadığına karar vermek için lezyonu tanımlayan bazı özellikler belirlenebilir. Bu özellikler uzamsal-zamansal, morfolojik, dokusal ve şekilsel özellikler olabilir. Projede şekil özellikleri kullanılarak meme lezyonlarının türlerinin belirlenmesine bilgi sağlanması amaçlanmıştır. Çalışmada yer alan radyoloji uzmanının tecrübelerine ve literatür incelemesine göre, iyi huylu lezyonlar daha oval ve birleşik bir yapıda iken kötü huylu lezyonlar çıkıntılı ve dağınık bir yapıdadır. Ayrıca iyi huylu lezyonlar kötü huylu lezyonlara göre memede daha küçük bir alan kaplamaktadır. Buna göre çalışmanın özellik çıkarma adımı, iki aşamalı segmentasyon işlemi uygulanmış ve lezyon alanı belirginleştirilmiş meme MR görüntülerinden 15 adet şekil özelliği hesaplanmıştır [83]. Bu özellikler, özelliklere ait açıklamalar ve formüller Tablo 3.7’de verilmiştir.

Tablo 3.7. Şekil özellikleri ve açıklamaları

No	Özellik	Açıklama/Formül	Etkinlik
1	Alan	Lezyonda yer alan toplam piksel sayısı	Kötü huylu lezyonlar iyi huylu lezyonlardan daha büyük bir alan kaplamaktadır.
2	Çevre	Lezyonun kenarlarında yer alan toplam piksel sayısı	Düzensiz yapıdaki lezyonların kenar piksel sayısı daha yüksektir.
3	Maksimum yarıçap	Lezyonun merkezinin en uzak köşesine olan mesafesidir.	Lezyonun merkezinden köşelere olan en uzak ve en yakın mesafe lezyonun büyüklüğü hakkında bilgi vermektedir.
4	Minimum yarıçap	Lezyonun merkezinin en yakın köşesine olan mesafesidir.	
5	Dış Merkezlilik (Eccentricity)	$\sqrt{1 - \left(\frac{Min\ yarıçap}{Max\ yarıçap}\right)^2}$	Lezyonun eliptik özelliklerini tanımlamada kullanılmaktadır.
6	Eşçaplılık (Equidiameter)	$\sqrt{4 * \frac{Alan}{\pi}}$	Yuvarlak / oval düzenli görünümlü lezyonları düzensiz lezyonlardan ayırmak için kullanılmaktadır.
7	Uzatılmışlık (Elongatedness)	$\frac{Alan}{(2 * Max\ yarıçap)^2}$	

8	Entropi	$\sum (p * \log_2(p))$	Lezyonun şekilsel yapısındaki bozukluk miktarını ölçmektedir.
9	Dairesellik 1	$\sqrt{\frac{Alan}{\pi * Max\ yarıçap^2}}$	Yuvarlak / oval kitleleri düzensiz / lobüler kitleden ayırmak için kullanılmaktadır.
10	Dairesellik 2	$\sqrt{\frac{Min\ yarıçap}{Max\ yarıçap}}$	
11	Yoğunluk	$\left(\frac{2 * \sqrt{Alan * \pi}}{\Çevre}\right)$	Lezyon bölgesinin pürüzsüzlük derecesini ölçmektedir.
12	Saçılma	$\left(\frac{Max\ yarıçap}{Alan}\right)$	Kötü huylu lezyonların karakteristik şekillerini belirlemektedir.
13	İncelik Oranı	$\left(\frac{4 * \pi * Alan}{\Çevre^2}\right)$	Çizgisel yapıdaki bölgeleri diğer yapıdaki bölgelerden ayırmaktadır.
14	Lezyon standart sapması	$\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$	Veri kümesindeki ortalamanın dağınıklığını belirlemektedir.
15	Şekil indeksi	$\left(\frac{\Çevre}{2 * Max\ yarıçap}\right)$	Lezyonun kenar boşlukları hakkında bilgi vermektedir.

3.3.4. Dönüşüm Uzayı Özellikleri

Şimdiye kadar verilen özellik çıkarma tekniklerinde görüntü piksel uzayında iken işlemler gerçekleştirilmiştir. Bu kısımdaki amacımız görüntü içerisinde piksel uzayında tespit edilemeyen saklı bazı önemli bilgileri tespit etmektir. Bu amaçla görüntüye farklı dönüşümler uygulanabilir. Fourier dönüşümü, dalgacık dönüşümü, Shearlet dönüşümü, Counterlet dönüşümü kullanılan tekniklerden bazılarıdır.

Projede yapılan ön çalışmalar ışığında en etkili özelliklerin ayrık Fourier dönüşümü (discrete Fourier transform, DFT) ve Shearlet dönüşümü ile elde edildiği tespit edilmiştir. Bu nedenle bu iki dönüşüm uzayı yönteminin açıklamaları ve hesaplanan özellikler aşağıda özetlenmiştir.

3.3.4.1. Ayrık Fourier Dönüşümü

DFT, sonlu uzunluklu ortogonal bir dönüşümdür. Görüntü işleme uygulamalarında Fourier dönüşümünün uygulanabilmesi için iki-boyutlu (2D) DFT ifadelerine ihtiyaç duyulur. Bu

dönüşüm örneklenmiş görüntünün piksel değerlerine uygulanır. Piksellerin koordinatları 2D uzamsal konumda (x,y) koordinatları ile gösterilir. Dolayısıyla u ve v şeklinde gösterilen yatay ve dikey uzamsal frekanslar şeklinde iki frekans boyutu elde edilir. Bir görüntü dikey çizgiler şeklinde verildiğinde Fourier dönüşümü sadece yatay uzamsal frekansları göstermektedir. y -ekseni boyunca dikey bir değişim olmadığından dikey uzamsal frekanslar sıfırdır. 2D DFT $P_{x,y}$ şeklinde gösterilen $N \times N$ pikselin frekans içeriği $FP_{u,v}$ hakkında şu şekilde değerlendirme yapmaktadır:

$$FP_{u,v} = \frac{1}{N} \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} P_{x,y} e^{-j\left(\frac{2\pi}{N}\right)(ux+vy)} \quad \text{Denklem (3.66)}$$

Frekans uzayında görüntü uzayına geri dönüşü sağlayan 2D ters DFT ise şu şekilde ifade edilir:

$$P_{x,y} = \sum_{u=0}^{N-1} \sum_{v=0}^{N-1} FP_{u,v} e^{j\left(\frac{2\pi}{N}\right)(ux+vy)} \quad \text{Denklem (3.67)}$$

DFT, ayrık-zaman Fourier dönüşümünün frekans ekseninde $w = \frac{2\pi k}{N}$, $0 \leq k \leq N-1$ anlarında örneklenmesi ile elde edilen sonlu uzunluklu bir dönüşümdür. Burada N , DFT'nin nokta sayısıdır. Frekansta örnekleme zaman uzayında örtüşmelere neden olabileceğinden DFT'nin nokta sayısı en az dizinin uzunluğu kadar seçilir. DFT'nin hesap karmaşıklığını azaltmak için hızlı Fourier dönüşümü (Fast Fourier Transform, FFT) algoritması geliştirilmiştir. N nokta 1D FFT algoritmasının hesap yükü $O(N \log(N))$, 2D FFT'nin hesap yükü $O(N^2(\log(N)))$ 'dir. Diğer taraftan 2D DFT'nin hesap yükü $O(N^3)$ 'dür. Özellikle büyük boyutlu görüntülerin işleme hızı FFT algoritması sayesinde oldukça azalmaktadır.

Hızlı olma özelliğinden dolayı görüntü işleme uygulamalarında 2D FFT algoritması kullanılır. Fourier dönüşümünün zorluklarından biri yorumlanması zor görüntülerle sonuçlanmasıdır. Bir görüntünün Fourier dönüşümü, görüntünün frekans bileşenlerini verir. Her bir bileşenin pozisyonu frekansına yansır. Örneğin, düşük frekans bileşenleri orijine yakın, yüksek frekans bileşenleri ise orijinden uzaktır.

Projede DFT, lezyon bölgesinin frekans uzayı özelliklerini elde etmek için kullanılmıştır. Bu özellikler enerji, dönüşümün maksimum ve minimum genlik değerleri, genlik spektrumunun ortalama değeri, standart sapması olarak belirlenmiştir.

3.3.4.2. Shearlet Dönüşümü

Shearlet dönüşümü, görüntülerin istenen ölçek ve yönde frekans bileşenlerini basit matematiksel yaklaşımlarla daha esnek geometrik yapılar içinde detaylı bir analiz imkânı sağlamaktadır [84, 85]. Shearlet fonksiyonu kutupsal koordinat sisteminde şöyle tanımlanır:

$$\Psi_{a,s,t}(x) = |\det M_{a,s}|^{-\frac{1}{2}} \varphi(M_{a,s}^{-1}x - t) \quad \text{Denklem (3.68)}$$

$a > 0, s \in R, t \in R^2$ için $M_{a,s} = \begin{pmatrix} a & \sqrt{as} \\ 0 & \sqrt{a} \end{pmatrix}$ olarak ifade edilir. Eşitlik (4.24)'de $M_{a,s} = B_s A_a$,

$A_a = \begin{pmatrix} a & 0 \\ 0 & \sqrt{a} \end{pmatrix}$ parabolik ölçüm matrisi $B_s = \begin{pmatrix} 1 & s \\ 0 & 1 \end{pmatrix}$ şeklinde ifade edilen kesme matrisi ve t çevirme parametresidir. Shearlet dönüşümünün görüntülere uygulanabilmesi için dönüşüm kartezyen koordinatlara taşınmalıdır. $j, l \in Z$ olmak üzere $a = 2^{-j}$ ve $s = -l$ olarak seçilir. Bu durumda,

$$M_{2^{-j}, -l}^{-1} = M_{2^j, l} = \begin{pmatrix} 2^j & l2^{j\lambda^2} \\ 0 & 2^{j\lambda^2} \end{pmatrix} = B_0^l A_0^j \quad \text{Denklem (3.69)}$$

elde edilir. Eşitlik (4.25)'de $A_0 = \begin{pmatrix} 2 & 0 \\ 0 & \sqrt{2} \end{pmatrix}$ ve $B_0 = \begin{pmatrix} 1 & 1 \\ 0 & 1 \end{pmatrix}$ kabul edilir. $j, l \in Z, k \in Z^2$ olmak üzere Shearlet dönüşümünün ayrık durumdaki ifadesi,

$$\Psi_{j,l,k} = |\det A_0|^{\frac{j}{2}} \varphi(B_0^l A_0^j x - k) \quad \text{Denklem (3.70)}$$

olarak elde edilir. Shearlet dönüşümü farklı ölçeklerde yön değişimine karşı hassas olduğundan, dönüşüm üç katmana ayrıştırılmıştır. Projede Shearlet dönüşümü tabanlı özellikler yatay konide birinci katmanın eş oluşum matrisinden hesaplanan entropi, korelasyon, kontrast ve açısal ikinci moment, yatay ve dikey konilerde birinci ve üçüncü katman katsayılarından hesaplanan ortalama değer, varyans ve enerji, son olarak yüksek frekans alt-bant katsayı matrisinin her bir sütununun maksimum değerleridir [86, 87]. Projede Shearlet tabanlı toplam 24 özellik hesaplanmıştır.

Tablo 3.8. Meme lezyonlarının sınıflandırılması için oluşturulan özellik vektörü

Yöntem	Özellikler	Özellik sayıları
Histogram	. Ortalama . Standart sapma . Eğrilik . Basıklık . Enerji . Entropi	6
Şekil	. Alan . Çevre	15

	<ul style="list-style-type: none"> . Maksimum yarıçap . Minimum yarıçap . Dış Merkezlilik . Eşçaplılık . Uzatılmışlık . Entropi . Dairesellik 1 . Dairesellik 2 . Yoğunluk . Saçılma . İncelik oranı . Lezyon standart sapması . Şekil indeksi 	
GLCM	<ul style="list-style-type: none"> . Açısal ikinci moment . Kontrast . Korelasyon . Varyans . Ters fark momenti . Toplam ortalama . Toplam entropi . Toplam varyans . Entropi . Fark varyansı . Fark entropisi . Korelasyon bilgi ölçütü 1 . Korelasyon bilgi ölçütü 2 . Maksimal korelasyon ölçütü 	28 (0°, 45°, 90°, 135°)
GLRLM	<ul style="list-style-type: none"> . Kısa koşu vurgusu . Uzun koşu vurgusu . Gri seviye düzensizliği . Koşu uzunluğu düzensizliği . Koşu yüzdesi . Düşük gri-seviye koşu vurgusu . Yüksek gri-seviye koşu vurgusu . Kısa-koşu düşük gri seviye vurgusu . Kısa-koşu yüksek gri seviye vurgusu 	22 (0°, 45°, 90°, 135°)

	<ul style="list-style-type: none"> . Uzun-koşu düşük gri seviye vurgusu . Uzun-koşu yüksek gri seviye vurgusu 	
NGTDM	<ul style="list-style-type: none"> . Kabalık . Kontrast . İşlevsellik . Karmaşıklık . Kuvvet 	5
GLDM	<ul style="list-style-type: none"> . Küçük bağıllık vurgusu . Büyük bağıllık vurgusu . Grilik seviyesi düzensizliği . Grilik seviyesi varyansı . Bağıllık varyansı 	6
DFT	<ul style="list-style-type: none"> . Enerji . Maksimum genlik . Minimum genlik . Genlik spektrumu ortalama değeri . Genlik spektrumu standart sapması 	5
Shearlet	<ul style="list-style-type: none"> . Yatay koni GLCM entropi . Yatay koni GLCM korelasyon . Yatay koni GLCM contrast . Yatay koni GLCM açısal ikinci moment . Yatay koni birinci katman ortalama değer . Yatay koni birinci katman varyans . Yatay koni birinci katman enerji . Dikey koni birinci katman ortalama değer . Dikey koni birinci katman varyans . Dikey koni birinci katman enerji . Yüksek frekans alt-band katsayı matrisi sütun maksimum değerleri 	21
Total:		108

3.4. Özellik Seçme

Medikal görüntüleme sistemlerinde gürültü görüntüleri ve dolayısıyla karar-destek sisteminin performansını etkilemektedir. Gürültünün etkisini azaltmak için, projede MR görüntülerine filtreleme teknikleri uygulanmıştır. Bunun dışında, özellik çıkarma ve özellik seçme işlemleri boyut azaltma teknikleridir ve gürültü içeren ve etkisiz özellikleri atam

popüler tekniklerdir. Projede sekiz farklı yöntem ile özellik çıkarma işlemi gerçekleştirilmiş ve meme lezyonlarını sınıflandırmak amacıyla toplamda 108 özellik belirlenmiştir.

Bu aşamadan sonra uygulanan özellik seçme yöntemlerinin amacı ilişkisiz özellikleri özellik vektöründen çıkararak ve sınıflandırma aşamasında lezyonlara daha yüksek doğrulukla etiket atanmasını sağlamayı hedefleyen, özellik vektöründen daha küçük boyutlu bir özellik alt kümesi seçmektir. Projenin özellik seçme adımında en başarılı sonuçlar verdiği tespit edilen Fisher skor tabanlı bir özellik seçme adımı uygulanmıştır. Aşağıdaki kısımda bu yöntemler hakkında bilgilendirme yapılmıştır.

3.4.1. Fisher Skor

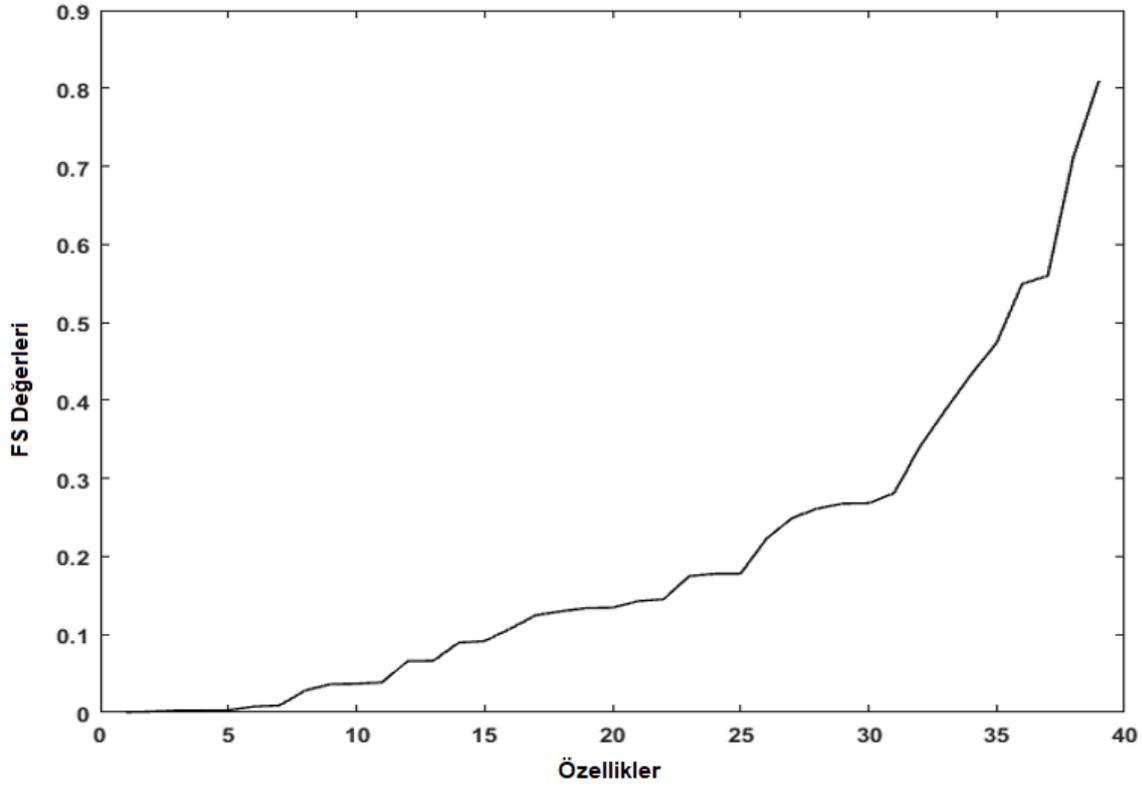
Fisher skor (FS) yöntemi sınıflandırmada en etkili olan özellikleri bulmak için kullanılan bir yöntemdir. FS, denetimli özellik seçme algoritmaları arasında en yaygın olarak kullanılan yöntemlerden biri olan örnek bir yöntemdir. Bu yöntem bir filtre modeli olarak sınıflandırılır yani özellikleri sınıflandırma algoritması uygulamadan değerlendirir. FS yönteminin ilk adımında özellikler belirli bir kritere göre derecelendirilir. İkinci adımda ise, en yüksek derecelere sahip özellikler sınıflandırma adımında kullanılmak üzere seçilir. FS yöntemine göre, eğer bir özelliğin skoru belirlenen eşik skor değerinden yüksekse özellik seçilir ve özellik vektöründe kalmaya devam eder. Aksi halde özellik vektöründen atılır. Bir özelliğin sahip olabileceği maksimum FS değeri 1 minimum FS değeri ise 0'dır. Dolayısıyla eşik değeri [0,1] aralığında seçilir.

FS yönteminde reel sayılardan oluşan iki küme (örneğin pozitif ve negatif veri kümeleri) vardır. Bir özelliğin FS değerini hesaplamak için aşağıdaki eşitlik kullanılır:

$$FS(i) = \frac{(m_i^{(p)} - m_i)^2 + (m_i^{(n)} - m_i)^2}{\frac{1}{np-1} \sum_{k=1}^{np} (f_{k,i}^p - m_i^{(p)})^2 + \frac{1}{nn-1} \sum_{k=1}^{nn} (f_{k,i}^n - m_i^{(n)})^2} \quad \text{Denklem (3.71)}$$

Eşitlik (5.1)'de m_i , $m_i^{(p)}$ ve $m_i^{(n)}$ sırasıyla i . özelliğin tüm veri setindeki, pozitif veri setindeki ve negatif veri setindeki ortalama değerini gösterir. np ve nn sayıları verilen eğitim vektöründeki pozitif ve negatif örneklerin sayısıdır. $f_{k,i}^p$ ve $f_{k,i}^n$ ise k . pozitif ve negatif örneğin i . özelliğidir [88]. Şekil 5.1'de özelliklerin FS değerleri küçükten büyüğe doğru sıralanmış bir şekilde gösterilmektedir. Şekilden de görüldüğü gibi belirlenen eşik değere göre özellik vektöründe kalmaya devam edecek özelliklerin sayısı değişmektedir.

Şekil 3.23. Bazı özelliklerin FS değerleri.



3.5. Sınıflandırma

Projenin amacı, meme MRG cihazı ile alınan görüntüleri kullanılarak memedeki lezyonların tespit edilmesini ve doğru bir şekilde sınıflandırılmasını sağlamaktır. Projenin ilk aşamasında, MR görüntülerinde lezyonun bulunduğu bölgenin belirlenmesi için görüntülere uzman tarafından başlatılan ve görüntü işleme yöntemleri kullanılarak otomatik olarak gerçekleştirilen bir segmentasyon adımı uygulanmıştır. İkinci aşamada, mevcut sistem tarafından kullanılan morfolojik ve kinetik özelliklere ilave, piksel ve dönüşüm uzaylarında tanımlı yöntemler aracılığı ile çıkarılan yeni özellikler tanımlanmıştır. Segmentasyon ve özellik çıkarma adımları kontrast madde öncesi (pre-kontrast) elde edilen T2 ağırlıklı sekanslar ve kontrast madde sonrası (post-kontrast) T1 ağırlıklı yağ baskılı dinamik MR görüntüleri kullanılarak gerçekleştirilmiştir. Üçüncü aşamada ise, metasezgisel optimizasyon teknikleri ve istatistiksel veri analiz yöntemleri kullanılarak özellik seçme işlemi yapılmıştır. Son olarak, özellik vektörünün yapısına en uygun sınıflandırıcılar kullanılarak sınıflandırma işlemi gerçekleştirilecektir.

Sınıflandırıcılar iki ya da daha fazla sınıfı özellik uzayında belirlediği sınırlar çerçevesinde birbirinden ayırmayı amaçlayan karar mekanizmaları olarak düşünülebilir. Projede, k- en yakın komşuluk (k-nearest neighbor, KNN), ağırlıklı k-en yakın komşuluk (weighted k-

nearest neighbor, WKNN), destek vektör makineleri (support vector machines, SVM), rastgele orman (random forest, RF) ve naif Bayes (naive Bayes, NB) yöntemleri sınıflandırma adımını gerçekleştirmek amacıyla kullanılmıştır. İzleyen kısımda bu algoritmalara ait kısa açıklamalar verilmiştir.

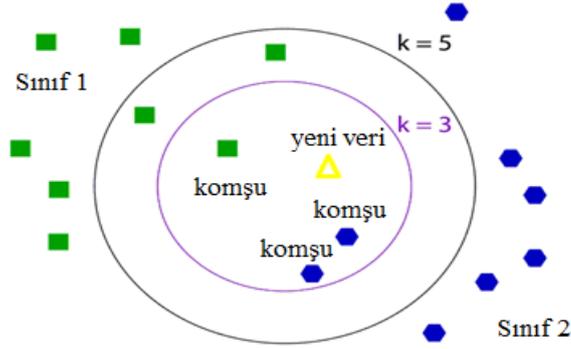
3.5.1. KNN, WKNN Yöntemleri

En yakın komşuluk yöntemi sınıflandırma amacıyla kullanılan en basit ve kolay uygulanabilir tekniklerden biridir. Yöntemde her bir test vektörüne eğitim setindeki en yakın komşularıyla aynı etiket atanır. KNN iki aşamalı örnek tabanlı bir teknik olarak düşünülebilir. İlk aşama komşuların belirlenmesi ikinci aşama ise komşuların sınıflarına göre gelen yeni veri noktasına sınıf etiketinin atanmasıdır. Eğitim veri kümesi $(x_i)_{i \in [1,D]}$ eğitim örneklerini içersin ve D ile gösterilsin. Her bir örnek bir özellik kümesi ile gösterilir ve özellik kümesi $[0, 1]$ aralığına düşecek şekilde normaliz edilmiştir. Her bir eğitim örneğine bir sınıf etiketi $y_j \in Y$ atandığını varsayalım. Amaç, q ile gösterilen bilinmeyen veri noktasına bir sınıf etiketi atamaktır. Bu amaçla, her bir $x_i \in D$ için q ve x_i arasındaki Öklid mesafesi hesaplanır. Öklid mesafesi şu şekilde hesaplanır:

$$d(q, x_i) = \|q - x_i\| \quad \text{Denklem (3.72)}$$

Denklem 3.72'de $\|\cdot\|$ vektör normunu göstermektedir. Öklid normu yerine Minkowski, Manhattan, Hamming, Mahalonobis vb. metrikler kullanılabilir. KNN yönteminin gösterilimi Şekil 6.1'de verilmiştir. Bilinmeyen örnek ile her bir eğitim örneği arasındaki mesafe hesaplandıktan sonra, en küçük mesafede bulunan k adet komşu belirlenir. Komşular bir kez seçildikten sonra, bilinmeyen örneğin sınıfına karar verilmesi gerekir. Karar işleminin gerçekleştirilmesinin birçok yolu vardır. En yaygın olarak kullanılan yaklaşım sorguya (q) en yakın komşuların sınıf etiketlerine bakarak çoğunluğa göre karar vermektir. KNN yönteminde karar üzerinde tüm komşuların etkisi eşittir. Ancak WKNN'de tüm komşulara eşit ağırlık verilmez. WKNN yönteminde sorgunun etiketine karar verirken daha yakın komşuların karar üzerindeki etkisi daha fazladır. Simülasyonlarda k değeri 1-11 arasında değiştirilerek sınıflandırma performansları değerlendirilmiştir [89, 90].

Şekil 3.24. KNN yönteminin şekilsel gösterilimi



3.5.2. SVM Yöntemi

SVM ikili öğrenme konusunda oldukça önemli özelliklere sahip olmakla beraber ileri beslemeli ağların bilinen kategorilerinden biridir. SVM'nin temel mantığı şu şekilde özetlenebilir: eğitim örneği bir kez verildiğinde makine karar yüzeyini olarak bir hiper düzlem oluşturmak amacıyla Lagrange yöntemi tabanlı bir optimizasyon işlemi uygular. Pozitif ve negatif örnekler arasındaki mesafe maksimum yapılır. Birçok durumda örüntüler doğrusal olarak ayrıştırılabilir. Ancak, bazı zor durumlarda, doğrusal olarak ayrıştırılamayan örüntülerle karşılaşılabilir [28]. Kolaylık olması açısından, SVM'yi kabaca açıklamak için doğrusal olarak ayrıştırılabilen örüntüleri ele alalım. Eğitim örneğini $\{(x_i, d_i)\}_{i=1}^N$ ile gösterelim. Burada x_i , i . örneğin giriş örüntüsü ve d_i hedef çıkıştır. $d_i = +1$ ve $d_i = -1$ alt kümeleri ile temsil edilen ve doğrusal olarak ayrışabilen iki örüntü sınıfı olduğunu varsayalım. Ayrıştırma işlemini gerçekleştiren hiper düzlem şu şekilde ifade edilir:

$$\mathbf{w}^T \mathbf{x} + b = 0 \quad \text{Denklem (3.73)}$$

Denklem (3.73)'de \mathbf{x} giriş vektörü ve \mathbf{w} ayarlanabilir ağırlık vektörü ve b ise denge katsayısıdır. Bu durumda doğrusal olarak ayrışabilen örüntüler için,

$$\mathbf{w}^T \mathbf{x}_i + b \geq 0, \text{ for } d_i = +1 \quad \text{Denklem (3.74)}$$

$$\mathbf{w}^T \mathbf{x}_i + b < 0, \text{ for } d_i = -1 \quad \text{Denklem (3.75)}$$

Belirli \mathbf{w} ve b değerleri için, Denklem (3.73) ile verilen hiper düzlem ile en yakın veri noktası ρ arasındaki mesafe aralık payı (margin of separation) olarak adlandırılır. SVM, ρ 'yu maksimum yapan en uygun (optimum) hiper düzlemi bulmayı amaçlar. Optimal hiper düzlem Denklem 3.76'daki eşitlikle ifade edilir:

$$\mathbf{w}_0^T \mathbf{x} + b_0 = 0 \quad \text{Denklem (3.76)}$$

Denklem (3.76)'da w_0 ve b_0 ağırlık vektörünün ve denge katsayısının optimum değeridir. O halde, x ile optimal hiper düzlem arasındaki mesafenin matematiksel değerini veren ayırıcılık fonksiyonu

$$g(x) = w_0^T x + b_0 \quad \text{Denklem (3.77)}$$

ile verilir. Amaç, $D = \{(x_i, d_i)\}$ şeklinde ifade edilen eğitim seti için optimal hiper düzlemi oluşturan aşağıdaki kısıtları sağlayan w_0 ve b_0 değerlerini bulmaktır.

$$w_0^T x + b_0 \geq 1 \text{ for } d_i = +1 \quad \text{Denklem (3.78)}$$

$$w_0^T x + b_0 \leq -1 \text{ for } d_i = -1 \quad \text{Denklem (3.79)}$$

Eşitlik (3.79) ve Eşitlik (3.80)'un sağlandığı (x_i, d_i) veri noktaları destek makineleri olarak adlandırılır ve bu makineler SVM'nin çalışmasında önemli bir rol oynar. Hiper düzleme en yakın veri noktaları sınıflandırılması en zor noktalardır ve karar yüzeyinin optimum konumu üzerinde doğrudan bir etkisi vardır. $x^{(s)}$ 'in $d^{(s)} = \mp 1$ için bir destek vektörü olduğunu varsayalım. Denklem (3.77) ile,

$$g(x^{(s)}) = w_0^T x^{(s)} + b_0 = \mp 1 \text{ for } d^{(s)} = \mp 1 \quad \text{Denklem (3.80)}$$

elde edilir. $x^{(s)}$ ile optimal hiper düzlem arasındaki mesafe

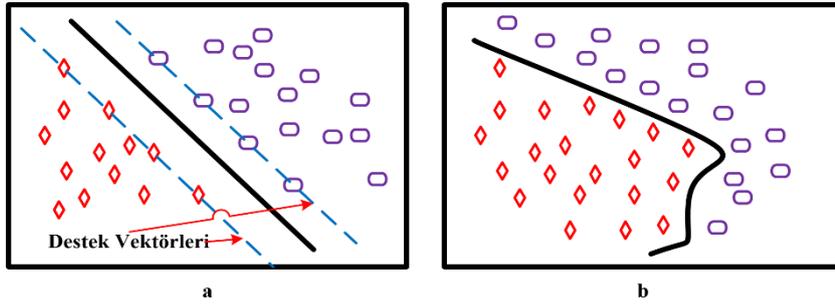
$$r = \frac{g(x^{(s)})}{\|w_0\|} = \begin{cases} \frac{1}{\|w_0\|} & \text{if } d^{(s)} = +1 \\ -\frac{1}{\|w_0\|} & \text{if } d^{(s)} = -1 \end{cases} \quad \text{Denklem (3.81)}$$

elde edilir. Denklem (3.82)'de, $x^{(s)}$ optimal hiper düzlemin pozitif tarafında ise işaret artı, $x^{(s)}$ optimal hiper düzlemin negatif tarafında ise işaret eksidir. Bu durumda iki sınıf arasındaki ayırma payı (ρ),

$$\rho = 2r = \frac{2}{\|w_0\|} \quad \text{Denklem (3.82)}$$

eşitliği ile elde edilir. Eşitlikten anlaşılacağı gibi, ayırma payının maksimum yapılması w ağırlık vektörünün Öklid normunun minimum yapılması ile eşdeğerdir. Optimum hiper düzlemin bulunması kısıtlamalı konveks bir optimizasyon problemidir. Bu problem Lagrange Çarpanları yöntemi ile çözülebilir. SVM yönteminin Bu çerçevede, kernel fonksiyonları SVM'nin yüksek boyutlu özellik uzaylarında uygulanmasına olanak sağlar. Projede lineer ve Gaussian kernel hedeflenen lezyon sınıflandırma probleminin çözülmesinde kullanılmıştır [89, 91, 92]. Şekil 3.24'de SVM için doğrusal ve doğrusal olmayan karar yüzeyleri gösterilmiştir.

Şekil 3.25. SVM'de doğrusal ve doğrusal olmayan karar yüzeyleri



3.5.3. Rastgele Orman Yöntemi

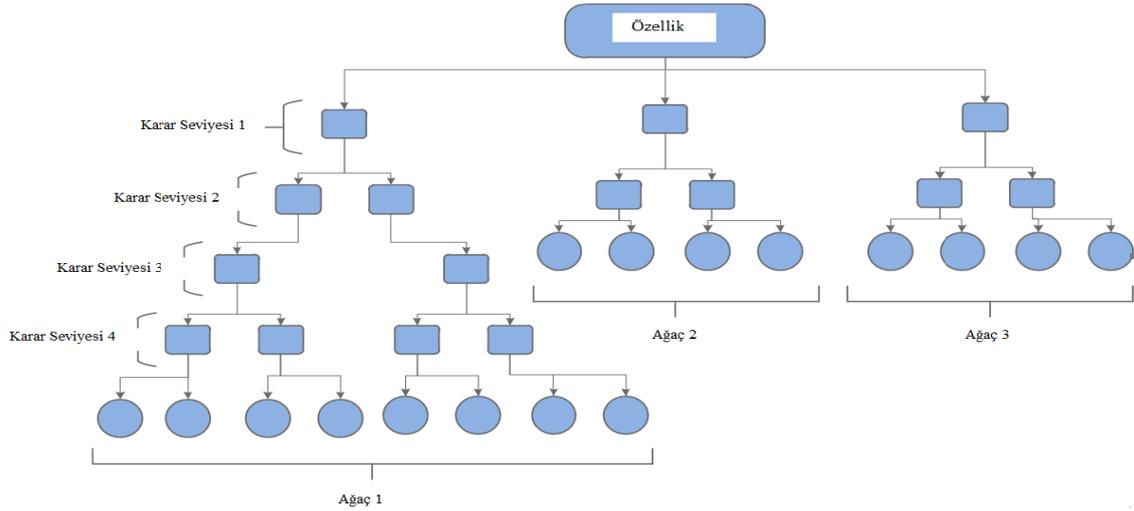
Rastgele orman (Random forest, RF) sınıflandırma amacıyla yaygın olarak kullanılan denetimli yöntemlerden biridir. Yöntem, Şekil 3.25'de gösterildiği gibi, orman oluşturmak için çok sayıda karar ağacı oluşturarak karar ağaçlarının aşırı uyum probleminin üstesinden gelmektedir. RF yönteminin temel adımları şu şekilde özetlenebilir:

- i. Ham verinin üçte biri kaldırılarak ve örneklenerek orijinal veri setinden yeni bir veri seti oluşturulur.
- ii. Model eğitim süreci azaltılan örnekler üzerinde gerçekleştirilir ve yansız hata model üzerinden tahminlenir.
- iii. Veri setinde her bir düğümde devam eden sütunlar belirlenir.
- iv. En yüksek karar doğruluğunu elde etmek için, eş zamanlı olarak birçok ağaç büyür ve her bir sınıflandırıcının oylarının çoğunluğuna göre son tahmin yapılır.

RF yöntemi oldukça kolay kullanılabilen bir yöntemdir ve sadece iki parametresi vardır. Parametrelerden biri ormandaki ağaç sayısı diğeri her bir düğümdeki rastgele alt kümelerdeki değişken sayısıdır. Projede ağaç sayısı 100 olarak seçilmiştir.

RF yöntemi oldukça kolay kullanılabilen bir yöntemdir ve sadece iki parametresi vardır. Parametrelerden biri ormandaki ağaç sayısı diğeri her bir düğümdeki rastgele alt kümelerdeki değişken sayısıdır. Projede ağaç sayısı 100 olarak seçilmiştir.

Şekil 3.26. RF yönteminde ağaç yapısı



Ağaç yapısı temelli sınıflandırma işlemi giriş değişkenlerinin basit bir fonksiyonu ile ifade edilen alternatif bir yaklaşımdır. Tahmin değerlerini artırmak için kullanılan bagging ve boosting olarak adlandırılan iki teknik vardır. Bu teknikler tahminleyicinin doğru tahminler yapma olasılığını yükseltir ve ağaç tabanlı yöntemlerle veya diğeri öğrencilerle birlikte kullanılabilir. Bootstrap aggregation (bagging) tekniği eğitim setinden yerine koymaksızın oluşturulan birçok eğitim seti alt kümeleri ile kullanılabilir. Bu alt kümelerin her biri farklı bir sınıflandırıcıyı eğitmek için kullanılır ve son karar kullanılan her bir sınıflandırıcının oylarının çoğunluğuna göre verilir. Bu teknikler sayesinde sınıflandırıcıların tahmin ve kararlılık özellikleri iyileştirilebilir [93, 94].

3.5.4. Naif Bayes Yöntemi

NB algoritması olasılık teorisinden biline Bayes teoremine dayalıdır. Bayes teoremi şu şekilde ifade edilebilir:

$$P(Y = Y_i | X) = \frac{P(X | Y = Y_i)P(Y = Y_i)}{P(X)} \quad \text{Denklem (3.83)}$$

Denklem (3.83)'de $Y = Y_i$, X veri noktasının mümkün sınıflarıdır. Bayes teoremi bize önsel olasılıkları $P(X | Y = Y_i)$ ve gözlemlenen veriyi kullanarak sonsal olasılıkları hesaplama

$P(Y = Y_i \setminus X)$ olanağı sağlar. NB algoritması naif özelliğini her bir sınıftaki girişleri koşullu olarak bağımsız varsayması sayesinde alır. NB bilinen yöntemlerden daha hızlı ve doğru sonuçlar verebilir. NB tekniğinin en önemli katkısı özellikler arasındaki korelasyonu ihmal ederek varyansı azaltması ve yanlılığı artırmasıdır. Bu sayede aşırı uyum probleminin de üstesinden gelir.

d özelliğe sahip sınıflandırma vektörünü X ile gösterelim. Tüm sınıflar üzerinde maksimum sonsal olasılık aşağıdaki eşitlik ile verilir:

$$\operatorname{argmax}_{Y_i \in Y} P(Y = Y_i) \prod_{j=1}^d P(X = X_j \setminus Y = Y_i) \quad \text{Denklem (3.84)}$$

Projede her bir özellik X_i ayrık değerler almaktadır. Bu nedenle, yeni veri noktasını sınıflandırmak için kullanılan bilgi vektörlerin bir araya getirilmesi ile temsil edilebilir. Bu temsil, verilen sınıflandırma görevini yerine getirmek için gereken verinin toplanmasını mümkün hale getirir. $P = P(Y = Y_i)$ olmak üzere $P = P_i$ bir vektör ve $T_{i,j} = P(X = X_j \setminus Y = Y_i)$ olmak üzere T bir matris olsun. Eğer T ve P veriliyorsa, yeni veri noktasının sınıf etiketi Denklem (3.84) kullanılarak belirlenebilir. Bu projede tahminleyiciler için belirlenen dağılım çok değişkenli çok terimli dağılımdır [93, 94].

3.5.5. K-Kat Çapraz Doğrulama

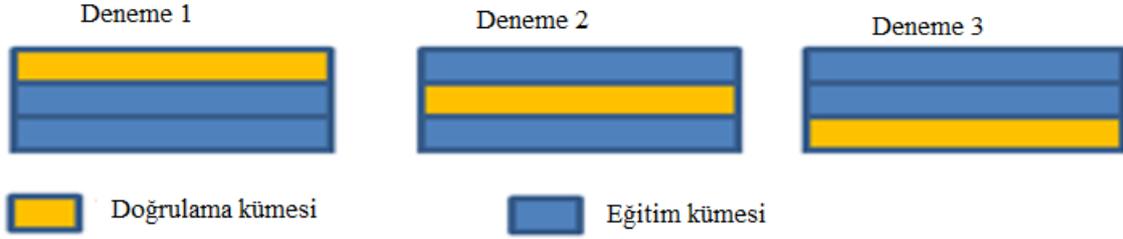
K-kat çapraz doğrulama tekniği son yıllarda sınıflandırma çalışmalarının çoğunda yaygın olarak kullanılmaktadır. Uygulamaların birçoğunda eğitim ve test için kullanılan veri sayısı sınırlıdır. Sınıflandırma performanslarının yüksek olması ve iyi bir model oluşturmak için mevcut verinin çoğunun eğitim için kullanılması istenir. Ancak, doğrulama kümesi küçükse tahminleyici performansında bozulmuş kestirimler karşımıza çıkar. Bu problemin üstesinden gelmek için üretilen çözümlerden biri çapraz doğrulama kullanmaktır.

K-kat çapraz doğrulamada $(k-1)k$ adet veri eğitim için kullanılır. Veri sayısı bariz bir şekilde az ise $k=N$ durumu ele alınır. Burada N toplam veri sayısıdır ve bu durum leave-one-out (LOO) tekniği olarak bilinir. Çapraz doğrulama algoritmalarının dezavantajlarından biri hesap karmaşıklığının artmasıdır. Diğerleri ise, k adet veri alt kümesi dengeli oluşturulmazsa sonuçların güvenilirliğinin azalmasıdır.

Basit olarak, k -kat sürecinde ilk olarak mevcut veri k adet gruba (alt kümeye) bölünür. Her bir gruptaki veri sayısı eşittir. Daha sonra, $k-1$ adet grup modelin eğitimi için kullanılır. Geriye kalan grup ise kullanılan sınıflandırıcının test edilmesi için ayrılır. Bu işlem Şekil 6.4'de gösterildiği gibi tüm k seçenekleri için tekrar edilir. Sınıflandırıcının nihai performansı k

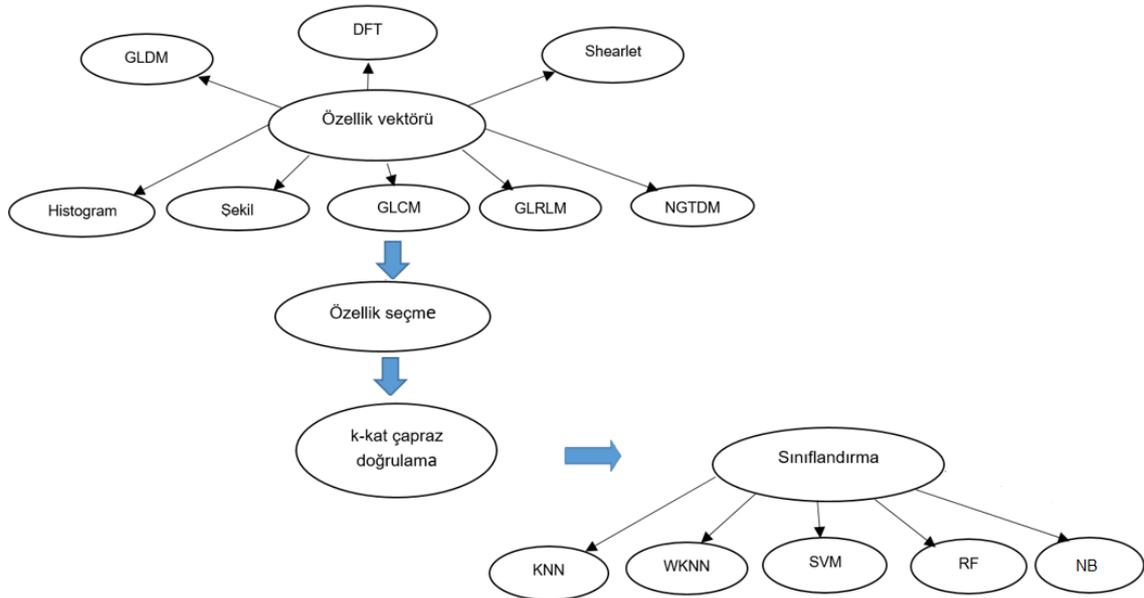
deneme sonuçlarının ortalaması alınarak hesaplanır. Projede 3-kat ve 10-kat çapraz doğrulama kullanılmıştır [90].

Şekil 3.27. K-kat çapraz doğrulama süreci (k=3)



Projede uygulanan sınıflandırma başka bir ifadeyle karar verme adımı genel hatlarıyla Şekil 3.27'de özetlenmiştir.

Şekil 3.27. Karar verme adımı genel yapısı



4. BÖLÜM: BULGULAR VE TARTIŞMA/SONUÇ

Projenin bu bölümünde amacımız meme lezyonlarının tespiti ve sınıflandırılması amacıyla tasarlanan yazılım tabanlı sistemin performansını değerlendirmek ve elde edilen sonuçları sunmaktır. Performans değerlendirmek amacıyla sınıflandırma adımı içeren çalışmaların değerlendirilmesinde kullanılan doğruluk, hassasiyet, özgüllük ve duyarlılık parametreleri hesaplanmıştır. Bunun dışında, segmentasyon yani lezyon tespiti aşamasının başarımını incelemek için manuel segmentasyon ve otomatik segmentasyon sonuçları karşılaştırılarak yorumlanmıştır.

Proje kapsamında, başvuru formunda belirtilen hedeflere ek olarak bir otomasyon sistemi de geliştirilmiştir. Bu sistemin detayları segmentasyon bölümü için aşağıda verilmiştir.

4.1. Geliştirilen Hastane Otomasyon Sistemi

Otomasyon sisteminin segmentasyon kısmında amaç, farklı segmentasyon yöntemlerini meme MR görüntülerine uygulayarak lezyon sınırlarını tespit ettikten sonra bit dörtlüsü yöntemi ile lezyon alanı hesaplanmaktadır. Lezyon alanının hesaplanmasında kullanıcıya (uzmana) istediği bölgeyi seçme olanağı da sağlanmaktadır. Geliştirilen otomasyon sistemi temel olarak aşağıda verilen adımlar kullanılarak tasarlanmıştır:

1. T-SQL dili kullanılarak veri tabanının oluşturulması,
2. C # dili ile otomasyon sisteminin yazılımının hazırlanması,
3. C # ekranında belirtilen segmentasyon yöntemlerinin Matlab ortamında yazılması,
4. SQL-C # ve C # -Matlab bağlantısının kurulması.

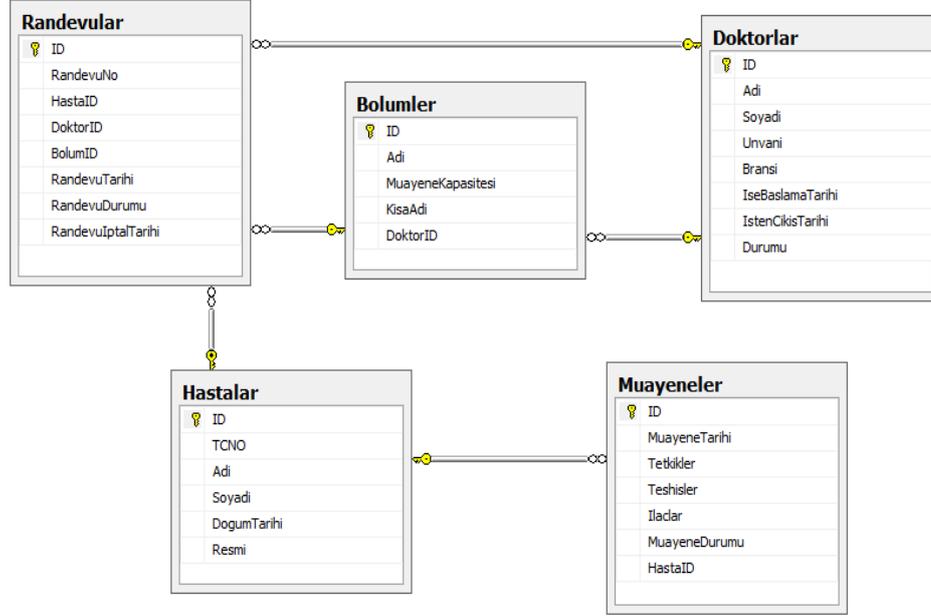
Görüldüğü gibi ilk aşamada SQL ile bir veri tabanı oluşturulmaktadır. Oluşturulan bu veri tabanı üzerinde verileri güncelleme, silme, yedekleme vb. işlemler bir sistemle kontrol edilmektedir. Bu sisteme veri tabanı yönetim sistemi denilmektedir. Veri tabanı yönetim sistemi, fiziksel hafızayı ve veri tiplerini kullanıcılar adına şekillendirip denetleyen ve kullanıcılarına standart bir SQL ara yüzü sağlayarak onların dosya yapıları, veri yapısı, fiziksel hafıza gibi sorunlarla ilgilenmek yerine veri giriş-çıkışı için uygun ara yüzler geliştirmelerine olanak sağlayan yazılımlardır. Çalışmada Microsoft SQL Server 2008 R2 kullanılmaktadır.

Otomasyon sisteminin tasarımının başlangıcında sisteme girilecek veriler için tablolar oluşturulmaktadır. Bu tablolara girilecek verilerin (örneğin; doktor isminin) türlerinin belirlenmesi gerekmektedir.

Şekil 4.1'de geliştirilen hastane otomasyonunun tüm tabloları ve tabloların birbirleriyle olan bağlantıları gösterilmektedir. Bu çalışmada, ilk aşamada beş adet tablo oluşturulmuştur. Geliştirilmek istenirse sisteme muhasebe kısmı, ilaç takip sistemi vb. için gerekli tablolar da

eklenebilir. Gerekli veri tabanını oluşturduktan sonra kullanıcının işlem yapacağı sisteme dönüştürmek için C# form uygulamalarından faydalanılmaktadır.

Şekil 4.1. Geliştirilen hastane otomasyon sisteminin bütün tabloları



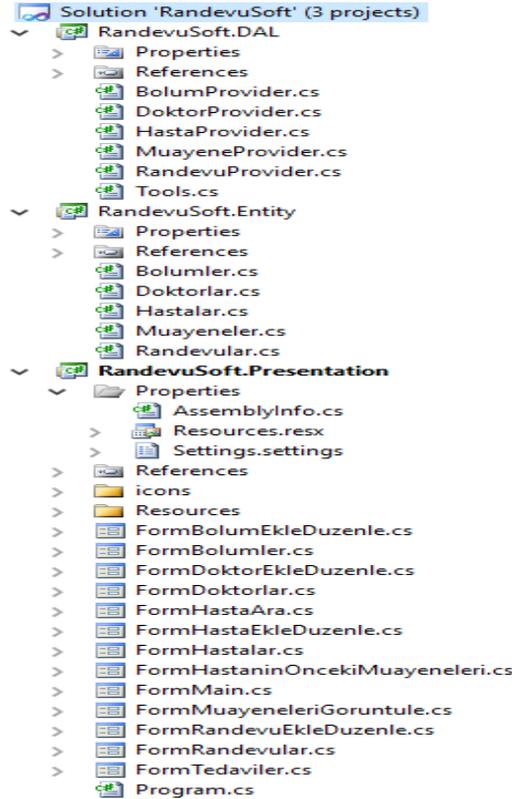
Sınıflar ve sistem için gerekli olan diğer yapılar (metotlar, alanlar, özellikler) oluşturulurken Nesne Yönelimli Programlama (Object Oriented Programming, OOP) mantığı kullanılmıştır. OOP bir görevi gerçekleştirmek için birbirleriyle etkileşime giren nesnelere dayalı bir yazılım geliştirme yaklaşımıdır. Bu etkileşimin temel yapısı nesnelere arasında mesajın gönderilmesi ve geri alınması biçimindedir. Bir nesne verilen bir mesaja tepki olarak bir fonksiyonu ya da işlemi aktif etmektedir. Sistemin ana yapısında çok (n) katmanlı mimari (n-tier architecture) yapısı modelinden esinlenilmiştir. Üç katmanlı yapıda, veri katmanı (data layer, DAL), iş katmanı (business layer, entity) ve sunum katmanından (presentation layer) yararlanılmaktadır. Yararlanılan katmanları kısaca,

- Veri katmanı (Data Layer): Bu katman bir uygulamanın verilerini depolayan kısımdır.
- İş Katmanı (Business Layer): Sunum katmanı ile veri katmanı arasında köprü işlevi görmektedir.
- Sunum Katmanı (Presentation Layer): Bir uygulama ile kullanıcıların etkileşimde olduğu katmandır.

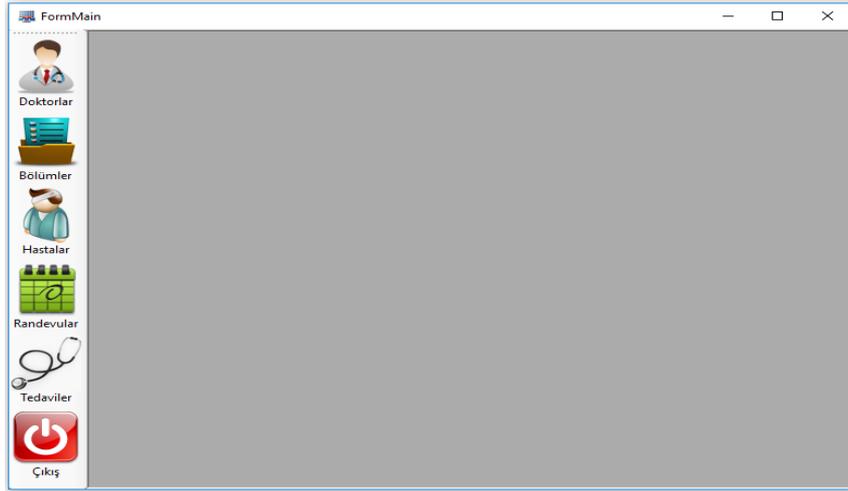
Şekil 4.2'de kullanılan üç katmanlı mimari yapısının genel görüntüsü yer almaktadır. Sistemin bu adımları gerçekleştirildikten sonra sunum katmanında kullanıcı ekranları tasarlanmakta ve sistem oluşturulmaktadır. Şimdi kullanıcı için tasarlanan ekranları açıklayalım.

Ana Ekran: Sunum katmanında tasarlanan ilk kullanıcı ekranı Şekil 4.3'de görülmektedir. Bu ekranda uygulamaya resimli araç çubuğu eklemek için sol tarafta “tool strip menu” aracı (tool) kullanılmaktadır. Araç çubuğundaki ilk buton “Doktorlar” butonudur. Bu buton tıklandığında aktif ya da pasif durumda bulunan hastanedeki tüm doktorları gösteren bir ekran karşımıza çıkacaktır. Bu ekran üzerinden yeni doktor bilgileri ekleme, güncelleme ve silme işlemleri de yapılmaktadır. Araç çubuğundaki ikinci satırda bölümler sekmesi yer almaktadır. Bu buton tıklandığında hastanenin aktif-pasif tüm bölümlerini içeren bir ekran açılmaktadır. Ayrıca bu ekranda yeni bölüm ekleme, silme ve güncelleme işlemleri de yapılmaktadır. Araç çubuğundaki üçüncü satırdaki “Hastalar” sekmesi aktif edildiğinde, tüm hastaların listesinin bulunduğu bir ekran gelmektedir. Burada yeni hasta ekleme, güncelleme ve silme işlemleri yapılmaktadır. Araç çubuğundaki dördüncü satırda “Randevular” sekmesi yer almaktadır. Bu buton aktif edildiğinde randevuları içeren bir ekran çıkmaktadır. Bu ekranda yeni randevu ekleme, güncelleme ve silme işlemleri yapılabilmektedir. Araç çubuğunun beşinci satırında yer alan “Tedaviler” kısmı aktif edildiğinde muayene bekleyen hastaların olduğu bir ekran yer almaktadır. Bu kısım şuan için sadece meme MR görüntülerindeki lezyonu belirlemek ve gerekli ölçümleri yapmak için tasarlanmıştır. Araç çubuğunda son satırda yer alan “Çıkış” sekmesi aktif olduğunda sistem kapanmaktadır.

Şekil 4.2. Üç katmanlı mimari yapısı

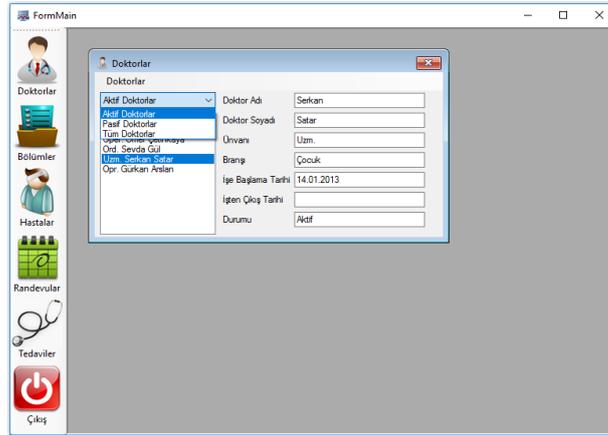


Şekil 4.3. Kullanıcı başlangıç ekranı



Doktorlar Ekranı: Ana ekranda “Doktorlar” butonuna tıkladığında aktif edilen ekrandır. Şekil 4.4’de doktorlar butonu aktif olduğunda kullanıcının karışılacağı ekran yer almaktadır. Burada yedi adet “text box”, yedi adet “label”, bir adet “list box”, bir adet “combo box” ve bir adet “tool script menu” yer almaktadır. Şekil 4.4’deki görüntü “combo box” aracına tıkladığında elde edilen görüntüdür. Burada tüm, aktif ve pasif doktorların oluşturduğu üç bölüm yer almaktadır. Bu şekilde tüm doktorlar seçilmektedir ve tüm doktorların listesi “list box”ta gösterilmektedir.

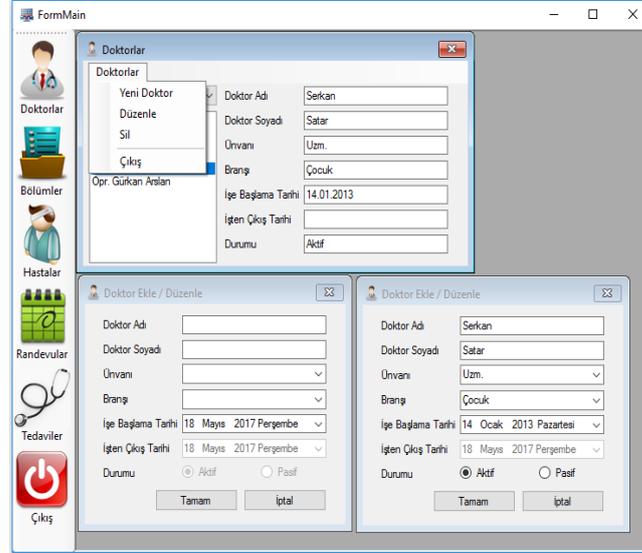
Şekil 4.4. Doktorlar ekranı



Örneğin; Şekil 4.4’de “list box” tan Uzm. Serkan Satır seçilmiştir. Seçimi yapılan doktor bilgileri sağ tarafta “text box” larda yer almaktadır. “combo box”ta seçimi “Aktif Doktorlar” yaptığımızda hastanede mevcut olan doktorlar “list box”ta sıralanmaktadır. Aynı durum “combo box”ta da “Pasif Doktorlar” sekmesinin seçimiyle de gerçekleşmektedir. Yani hastanede olmayan veya izinli olan doktorların listesi “list box” altında yer alacaktır. Şekil 4.4’de “combo box” in üstünde yer alan “Doktorlar” adındaki “tool script menu”ye

tıklandığında ise Şekil 4.5'deki ilk ekran görülmektedir. Bu araç çubuğunda doktorlarla ilgili doktor ekleme, listeden doktor silme ya da doktor bilgilerini güncelleme işlemleri rahatlıkla yapılabilmektedir.

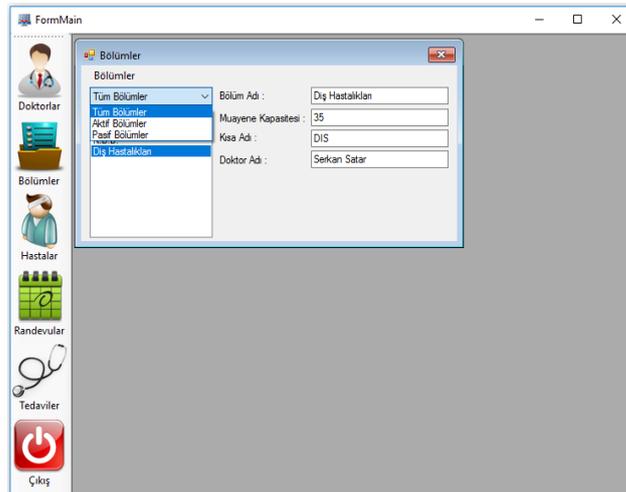
Şekil 4.5. Doktor ekleme, silme ve güncelleme ekranı



Doktorlar	Doktor Ekle / Düzenle	Doktor Ekle / Düzenle
Doktor Adı	Doktor Adı	Doktor Adı
Doktor Soyadı	Doktor Soyadı	Doktor Soyadı
Unvanı	Unvanı	Unvanı
Branş	Branş	Branş
İşe Başlama Tarihi	İşe Başlama Tarihi	İşe Başlama Tarihi
İşten Çıkış Tarihi	İşten Çıkış Tarihi	İşten Çıkış Tarihi
Durumu	Durumu	Durumu

Bölümler Ekranı: Ana ekranda “Bölümler” butonuna tıklandığında aktif edilen ekrandır. Şekil 4.6'da bölümler butonu aktif olduğunda kullanıcının karşılaşacağı ekran verilmiştir. Burada dört adet “text box”, dört adet “label”, bir adet “list box”, bir adet “combo box” ve bir adet “tool script menu” yer almaktadır. Şekil 4.6'da “combo box” aracına tıklanmış görüntü yer almaktadır. Butonda tüm, aktif ve pasif bölümlerin oluşturduğu üç bölüm yer almaktadır. Bu araç çubuğunda bölümlerle ilgili üç adet işlem yapılabilmektedir. Bu işlemler bölüm ekleme, düzenleme ve silme işlemleridir.

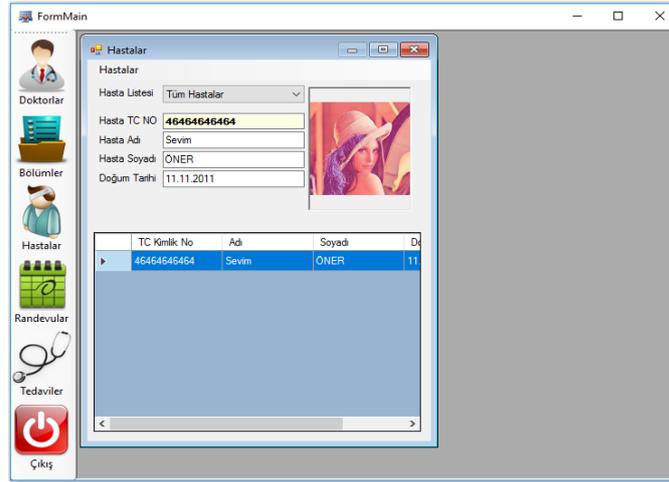
Şekil 4.6. Bölümler ekranı



Bölümler	Bölümler
Tüm Bölümler	Bölüm Adı :
Aktif Bölümler	Muayene Kapasitesi :
Pasif Bölümler	Kısa Adı :
Dış Hastalıklar	Doktor Adı :

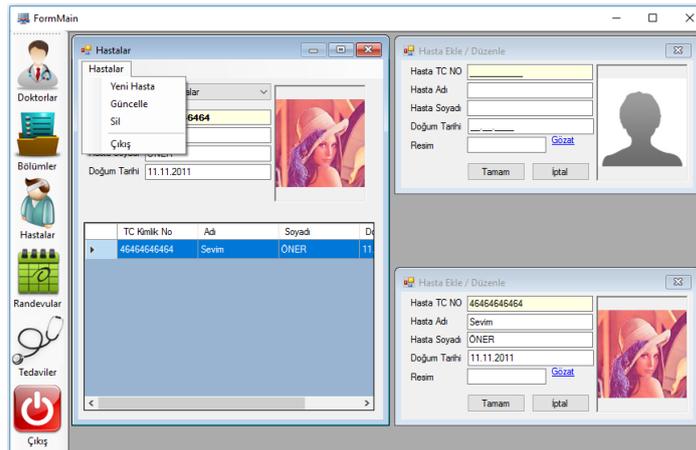
Hastalar Ekranı: Ana ekranda “Hastalar” butonuna tıklandığında aktif hale gelen ekrandır. Şekil 4.7’de hastalar butonu aktif olduğunda kullanıcının karışılacağı ekran yer almaktadır. Burada dört adet “text box”, beş adet “label”, bir adet “picture box”, bir adet “combo box”, bir adet “data grid view” ve bir adet “tool script menu” yer almaktadır.

Şekil 4.7. Hastalar ekranı



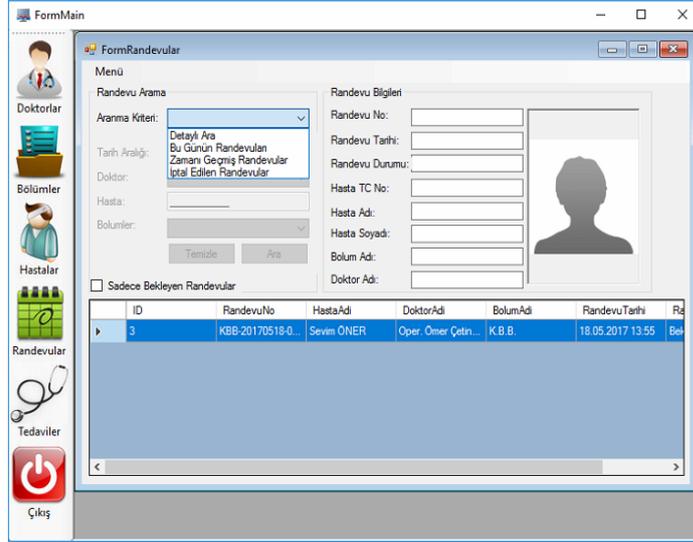
Şekil 4.7’de “combo box” ta “Tüm Hastalar” sekmesi aktif edilmiştir ve tüm bölümlerin listesi “list box”ta gösterilmektedir. Örneğin; Şekil 16’da “data grid view” den tüm hastaların içinden “Sevim Öner” seçilmiştir. Seçimi yapılan hasta bilgileri yukarıda “text box” larda yer almaktadır. Şekil 4.7’de “combo box” ın üstünde yer alan “Hastalar” adındaki “tool script menu”ye tıklandığında ise Şekil 4.8’deki ilk ekran görülmektedir. Bu araç çubuğunda hastalarla ilgili üç adet işlem yapılabilmektedir. Bu işlemler hasta ekleme, hasta bilgileri düzenleme ve silme işlemleridir.

Şekil 4.8. Hasta ekleme, silme ve güncelleme ekranı



Randevu Ekranı: Ana ekranda “Randevular” butonuna tıklanıldığında aktif edilen ekrandır. Şekil 4.9’de randevular butonu aktif olduğunda kullanıcının karşılaşacağı ekran yer almaktadır. Burada on adet “text box”, on dört adet “label”, bir adet “data grid view”, üç adet “combo box”, bir adet “picture box”, iki adet “group box”, bir adet “check box”, iki adet “button” ve bir adet “tool script menu” yer almaktadır. Ekran ilk açıldığında “data grid view” de sistemdeki tüm randevular gözükmemektedir. Şekil 4.9’de gösterildiği gibi “combo box” aracına tıklanırsa eğer bu aracın içindeki seçeneklerin açıldığı görülür. Burada, “Detaylı Ara”, “Bu Günün Randevuları”, “Zamanı Geçmiş Randevular” ve “İptal Edilen Randevular” gibi dört adet seçenek yer almaktadır. Bu ekranda yine ekleme, güncelleme ve silme işlemleri yapılabilmektedir.

Şekil 4.9. Randevular ekranı



ID	RandevuNo	HastaAdi	DoktorAdi	BolumAdi	RandevuTarihi	Ra
3	KB6-20170518-0.	Sevim ÖNER	Oper. Ömer Çetiri...	K.B.B.	18.05.2017 13:55	Be

Tedaviler Ekranı: Ana ekranda “Tedaviler” butonuna tıklanıldığında aktif edilen ekrandır. Tedaviler ekranında dokuz adet “text box”, on iki adet “label”, on üç adet “picture box”, yedi adet “group box”, dört adet “radio button”, bir adet “numeric up down”, bir adet “link label”, dört adet “button” ve bir adet “tool script menu” yer almaktadır. Buraya kadar anlatılan ekranlarda genel hastane sistemi bilgileri yer almaktadır. Sistemin en can alıcı noktası aslında bu ekranda gerçekleşmektedir. Bu ekranda radyologlara meme kanserinin sınırlarının belirlenmesi ve lezyonun olduğu alan, çevre ve dairesellik hakkında bilgi veren bir ekran tasarlanmıştır. İlk önce “Bölüm/Doktor Bilgisi” adındaki “group box” içindeki bölüm ve doktorlar belirlenmektedir. Bu işlem gerçekleştirildikten sonra muayene bekleyen hastalar “data grid view” da sıralanır. Bir hasta seçildiğinde “Segmentasyon İşlemleri” ve “Randevu Durumu” isimindeki “group box”lar aktif olacaktır. Seçilen hasta eğer muayeneye gelmediyse direk olarak “Hasta Randevuya Gelmedi” isimli “radio button” aktif edilerek işlem tamamlanır. Hasta muayeneye geldi ise “data grid view” da hasta seçilerek “Segmentasyon

İşlemleri” işlemine başlamak için hastaya ait meme MR görüntüsü kayıtlı olan adresten seçilmelidir. Seçimi yapılan bu görüntüye segmentasyon adımı uygulanması için “Otsu”, “FCM”, “k-Means” veya “Region Growing” isimli “radio button” lardan istenilen yöntem seçilir.

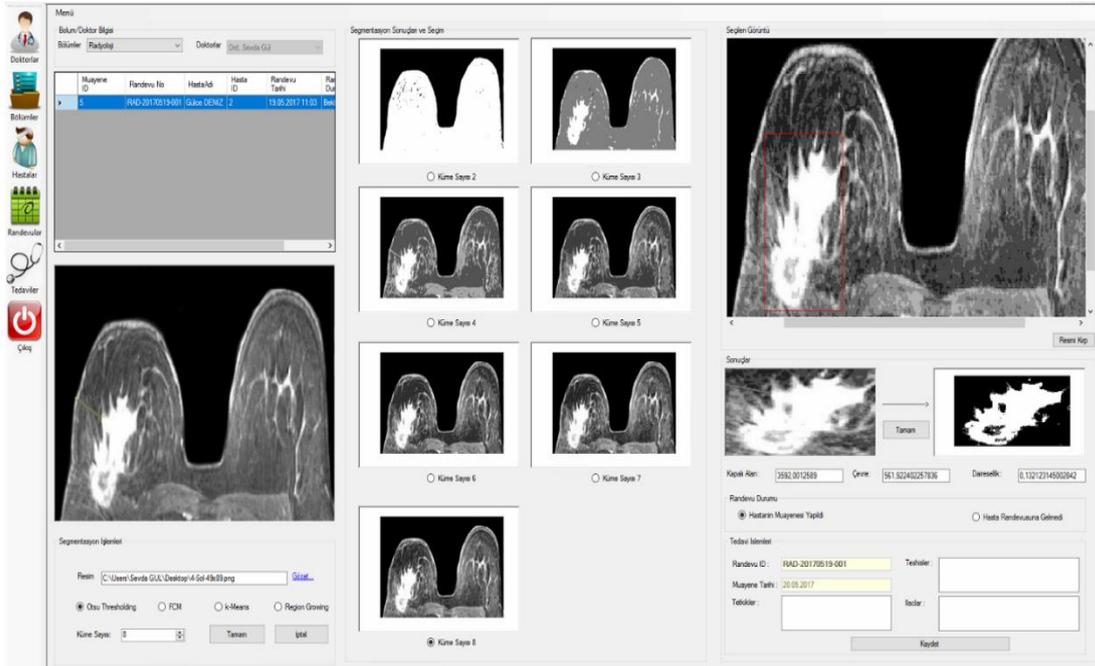
Örneğin; Şekil 4.10’da “Gülce DENİZ” adında bir hasta randevuya gelmiş olsun. Bu hastanın meme MR görüntüsü “Gözet” isimli “link label”a tıklanarak “picture box”ta görüntülenmektedir. Segmentasyon adımı için “Otsu hresholding” isimli “radio button” aktif edilerek ve “Küme Sayısı” isimli “numeric up down” da küme sayısı seçilerek segmentasyon işlemi başlatmak için “Tamam” “button” nuna basılır. Şekil 4.10’da seçilen segmentasyon yönteminin sonuçlarının yer aldığı görüntüler “Segmentasyon Sonuçları ve Seçim” isimli “group box” ta verilmiştir. “group box” içerisinde “numeric up down” da seçtiğimiz sayı olan sekiz değerine kadar olan bütün eşikleme sonuçları yer almaktadır. Örneğin; Şekil 4.12’de küme sayısı sekiz olan görüntü seçilmiştir. Seçilen bu görüntü “Seçilen Görüntü” ismindeki “group box”ta görülmektedir. Uzman, bu görüntüde lezyon alanını belirleyip “Resmi Kırp” isimli “button” a basarak lezyon alanını kesmektedir. “Sonuçlar” ismindeki “group box”ta kesilen lezyonun orijinal hali ve sağ tarafta ise iki seviyeli görüntüsü yer almaktadır. Bu iki görüntünün altında lezyon bilgilerini içeren alan, çevre ve dairesellik hesabı yer almaktadır. Bu bilgiler dâhilinde uzman kişinin yorumlamasıyla hastanın teşhis, tetkik ve ilaç bilgileri girilerek hastanın muayene işlemi tamamlanıp “Kaydet” isimli “button” a tıklanarak muayene tamamlanır. Benzer şekilde diğer yöntemlerle de aynı işlemler benzer adımlarla gerçekleştirilebilir.

C# programı kullanılarak tasarlanan sistem ve sistemin gerçekleştirdiği işlevler açıklanmıştır. Bu ekranlar bir hastanenin yönetimi için genel adımları teşkil etmektedir. Sistemin bizim için en önemli olan kısmı “Tedaviler” ekranıdır. Burada meme MR görüntüleri dört farklı segmentasyon yönteminden biri seçilerek gerçekleştirilmektedir. Ancak segmentasyon yöntemlerinin gerçekleştirme aşaması C# uygulaması ile sağlanmamaktadır. Yöntemlere ait fonksiyonlar Matlab 2017a programında oluşturulmuş ve kullanılmıştır. Sistemin ek kısımlarında segmentasyondan devam ederek karar aşamasına kadar tüm adımların butonlarla kolayca gerçekleştirilebileceği daha komplike bir yapılar oluşturmak mümkündür. Temel altyapıda ve çalışma mantığında bir farklılık olmadığından bu kısımların da tek tek gösterilmesine açıklanmasına gerek kalmamıştır.

Şekil 4.10 Hasta seçimi yapılmış tedaviler ekranı



Şekil 4.11 Otsu eşikleme ile örnek bir meme MR görüntüsünde lezyon tespiti



4.2. Lezyon Tespiti Adımının Başarımının Değerlendirilmesi

Lezyon tespiti aşamasının amacı sağ, sol ya da her iki memede de lezyon olması durumunda lezyonun sınırlarının en doğru şekilde belirlenmesini sağlamaktır. Bu aşamanın başarılı olması tüm sistemin başarımını doğrudan etkilemektedir. Lezyon tespiti aşamasının performansını incelemek amacıyla yapılması gereken işlem manuel segmentasyon sonuçları ile otomatik segmentasyon sonuçlarını birbiri ile kıyaslamaktır. Kıyaslama iki şekilde yapılabilir: i. Uzman tarafından belirlenen lezyon bölgesi otomatik olarak elde edilen bölge ile görsel olarak kıyaslanabilir, ii. İlgili bölümde verilen metrikler kullanılarak sayısal sonuçlar üzerinden sonuçların doğruluğu yorumlanabilir.

İlk kıyaslama projede görevli uzman tarafından gerçekleştirilmiştir. Elde edilen sonuçlara göre: Mevcut meme segmentasyon çalışmalarında karşılaşılan en önemli sorunlardan biri aksiyel olarak alınan kesitlerde sinyal şiddetlerinin yakın olmasından dolayı fibroglandüler doku ile göğüs kasının birbirinden ayrılabilmesidir. Bu nedenle meme bölgesi de doğru tespit edilememektedir. Projede gerçekleştirilen yerel adaptif eşikleme, bağlı bileşen analizi, yatay iz düşüm ve maskeleymeden oluşan meme bölgesi segmentasyonu adımı ile bu sorun çözülmüştür. Bazı görüntülerde ise meme yapısından kaynaklanan durumlardan dolayı meme lezyonu içerebilen şüpheli bölge istenildiği kadar hassa elde edilememektedir. Projede lezyon bölgesi tespiti için altı farklı yöntem (Otsu eşikleme yöntemi, bölge büyütme, bulanık c-ortalama, k-ortalamalar, Markov rastgele alanlar, aktif sınırlar) kullanılarak bu sorunun da üstesinden gelinmiştir. Segmentasyon sonrası elde edilen renk tabakaları sayesinde lezyonun malignitesi hakkında uzmana bilgi verilmektedir. Bu da sistemin pozitif yönlerinden biridir.

Projenin katkılarında biri hiçbir müdahale olmadan meme bölgesinin ve sağ-sol meme bölgelerinin ayrı ayrı tespit edilebilmesidir. İlgili bölgenin doğru bir şekilde tespit edilmediğinin belirlenmesi için uzman tarafından manuel olarak belirlenen bölge ile otomatik olarak belirlenen bölge birbiri ile karşılaştırılmıştır. Uzman kontrolüne ek olarak, sayısal metrikler kullanılarak da otomatik ve manuel segmentasyon kıyaslaması yapılabilir. Bu amaçla yaygın olarak kullanılan iki ölçüt vardır. Bu ölçütler DSC ve JC ölçütleridir. DSC ve JC ölçütleri otomatik ve manuel segmentasyon sonuçlarını kıyaslamak için kullanılan ortalama ve birleşik örtüşme oranlarıdır. Projemizde DSC ve JC yüzdeleri sırasıyla 91 ± 0.06 ve 85 ± 0.08 olarak elde edilmiştir. Elde edilen sonuçlar meme bölgesi tespitinin başarılı bir şekilde gerçekleştirildiğini göstermektedir. Ayrıca, meme bölgesinin belirlenmesi sistemin hesap yükünü oldukça azaltmaktadır. Tablo 4.1'den de görüldüğü gibi proje 97

lezyonun sadece 13'ünde (0,14/durum) yalancı pozitif bölge tespit etmiştir. Bu oran mevcut çalışmalara kıyasla veri tabanında çok farklı türde lezyonlar olmasına rağmen oldukça başarılıdır. Ayrıca projede önerilen yöntem sayesinde belirlenemeyen hiçbir lezyonun olmadığı da görülmektedir.

Tablo 4.1. Segmentasyon sürecinin lezyon tespiti başarımı

Metot	Belirleme Oranı	Yalancı pozitif belirleme	Veri seti
Önerilen yöntem	1	0,14/durum	97 durum (74 kötü huylu ve 23 iyi huylu)
Shokouhi vd. [2017]	0,94	5,29/durum	76 durum (107 iyi huylu ve 63 kötü huylu)
Ertaş vd. [2008]	1	0,64/durum	19 durum (19 iyi huylu ve 20 kötü huylu)
Chang vd. [2014]	0,93	6,15/durum	54 durum (28 iyi huylu ve 67 kötü huylu)

4.3. Sınıflandırma Aşamasının Başarımı

Bu aşamada amacımız meme lezyonlarının türlerine ait kararın en doğru şekilde verilmesidir. Bu amaçla birçok teknik kullanılmış farklı durumlar ele alınmıştır. Projede sınıflandırma performanslarının karşılaştırılması amacıyla Tablo 4.2'de verilen hata matrisi oluşturularak doğruluk, duyarlılık, özgüllük ve hassasiyet oranları hesaplanmıştır.

Tablo 4.2 Hata matrisi

Hata Matrisi		Tahmin	
		İyi Huylu	Kötü Huylu
Gerçek Değer	İyi Huylu	Doğru Negatif (True Negative, TN)	Yalancı Pozitif (False Positive, FP)
	Kötü Huylu	Yalancı Negatif (False Negative, FN)	Doğru Pozitif (True Positive, TP)

Sınıflandırıcıların karar performanslarını değerlendirmek için doğruluğa ek olarak hata (konfüzyon) matrisi oluşturularak hesaplanan başka ölçütler de vardır. Bu ölçütler duyarlılık, özgüllük ve hassasiyettir. Doğruluk, duyarlılık, özgüllük ve hassasiyet ölçütlerinin hesaplanışları aşağıdaki eşitliklerde verilmiştir.

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN} \times 100 \quad \text{Denklem (4.1)}$$

$$Duyarlılık = \frac{TP}{TP + FN} \times 100 \quad \text{Denklem (4.2)}$$

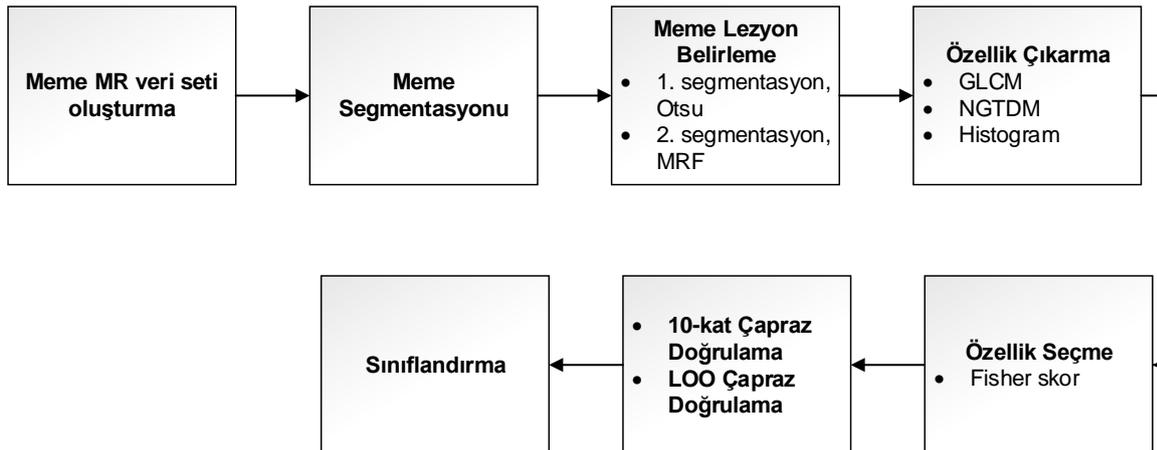
$$Özgüllük = \frac{TN}{TN + FP} \times 100 \quad \text{Denklem (4.3)}$$

$$Hassasiyet = \frac{TP}{TP + FP} \times 100 \quad \text{Denklem (4.4)}$$

Doğruluk doğru tahminlerin tüm tahminlere oranıdır. Veri tabanında bulunan lezyonlardan ne kadarının doğru olarak sınıflandırıldığını yüzde olarak hesaplama olanağı sağlar. Duyarlılık doğru tahmin edilen pozitif örneklerin oranıdır. En iyi değeri %100'dür ve duyarlılık değeri en iyi değerini aldığı anda yalancı negatif sayısı sıfır demektir. Özgüllük ise doğru tahmin edilen negatif örneklerin oranıdır. Özgüllük, maksimum değeri olan %100'e ulaştığında yalancı pozitif sayısı da sıfıra yakınsar. Hassasiyet doğru tahmin edilen pozitif örneklerin tüm pozitif örneklere oranıdır.

Proje kapsamında yapılan birinci çalışmada lezyon segmentasyonunda Otsu ve MRF yöntemleri birlikte kullanılmıştır. Özellik çıkarma adımında histogram, GLCM ve NGTDM özellikleri kullanılarak bir sınıflandırma yapılmıştır. Burada amaç, tespit edilen lezyonları iyi huylu-kötü huylu olarak sınıflandırmaktır. Çalışmada KNN ve SVM sınıflandırıcılarının başarımları incelenmiştir. KNN için komşu sayısı k=7 olarak seçilmiş ve mesafe metriği olarak Öklid mesafesi kullanılmıştır. SVM'de ise Gaussian kernel fonksiyonu tercih edilmiştir. Sınıflandırıcıların performansını artırmak için 10-kat çapraz doğrulama tekniği de çalışmaya dâhil edilmiştir. Çalışmanın genel şeması Şekil 4.12'de gösterilmiştir. Altı farklı senaryo için performanslar Tablo 4.3'de verilmiştir.

Şekil 4.12. İlk çalışmanın blok diyagram gösterilimi.



Tablo 4.3. Farklı durumlar için KNN ve SVM sınıflandırma performansları

Sınıflandırıcı	Doğruluk (%)	Duyarlılık (%)	Hassasiyet (%)	Açıklama
SVM	80	100	80,06	Durum 1: Özellik seçme ve çapraz doğrulama yok
k-NN	73,33	91,67	79,84	
SVM	85,89	100	85	Durum 2: Özellik seçme yok, 10-kat çapraz doğrulama var
k-NN	78,88	97,73	80,05	
SVM	83,18	96,79	84,27	Durum 3: FS (ortalama) ve 10-kat çapraz doğrulama var
k-NN	80,72	100	81,68	
SVM	83,35	100	82,12	Durum 4: FS (0,1) ve 10-kat çapraz doğrulama var
k-NN	80,05	99,16	80,46	
SVM	83,20	98,79	83,14	Durum 5: FS (ortalama) ve LOO var
k-NN	81,03	100	79	
SVM	85,88	100	85	Durum 6: FS (0,1) ve LOO var
k-NN	81,15	99,16	79,04	

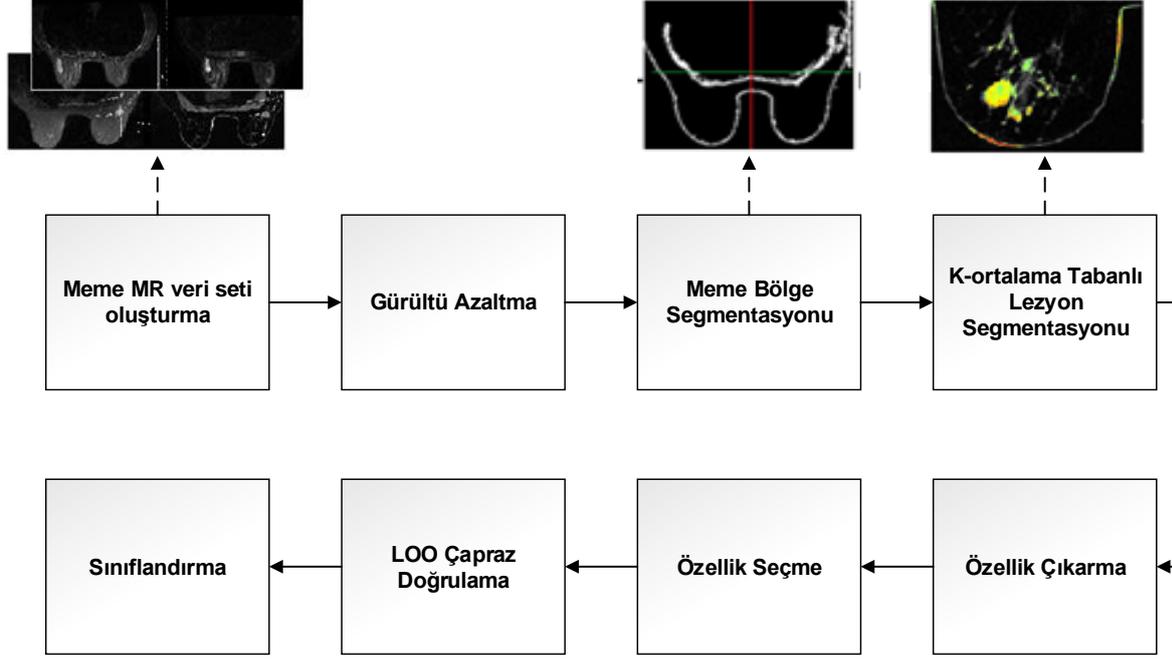
Tablo 4.4. Performans karşılaştırma tablosu

	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	Hassasiyet (%)
Sunulan yöntem	85,89	100	66,67	85
Piantadosi vd. [95]	83,33	95,14	66,67	-
Marrone vd. [10]	76,19	73,91	78,95	-
Glaßer vd. [34]	64,29	95,65	26,32	-

Yapılan bu çalışmada histogram, GLCM ve NGTDM tabanlı 39 özellik kullanılmıştır. Özellik seçmede FS yöntemi için iki ayrı eşik değeri seçilmiştir. Eşiklerden ilki FS ortalama değeri değeri 0,1 olarak belirlenmiştir. Özellik seçme vektöründe, ortalama değer eşiği ile 15, 0,1 eşiği ile 25 özellik kalmıştır. Bu sayede özellik seçme adımının etkisi de incelenmiştir. Çapraz doğrulama adımında en iyi performansları veren 10-kat ve LOO teknikleri kullanılmıştır. Elde edilen sonuçlara göre, SVM yöntemi en yüksek doğruluk, duyarlılık ve hassasiyet değerlerini ikinci ve altıncı durumda sağlamıştır. Diğer durumlar için de performansı oldukça yüksektir. Tablo 4.4'de ise çalışmanın mevcut ilgi gören çalışmalarla karşılaştırmalı analizi yapılmıştır. Tabloya göre, çalışma oldukça başarılı sonuçlar elde etmektedir. Özgüllük değeri mevcut çalışmaların çoğunda daha yüksektir. Bir çalışma ile

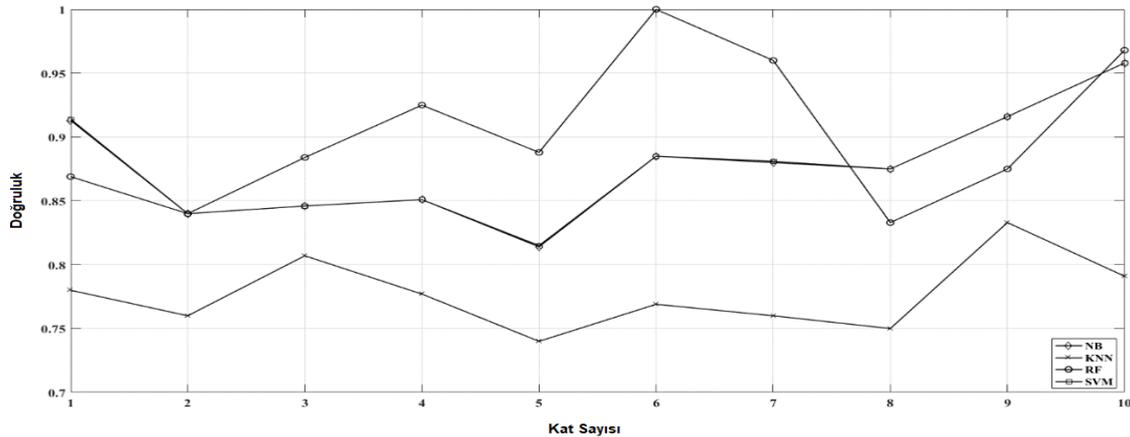
ise aynıdır. Özgüllük değeri doğru tahmin edilen negatif örneklerin oranıdır. Özgüllük, maksimum değeri olan %100'e ulaştığında yalancı pozitif sayısı sıfıra yakınsar.

Şekil 4.13 İkinci çalışmanın blok diyagramı

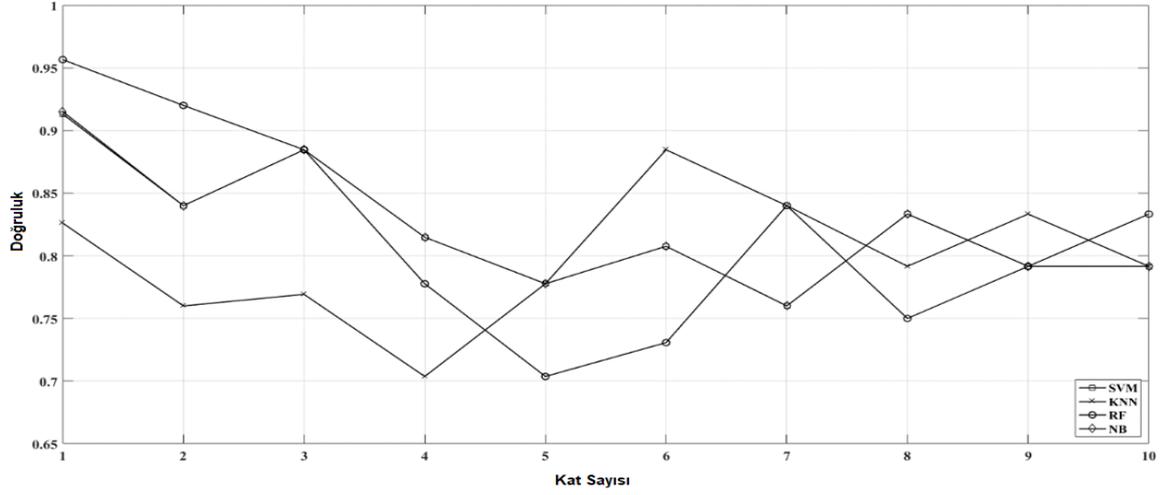


Proje kapsamında yapılan ikinci çalışmada lezyon segmentasyonunda k-ortalama yöntemi kullanılmıştır. Özellik çıkarma adımında histogram, şekil, GLCM, GLRLM, NGTDM ve GLDM özellikleri hesaplanmıştır. Çalışmada toplamda 88 özellik elde edilmiştir. Özellik çıkarma adımında FS ve sınıflandırma öncesi LOO çapraz doğrulama yöntemlerinden yararlanılmıştır. Son olarak karar aşamasında SVM, KNN, RF ve NB teknikleri uygulanmıştır. Şekil 4.14 ve Şekil 4.15'de her bir kat için doğruluk sonuçları grafiksel olarak gösterilmiştir. Tablo 4.5'de ise çalışmanın performansı analiz edilmiştir.

Şekil 4.14. 10-kat çapraz doğrulama için özellik seçmesiz elde edilen doğruluk değerleri



Şekil 4.15. 10-kat çapraz doğrulama için özellik seçme varken elde edilen doğruluk değerleri



Şekil 4.14 ve Şekil 4.15 10-kat çapraz doğrulamanın her bir katındaki doğruluk sonuçlarını göstermek amacıyla verilmiştir. Şekil 4.15 incelendiğinde özellik seçme adımı uygulandığında özellikle yedinci kattan itibaren elde edilen doğruluk değerlerinin varyansı azalmaktadır. SVM ve NB için doğruluk varyansı 0.023, KNN için 0.026 ve RF için 0.069 olarak hesaplanmıştır. Dolayısıyla sonuçların da güvenilir olduğu doğrulanmıştır.

Tablo 4.5. Sınıflandırıcı performansları

		Ortalama Doğruluk (%)	Ortalama Duyarlılık (%)	Ortalama Özgüllük (%)	Ortalama Hassasiyet (%)	Maksimum Doğruluk (%)	Minimum Doğruluk (%)
10-kat çapraz doğrulama Özellik seçme yok	SVM	87,80	100	60	86,0	95,83	81,48
	KNN	78,56	96,80	20	80,0	83,33	74,07
	RF	90,36	96,25	83,33	92,0	100	83,33
	NB	87,82	100	66,67	86,0	95,83	81,48
10-kat çapraz doğrulama FS tabanlı özellik seçme	SVM	82,15	100	56,66	81,0	91,30	76
	KNN	79,36	92,29	50	83,0	88,46	70,37
	RF	81,88	92,81	80	85,0	95,65	70,37
	NB	82,2	100	60	81,0	91,30	76

Tablo 4.6. Önerilen çalışmanın karşılaştırmalı analizi

Yöntemler	Ortalama Doğruluk (%)	Ortalama Duyarlılık (%)	Ortalama Özgüllük (%)	Ortalama Hassasiyet (%)
Sunulan Yöntem	90,36	96,25	83,33	92,0
Piantodosi vd. [95]	83,33	95,14	66,67	-
Marrone vd. [10]	76,19	73,91	78,95	-
GlaBer et. vd. [34]	64,29	95,65	26,32	-

Tablo 4.5’de blok diyagramı Şekil 4.13’de verilen çalışma sayesinde elde edilen sonuçlar verilmiştir. Tablonun üst kısmında 10-kat çapraz doğrulama varken ancak özellik seçme yokken elde edilen sonuçlar verilmiştir. Alt tarafta ise 10- kat çapraz doğrulama ve FS tabanlı özellik seçme varken elde edilen sonuçlar bulunmaktadır. Tabloda verilen doğruluk, duyarlılık, özgüllük ve hassasiyet değerleri çapraz doğrulama sonucu elde edilen sonuçların ortalamasıdır. Tablodan da görüldüğü gibi en yüksek doğruluk RF sınıflandırıcı ile 10-kat çapraz doğrulama var özellik seçme yok iken elde edilmiştir. SVM ve NB sınıflandırıcıların doğruluk performansları yakındır (~%88).

Tüm sınıflandırıcıların duyarlılık değerleri %96 civarındadır. Bu sonuç bize yalancı negatif sayısının oldukça düşük olduğunu gösterir. Yani sunulan sistem memede lezyon varsa çok büyük bir ihtimalle yakalamaktadır. Bu sayede teşhis edilememeden kaynaklı problemler azaltılmış olur. Bu sonuç proje için oldukça önemli bir sonuçtur.

Özgüllük değerleri incelendiğinde en yüksek özgüllük değerinin RF yöntemi ile %83.33 olarak elde edildiği görülmüştür. İlk çalışmaya kıyasla özgüllük değerinde de bir başarı elde edilmiştir. İlk çalışmada özgüllük %66.67 iken ikincisinde %83.33’e yükselmiştir. Bu da bize yalancı pozitif sayısının oldukça azaldığını, doğru negatif sayısında arttığını gösterir. Tablo 4.6 incelendiğinde diğer çalışmalara göre projenin performansının oldukça öne çıktığı rahatlıkla görülmektedir. Duyarlılık doğru tahmin edilen pozitif örneklerin oranıdır. En iyi değeri %100’dür ve duyarlılık değeri en iyi değerini aldığı anda yalancı negatif sayısı sıfır demektir. Bu durumda doğru pozitif sayısı da en yüksek değere ulaşmıştır.

10-kat çapraz doğrulama ve FS özellik çıkarma var iken sınıflandırıcıların doğruluk değerlerinin azaldığı görülmüştür. Bunun nedeni özellik seçme adımı ile özellik sayısının

belli bir oranda azalmasıdır. Bu sonuç bize özellik seçme prosedürünün her zaman başarımı artırmadığını da söylemektedir. FS yöntemi ile sadece KNN yönteminin doğruluğu artmıştır. Tablo 4.6'da sunulan meme lezyon tespit ve sınıflandırma sisteminin performansı kıyaslamalı olarak değerlendirilmektedir. Tabloya göre, çalışma lezyon malignitesine karar vermede sırasıyla %90.36, %95.25, %83.33 ve %92 ortalama doğruluk, duyarlılık, özgüllük ve hassasiyet ile başarılı olmuştur.

Üçüncü çalışmada dönüşüm uzayı özelliklerinin performansı incelenmiştir. Lezyon segmentasyon adımında aktif sınırlar yöntemi kullanılmıştır. Özellik çıkarma kısmında DFT ile beş, Shearlet dönüşümü ile 21 olmak üzere toplam 26 özellik hesaplanmıştır. Daha önceki çalışmalardan elde edilen tecrübelerle göre burada özellik seçme adımı özellik sayısı zaten az olduğundan uygulanmamıştır. Sınıflandırıcı olarak ise en iyi sonuçları veren RF, NB ve SVM tercih edilmiştir. Elde edilen sonuçlar Tablo 4.7'de verilmiştir.

Tablo 4.7. Dönüşüm uzayı özelliklerinin performansı

Yöntem	Ortalama Doğruluk (%)	Ortalama Duyarlılık (%)	Ortalama Özgüllük (%)	Ortalama Hassasiyet (%)	Maksimum Doğruluk (%)	Minimum Doğruluk (%)
SVM	84,80	100	63,33	84,0	88,83	78,48
RF	86,36	92,85	83,93	88,0	95	83,33
NB	85,82	100	66,67	84,6	92,83	81,48

Elde edilen sonuçlara göre dönüşüm uzayı özellikleri lezyon sınıflandırma adımında SVM, RF ve NB teknikleri ile %84 üzeri ortalama doğruluk sağlamaktadır. Özgüllük değeri RF için oldukça iyi ve bir önceki çalışmada elde edilen sonuca oldukça yakındır. Özellikle duyarlılık değeri neredeyse mükemmel yakındır. Hassasiyet doğru tahmin edilen pozitif örneklerin tüm pozitif örneklere oranıdır. Her üç çalışmada da hassasiyet oranları oldukça yüksektir.

Son olarak, Tablo 3.1'de verilen iyi huylu ve kötü huylu meme lezyonlarının alt gruplarına ayrıştırılması amaçlanmıştır. Bu amaçla RF, KNN, NB ve SVM sınıflandırıcıları tercih edilmiştir. Özellik çıkarma adımında hesaplanan tüm özellikler kullanılmıştır. Yani toplamda 108 özellik üzerinde çalışılmıştır. Tüm özellikler özellik vektörüne dâhil edildiğinde görüntüdeki benzer parametreleri değerlendiren özellikler olduğu tespit edilmiştir. Bu nedenle bu incelemede FS yöntemi kullanılarak özellik seçme yapılmıştır. Lezyon alt türlerinin sayısı her alt tür için eğitim ve test aşamalarında kullanılacak kadar yeterli olmadığından tek olan türler dikkate alınmamıştır. Bunun dışında çapraz doğrulamada LOO

tekniki tercih edilmiştir. Tüm bu şartlar altında elde edilen doğruluk sonuçları Tablo 4.8'de verilmiştir. Sınıf sayısı çok fazla olduğundan hata matrisi oluşturulmamıştır. Bu çalışmada kötü huylu lezyonlar invazif duktal karsinom, invazif lobüler karsinom, duktal karsinom in situ başta olmak üzere papiller karsinom, apokrin karsinom, tübüler karsinom, invazif duktal karsinom+intraduktal papiloma beraberinde yedi alt gruba ayrılmıştır. İyi huylu lezyonlar ise kist, fibroadenom, duktal gland, fibrokistik olmak üzere dört alt gruba ayrılmıştır.

Tablo 4.8. Lezyon alt türlerinde sistem performansı

Sınıflandırıcı	Doğruluk (%)
KNN	59,3
NB	84,8
SVM	84,3
RF	78,1

Tablodan görüldüğü gibi alt türlerin sayısı çok fazla olması durumunda dahi geliştirilen yazılım başarılı sonuçlar sunmaktadır. Projede görevli uzman radyolog elde edilen sonuçların meme kanseri teşhisinde oldukça faydalı bilgi sağladığını ifade etmiştir. Özellikle birbiri ile karışan lezyonlarda dahi sistemin eriştiği doğruluk göz ardı edilemeyecek kadar yüksektir.

4.4. Sonuç

Sonuç olarak proje kapsamında geliştirilen yazılım tabanlı sistem meme lezyonlarının tespit edilmesinde, lezyonların iyi huylu ve kötü huylu olaka ayrıştırılmasında, hatta lezyon alt türlerinin belirlenmesinde dikkate şayan sonuçlar sağlamıştır. Proje süresince yapılan incelemeler sayesinde proje ekibi yazılımın daha da geliştirilebileceği gözleminde bulunmuştur. Proje tamamlandıktan sonra ekibin hedefi MR cihazlarında entegre bir yazılım kiti tasarlamaktır. Bu amaçla ön veriler elde edilmiş ve çalışmalar başlatılmıştır. Projemizin ülkemize faydalı ve çok daha önemli çalışmalara ışık olan bir çalışma olmasını temenni ederiz.

KAYNAKLAR

- [1] Dünya Sağlık Örgütü Uluslararası Ajansı, “Meme Kanseri İstatistikleri” <http://www.wcrf.org/int/cancer-facts-figures/data-specific-cancers/breast-cancer-statistics>. Son erişim tarihi: 06.04.2016.
- [2] Türkiye Halk Sağlığı Kurumu Kansere Daire Başkanlığı, “Türkiye Kansere İstatistikleri”http://kanser.gov.tr/Dosya/ca_istatistik/ANA_rapor_2013v01_2.pdf. Son erişim tarihi: 06.04.2016.
- [3] Özlük, A., “<http://www.dr.aliozluk.com/op-dr-ali-ozluk-genel-cerrahi-uzmani-meme-sagligi-memeyapisi.asp>”, Son erişim tarihi: 06.11.2019.
- [4] “http://www.breastcancer.org/symptoms/understand_bc/what_is_bc.”, Son erişim tarihi: 07.04.2017.
- [5] M. Dolan, T. E. McEwan, R. Doley, and K. Fritzon, Risk Factors and Risk Assessment in Juvenile Fire-Setting, vol. 18, no. 3. Elsevier Inc., 2011.
- [6] Wolfe, J.N., “Risk for Breast Cancer Development Determined by Mammographic Parenchymal Pattern”, *Cancer*, Vol. 37, No. 5, pp 2486-2492, May 1997.
- [7] Pandey D, Yin X, Wang H, Su MY, Chen JH, Wu J, Zhang Y (2018) Automatic and fast segmentation of breast region-of-interest (ROI) and density in MRIs. *Heliyon*, 4: 1-30 <https://doi.org/10.1016/j.heliyon.2018.e01042>
- [8] Illan IA, Ramirez J, Gorriz JM (2018) Automated Detection and Segmentation of Nonmass-Enhancing Breast Tumors with Dynamic Contrast-Enhanced Magnetic Resonance Imaging. *Contrast Media Mol. Imaging* 2018:1-11 <https://doi.org/10.1155/2018/5308517>
- [9] Shokouhi SB, Fooladivanda A, Ahmadinejad N (2017) Computer-aided detection of breast lesions in DCE-MRI using region growing based on fuzzy C-means clustering and vesselness filter. *Eurasip J. Adv. Sig. Process.* 2017:1-11 <https://doi.org/10.1186/s13634-017-0476-x>
- [10] Marrone S, Piantadosi G, Fusco R, Petrillo A, Sansone M, Sansone C (2016) Breast segmentation using Fuzzy C-Means and anatomical priors in DCE-MRI. *Proc. Int. Conf. Pattern Recognition* 1472–1477 <https://doi.org/10.1109/ICPR.2016.7899845>
- [11] Waugh SA, Purdie CA, Jordan LB, Vinnicombe S, Lerski RA (2016) Magnetic resonance imaging texture analysis classification of primary breast cancer. *26: 322–330* <https://doi.org/10.1007/s00330-015-3845-6>



- [12] Tzalavra A, Dalakleidi K, Zacharaki EI, Tsiaparos N (2016) Comparison of Multi-resolution Analysis Patterns for Texture Classification of Breast Tumors Based On DCE-MRI. 7th Int. Workshop on Machine Learning in Medical Imaging (MICCAI): 296-304, https://doi.org/10.1007/978-3-319-47157-0_36
- [13] Honda E, Nakayama R, Koyama H, Yamashita A (2016) Computer-Aided Diagnosis Scheme for Distinguishing Between Benign and Malignant Masses in Breast DCE-MRI. *J. Digit. Imaging*, 29: 388–393 <https://doi.org/10.1007/s10278-015-9856-7>.
- [14] Antropova N, Huynh B, Giger M (2016) Predicting breast cancer malignancy on DCE-MRI data using pre-trained convolutional neural networks. *Med. Phys.*43: 3349–3350 <https://doi.org/10.1118/1.4955674>
- [15] Mahrooghy M, Ashraf AB (2015) Pharmacokinetic tumor heterogeneity as a prognostic biomarker for classifying breast cancer recurrence risk. *IEEE Trans. on Biomedical Eng.* 62: 1585-1594 <https://doi.org/10.1109/TBME.2015.2395812>.
- [16] Commons C, License A (2015) Automatic Segmentation in Breast Cancer Using Watershed Algorithm. *International Journal of Biomedical Engineering and Science (IJBES)*, 2: 1-6.
- [17] Yang Q, Li L, Zheng B (2015) A new quantitative image analysis method for improving breast cancer diagnosis using DCE-MRI examinations. *Medical Physics* 42:103-109 <https://doi.org/10.1118/1.4903280>.
- [18] Navaei-Lavasani S, Fathi-Kazerooni A, Saligheh-Rad H, Gity M (2015) Discrimination of Benign and Malignant Suspicious Breast Tumors Based on Semi-Quantitative DCE-MRI Parameters Employing Support Vector Machine. *Front. Biomed. Technol.* 2:87-92
- [19] Chaudhurya B, Zhou M, Goldgof DB, Hall LO (2015) Identifying metastatic breast tumors using textural kinetic features of a contrast based habitat in DCE-MRI. *Med. Imaging 2015 Comput. Diagnosis* 941415 <https://doi.org/10.1117/12.2081386>.
- [20] Hassanien AE, Mofteh H, Azar AT, Shoman M (2014) MRI breast cancer diagnosis hybrid approach using adaptive ant-based segmentation and multilayer perceptron neural networks classifier. *Appl. Soft Comput. J.* 14:62–71 <https://doi.org/10.1016/j.asoc.2013.08.011>
- [21] Song H, Zhang Q, Sun F, Wang J (2014) Breast tissue segmentation on MR images using KFCM with spatial constraints. *Proc. - 2014 IEEE Int. Conf. Granul. Comput. GrC* :254-258 <https://doi.org/10.1109/GRC.2014.6982845>



- [22] Al-faris AQ, Ngah UK, Ashidi N, Isa M, Shuaib IL (2014) Breast MRI Tumour Segmentation Using Modified Automatic Seeded Region Growing Based on Particle Swarm Optimization Image Clustering. *Soft Computing in Industrial Applications* 223: 49–60
- [23] Wang TC, Huang YH, Huang CS, Chen JH (2014) Computer-aided diagnosis of breast DCE-MRI using pharmacokinetic model and 3-D morphology analysis. *Magn. Reson. Imaging* 32: 197–205 <https://doi.org/10.1016/j.mri.2013.12.002>
- [24] Jayender J, Chikarmane S, Jolesz FA, Gombos E (2014) Automatic segmentation of invasive breast carcinomas from dynamic contrast-enhanced MRI using time series analysis. *J. Magn. Reson. Imaging* 40:467–475 <https://doi.org/10.1002/jmri.24394>
- [25] Cai H, Peng Y, Ou C, Chen M, Li L (2014) Diagnosis of breast masses from dynamic contrast-enhanced and diffusion-weighted MR: A machine learning approach. *PLoS One*, 9:873-887 <https://doi.org/10.1371/journal.pone.0087387>
- [26] Chen JH, Chen S, Chan S, Lin M, Su MY, Wang X (2013) Template-based automatic breast segmentation on MRI by excluding the chest region. *Med. Phys.* 40: 22301, <https://doi.org/10.1118/1.4828837>.
- [27] Yang Q, Li L, Zhang J, Shao G, Zhang C, Zheng B (2013) Computer-aided diagnosis of breast DCE-MRI images using bilateral asymmetry of contrast enhancement between two breasts. *J. Digit. Imaging*, 27: 152–160, <https://doi.org/10.1007/s10278-013-9617-4>
- [28] Wu S, Weinstein SP, Conant EF, Schnall MD, Kontos D (2013) Automated chest wall line detection for whole-breast segmentation in sagittal breast MR images. *Med. Phys.* 40: 042301 <https://doi.org/10.1118/1.4793255>.
- [29] Wang Y, Morrell G, Heibrun ME, Payne A, Parker DL (2013) 3D Multi-Parametric Breast MRI Segmentation Using Hierarchical Support Vector Machine with Coil Sensitivity Correction. *Acad. Radiol.* 20: 137–147 <https://doi.org/10.1016/j.acra.2012.08.016>.
- [30] Sathya DJ, Geetha K (2013) Experimental Investigation of Classification Algorithms for Predicting Lesion Type on Breast DCE-MR Images. *Int. J. Comput. Appl.* 82:1-8 <https://doi.org/10.5120/14101-2125>
- [31] Sathya DJ, Geetha K (2013) Mass classification in breast DCE-MR images using an artificial neural network trained via a bee colony optimization algorithm.



Science Asia, 39: 294–305 <https://doi.org/10.2306/scienceasia1513-1874.2013.39.294>

[32] Nagarajan MB, Huber MB, Schlossbauer T, Leinsinger G, Krol A, Wismüller A (2013) Classification of small lesions in dynamic breast MRI: Eliminating the need for precise lesion segmentation through spatio-temporal analysis of contrast enhancement. *Mach. Vis. Appl.* 24: 1371–1381 <https://doi.org/10.1007/s00138-012-0456-y>.

[33] McClymont D, Trakic A, Mehnert A, Crozier S, Kennedy D (2013) Fully automatic lesion segmentation in breast MRI using mean-shift and graph-cuts on a region adjacency graph. *J. Magn. Reson. Imaging*, 39: 795–804 <https://doi.org/10.1002/jmri.24229>

[34] Glaßer S, Niemann U, Preim B, Spiliopoulou M (2013) Can we distinguish between benign and malignant breast tumors in DCE-MRI by studying a tumor's most suspect region only? *Proc. Of 26th IEEE Int. Symp. Comput. Med. Syst.*: 77-82 <https://doi.org/10.1109/CBMS.2013.6627768>

[35] Wang L, Platel B, Ivanovskaya T, Harz M, Hahn HK (2012) Fully automatic breast segmentation in 3D breast MRI. *Proc. of Int. Symp. Biomed. Imaging* :1024–1027 <https://doi.org/10.1109/ISBI.2012.6235732>

[36] Nagarajan MB, Huber MB, Schlossbauer T, Leinsinger G, Krol A, Wismüller A (2012) Classification of Small Lesions in Breast MRI: Evaluating The Role of Dynamically Extracted Texture Features Through Feature Selection. *J. Med. Biol. Eng.*,33: 59–68 <https://doi.org/10.5405/jmbe.1183>

[37] Hassanien AE, Kim TH (2012) Breast cancer MRI diagnosis approach using support vector machine and pulse coupled neural networks. *J. Appl. Log.*, 10: 277–284, 2012d. <https://doi.org/10.1016/j.jal.2012.07.003>

[38] Fusco R, Sansone M, Petrillo A, Sansone C (2012) A multiple classifier system for classification of breast lesions using dynamic and morphological features in DCE-MRI. *Lect. Notes Comput. Sci.* 7626 LNCS: 684–692

[39] Vignati A, Giannini V, De Luca M, Voral L (2011) Performance of a fully automatic lesion detection system for breast DCE-MRI. *J. Magn. Reson. Imaging* 34:1341–1351, 2011 <https://doi.org/10.1002/jmri.22680>

[40] Kannan SR, Ramathilagam S, Devi R, Sathya A (2011) Robust kernel FCM in segmentation of breast medical images. *Expert Syst. Appl.* 38: 4382–4389 <https://doi.org/10.1016/j.eswa.2010.09.107>



- [41] Agner SC, Soman S, Libfeld E, McDonald M (2011) Textural kinetics: A novel dynamic contrast-enhanced (DCE)-MRI feature for breast lesion classification. *J. Digit. Imaging.* 24: 446–463, 2011 <https://doi.org/10.1007/s10278-010-9298-1>
- [42] Giannini V, Vignati A, Morra L, Persano D (2010) A fully automatic algorithm for segmentation of the breasts in DCE-MR images. *Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBC:* 3146–3149 <https://doi.org/10.1109/IEMBS.2010.5627191>
- [43] Lee SH, Kim JH, Cho N, Yang Z (2010) Multilevel analysis of spatiotemporal association features for differentiation of tumor enhancement patterns in breast DCE-MRI. *Med. Phys.* 37: 3940–3956, 2010. <https://doi.org/10.1118/1.3446799>
- [44] Dyck DV, Backer SD, Juntu J, Sijbers J, Rajan J (2010) Machine learning study of several classifiers trained with texture analysis features to differentiate benign from malignant soft-tissue tumors in T1-MRI images. *J. Magn. Reson. Imaging* 31: 680–689, 2010. <https://doi.org/10.1002/jmri.22095>
- [45] Newstead GM, Lan L, Giger ML, Li H, Jansen SA, Bhooshan N (2010) Cancerous Breast Lesions on Dynamic Contrast-enhanced MR Images: Computerized Characterization for Image-based Prognostic Markers. *Radiology*, 254 :680–690 <https://doi.org/10.1148/radiol.09090838>
- [46] Manuscript A, Levman J, Leung T, Causer P, Martel AL (2010) Resonance Breast Lesions by Support Vector Machines. 27: 688–696, <https://doi.org/10.1109/TMI.2008.916959>
- [47] Zheng Y, Englander S (2009) STEP: Spatiotemporal enhancement pattern for MR-based breast tumor diagnosis. *Med. Phys.* 36: 3192–3204 <https://doi.org/10.1118/1.3151811>
- [48] Newell D, Nie K, Chen JH, Hsu CC (2009) Selection of diagnostic features on MRI to differentiate between malignant and benign lesions using computer-aided diagnosis: Differences in lesions presenting as mass and non-mass-like enhancement. *Eur. Radiol.*, 20: 771–781, <https://doi.org/10.1007/s00330-009-1616-y>.
- [49] McLaren CE, Chen WP, Nie K, Su MY (2009) Prediction of Malignant Breast Lesions from MRI Features: A Comparison of Artificial Neural Network. *Acad Radiology* 16: 842–851, 2009 <https://doi.org/10.1016/j.acra.2009.01.029>
- [50] Lee SH, Kim JH, Park JS, Jung YS, Moon WK (2009) Characterizing time-intensity curves for spectral morphometric analysis of intratumoral enhancement patterns in breast DCE-MRI: Comparison between differentiation performance of



temporal model parameters based on DFT AND SVD. IEEE Int. Symp. Biomed. Imaging from Nano to Macro, ISBI 2009: 65–68
<https://doi.org/10.1109/ISBI.2009.5192984>

[51] Furman-Haran E, Eyal E, Kirshenbaum KJ, Kelcz F, Degani H, Badikhi D (2009) Principal component analysis of breast DCE-MRI adjusted with a model-based method. *J. Magn. Reson. Imaging* 30: 989–998 <https://doi.org/10.1002/jmri.21950>

[52] Agner SC, Xu J, Fatakdavala H, Ganesan S (2009) Segmentation and classification of triple negative breast cancers using DCE-MRI. *Proc. of 2009 IEEE Int. Symp. Biomed. Imaging from Nano to Macro, ISBI 2009*: 1227–1230
<https://doi.org/10.1109/ISBI.2009.5193283>

[53] Twellmann T, Romeny BT (2008) Computer-aided classification of lesions by means of their kinetic signatures in dynamic contrast-enhanced MR images. *Med. Imaging 2008 Comput. Diagnosis* 6915.

[54] Mayerhoefer ME, Breitsenseher M, Amann G, Dominkus M (2008) Are signal intensity and homogeneity useful parameters for distinguishing between benign and malignant soft tissue masses on MR images? *Magn. Reson. Imaging* 26: 1316–1322, 2008. <https://doi.org/10.1016/j.mri.2008.02.013>

[55] Lee SH, Kim JH, Park JS, Chang CM (2008) Computerized segmentation and classification of breast lesions using perfusion volume fractions in dynamic contrast-enhanced MRI. *Biomed. Eng. Informatics New Dev. Futur. Proc. 1st Int. Conf. Biomed. Eng. Informatics, BMEI 2*: 58–62, 2008.
<https://doi.org/10.1109/BMEI.2008.215>

[56] Ertaş G, Gülçür HÖ, Osman O, Uçan ON, Tunaci M, Dursun M (2008) Breast MR segmentation and lesion detection with cellular neural networks and 3D template matching. *Comput. Biol. Med.* 38: 116–126
<https://doi.org/10.1016/j.compbimed.2007.08.001>

[57] Woods BJ, Clymer BD, Kurc T, Heverhagen JT (2007) Malignant-lesion segmentation using 4D co-occurrence texture analysis applied to dynamic contrast-enhanced magnetic resonance breast image data. *J. Magn. Reson. Imaging*, 25: 495–501, 2007. <https://doi.org/10.1002/jmri.20837>

[58] Meinel LA, Stolpen AH, Berbaum KS, Fajardo LL, Reinhardt JM (2007) Breast MRI lesion classification: Improved performance of human readers with a backpropagation neural network computer-aided diagnosis (CAD) system. *J. Magn. Reson. Imaging* 25: 89–95 <https://doi.org/10.1002/jmri.20794>

- [59] Khazen M, Leach MO, Hawkes DJ, Tanner C, Kessar P (2006) Does Registration Improve the Performance of a Computer Aided Diagnosis System for Dynamic Contrast-Enhanced MR Mammography? 3rd IEEE Int. Symp. Biomed. Imaging Nano to Macro: 466–469, <https://doi.org/10.1109/ISBI.2006.1624954>
- [60] Leinsinger G, Schlossbauer T, Scherr M, Lange O, Reiser M, Wismüller A (2006) Cluster analysis of signal-intensity time course in dynamic breast MRI: Does unsupervised vector quantization help to evaluate small mammographic lesions? *Eur. Radiol.*, 16: 1138–1146, <https://doi.org/10.1007/s00330-005-0053-9>
- [61] Chen W, Giger ML, Bick U, Newstead GM (2006) Automatic identification and classification of characteristic kinetic curves of breast lesions on DCE-MRI. *Med. Phys.* 33: 2878–2887 <https://doi.org/10.1118/1.2210568>
- [62] Xiaohua C, Brady M, Lo JJ (2005) Simultaneous segmentation and registration of contrast-enhanced breast MRI. *Information Processing in Medical Imaging, LNCS 3565*: 31–59
- [63] Arbach L, Stolpen A, Reinhardt JM (2004) Classification of breast MRI lesions using a backpropagation neural network (BNN). *IEEE Int. Symp. Biomed. Imaging Nano to Macro (IEEE Cat No. 04EX821)*: 253–256 <https://doi.org/10.1109/ISBI.2004.1398522>
- [64] Vomweg TW, Buscema M, Kauczor HU, Teifke A (2003) Improved artificial neural networks in prediction of malignancy of lesions in contrast-enhanced MR-mammography. *Med. Phys.* 30: 2350–2359 <https://doi.org/10.1118/1.1600871>
- [65] Tzacheva AA, Najarian K, Brockway JP (2003) Breast cancer detection in gadolinium-enhanced MR images by static region descriptors and neural networks. *J. Magn. Reson. Imaging* 17: 337–342 <https://doi.org/10.1002/jmri.10259>
- [66] Lucht R, Delorme S, Brix G (2002) Neural network-based segmentation of dynamic MR mammographic images. *Magnetic Res. Imaging* 20: 147–154 [https://doi.org/10.1016/S0730-725X\(02\)00464-2](https://doi.org/10.1016/S0730-725X(02)00464-2)
- [67] Abdolmaleki P, Buadu LD, Naderimansh H (2001) Feature extraction and classification of breast cancer on dynamic magnetic resonance imaging using artificial neural network. *Cancer Lett.*, 171: 183–191. [https://doi.org/10.1016/s0304-3835\(01\)00508-0](https://doi.org/10.1016/s0304-3835(01)00508-0)
- [68] Vergnaghi D, Monti A, Setti E, Musumeci R (2001) A use of a neural network to evaluate contrast enhancement curves in breast magnetic resonance images. *J. Digit. Imaging*, 14:58-59 <https://doi.org/10.1007/bf03190297>.



- [69] Haralick RM, Dinstein I, and Shanmugam K, "Textural Features for Image Classification," *IEEE Trans. Syst. Man Cybern.*, vol. SMC-3, no. 6, pp. 610–621, 1973.
- [70] Fooladivanda A, Shokouhi SB, Ahmadinejad N, and Mosavi MR, "Automatic segmentation of breast and fibroglandular tissue in breast MRI using local adaptive thresholding," 2014 21st Iran. Conf. Biomed. Eng. ICBME 2014, no. Icbme, pp. 195–200, 2014.
- [71] Pratt WK, *Processing Digital Image Processing*, vol. 5, no. 11. 2001.
- [72] Renukalatha S and Suresh KV, "Automatic Roi Extraction in Noisy Medical Images," *ICTACT J. Image Video Process.*, vol. 7, no. 4, pp. 1505–1514, 2018.
- [73] Gonzalez R and Woods R, *Digital image processing*. 2014.
- [74] Gül S, Çetinel G, "Detection of Lesion Boundaries in Breast Magnetic Resonance Imaging with Otsu Thresholding and Fuzzy C-Means", 3rd International Conference on Advanced Technology & Sciences (ICAT), 2017.
- [75] Otsu N, "A threshold selection method from gray-level histograms," *IEEE Trans. Syst. Man. Cybern.*, vol. 9, no. 1, pp. 62–66, 1979.
- [76] Norouzi N, "Medical image segmentation methods, algorithms, and applications," *IETE Tech. Rev.*, vol. 31, no. 3, pp. 199–213, 2014.
- [77] Pham DL, Xu C, and Prince JL, "A survey of current methods in medical image segmentation," *Annu. Rev. Biomed. Eng.*, vol. 2, no. 315–337, pp. 315–337, 2000.
- [78] Maintz T, "Chapter 10. Segmentation," *Digit. Med. Image Process.*, 2005.
- [79] Deng H, Clausi DA, "Unsupervised image segmentation using a simple MRF model with a new implementation scheme". *Pattern Recognition*, 37: 2323-2335. <https://doi.org/10.1016/j.patcog.2004.04.015>, 2004.
- [80] Geman S, Geman D, "Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images", *IEEE Trans. Pattern Anal. Mach. Intell.* 6 (6) 721–741, 1984.
- [81] Kass M, Witkin A, Terzopoulos D, "Snakes: Active Contour Models", *International Journal of computer Visions*, Vol1. 4, pp. 321-331, 1987.
- [82] Gray SB, "Local Properties of Binary Images in Two Dimensions," *IEEE Trans. Comput.*, vol. C-20, no. 5, pp. 551–561, 1971.
- [83] Surendiran B, and Vadivel A, "Mammogram mass classification using various geometric shape and margin features for early detection of breast cancer," *Int. J. Med. Eng. Inform.*, vol. 4, no. 1, p. 36, 2012.



- [84] Yaşar H, and Ceylan M, Investigation of image representation and denoising performances of real and complex valued fast finite shearlet transform, Signal Processing and Communications Applications Conference (SIU), 2015 23th. IEEE, 2015.
- [85] Guo K, Gitta K, Demetrio L, Sparse multidimensional representations using anisotropic dilation and shear operators, International Conference on the Interaction between Wavelets and Splines, 189201, 2005.
- [86] Türkoğlu M and Hanbay D, "Plant recognition system based on extreme learning machine by using shearlet transform and new geometric features," *J. Fac. Eng. Archit. Gazi Univ.*, vol. 34, no. 4, pp. 2097–2112, 2019.
- [87] Zhou S, Shi J, Zhu J, Cai Y, and Wang R, "Shearlet-based texture feature extraction for classification of breast tumor in ultrasound image," *Biomed. Signal Process. Control*, vol. 8, no. 6, pp. 688–696, 2013.
- [88] Chen YW, Lin CJ, "Combining SVMs with Various Feature Selection Strategies Studies in Fuzziness and Soft Computing" 207: 315-324, 2006.
- [89] Evgeniou T, Pentil M, "Support vector machines: theory and applications", Machine Learning and Its Applications Advanced Lectures, 249-257, 2001.
- [90] Duda RO, Hart PE, Stark DG, "Pattern Classification", Second Edition, New York, USA, 2001.
- [91] Chunninghan P, Delany SJ, "k-Nearest neighbor classifiers" Technical Report UCD-CSI-2007-4, 2007.
- [92] Haykin S, "Neural Networks and Learning Machines", Upper Saddle River, New Jersey, 2009.
- [93] Bishop CM, "Pattern Recognition and Machine Learning", New York, USA, 2006.
- [94] Vaithinathan K, Parthiban L, "A Novel Texture Extraction Technique with T1 Weighted MRI for the Classification of Alzheimer's Disease", *Journal of Neuroscience Methods*, vol no 318, pp. 84-99, 2019.
- [95] Piantadosi G, Marrone S, Fusco R, Sansone M, Sansone C "Comprehensive computer-aided diagnosis for breast T1-weighted DCE-MRI through quantitative dynamical features and spatio-temporal local binary patterns.", *IET Comput. Vis.* 12: 1007–1017, 2018.

TÜBİTAK
PROJE ÖZET BİLGİ FORMU

Proje Yürütücüsü:	Dr. Öğr. Üyesi GÖKÇEN ÇETİNEL
Proje No:	118E201
Proje Başlığı:	Meme Manyetik Rezonans Görüntüleme (MRG) Lezyon Tespiti, Yalancı Pozitif ve Yalancı Negatif Bulguların Azaltılmasına Yönelik Yazılım Geliştirilmesi
Proje Türü:	3001 - Başlangıç AR-GE
Proje Süresi:	12
Araştırmacılar:	FULDEM MUTLU
Danışmanlar:	
Projenin Yürütüldüğü Kuruluş ve Adresi:	SAKARYA Ü.
Projenin Başlangıç ve Bitiş Tarihleri:	15/07/2018 - 15/10/2019
Onaylanan Bütçe:	61274.0
Harcanan Bütçe:	43711.7
Öz:	<p>ÖZET</p> <p>Projenin amacı, meme kanserinin teşhisinde yaygın olarak tercih edilen manyetik rezonans görüntüleme sistemi üzerinden alınan görüntüleri kullanarak yazılım tabanlı bir meme lezyon tespit ve sınıflandırma sistemi geliştirmektir. Geliştirilen sistem uzmanlar için yazılım tabanlı bir karar destek sistemi olarak düşünülebilir. Belirtilen amaca ulaşmak için sistemde beş temel adım gerçekleştirilmiştir. Bu adımlardan her biri çeşitli işaret işleme ve görüntü işleme yöntemleri içermektedir.</p> <p>Projede gerçekleştirilen beş temel adım sırasıyla veri tabanı oluşturulması, meme lezyonlarının tespit edilmesi, lezyon özelliklerinin çıkarılması, en etkili özelliklerin belirlenmesi ve karar adımlarıdır. Veri tabanı oluşturulması adımı uzman eşliğinde MRG cihazı ile yapılan çekimlerden en uygun görüntüler seçilmiştir. Ayrıca, görüntüde oluşabilecek bozunumları gidermek için filtre tabanlı bir ön işleme adımı uygulanmıştır. Daha sonra, meme lezyonlarının tespit edilmesi amacıyla iki aşamalı bir segmentasyon süreci uygulanmıştır. İlk aşama lezyon içerebilecek meme bölgesinin tespit edilmesi, ikinci aşama meme bölgesinden lezyonun bulunduğu bölgenin elde edilmesidir. Meme bölgesi tespitinde yerel adaptif eşikleme, bağlı bileşen analizi, yatay iz düşünüm ve maskeleyme teknikleri sırasıyla kullanılmıştır. Lezyon tespiti için Otsu, bölge büyütme, bulanık c-ortalama, k-ortalama, aktif sınırlar ve Markov rastgele alanlar yöntemleri görüntüleme uygulanmıştır. Lezyonlara ait özelliklerin çıkarılması adımı ise histogram, şekil, doku ve dönüşüm uzayı özellikleri hesaplanmıştır. Toplamda her bir lezyon için 108 özellik belirlenmiş ve özellik seçme adımı etkisi az olan özellikler Fisher skoru yöntemi ile özellik vektöründen atılmıştır. Projenin son adımı karar aşaması olan sınıflandırma adımıdır. Bu adımda k en yakın komşuluk, destek vektör makineleri, rastgele orman, naif Bayes teknikleri kullanılmıştır. Elde edilen sonuçlara göre proje kapsamında hazırlanan yazılım meme lezyonlarının tespitinde %91±0,06, iyi huylu kötü huylu lezyon ayırımında %90,36±0,069, lezyon alt gruplarının ayırımında ise %84,3±0,24 doğruluk sağlamıştır.</p>
Anahtar Kelimeler:	Meme kanseri, lezyon tespiti, segmentasyon, özellik çıkarma, özellik seçme, lezyon sınıflandırma
Fikri Ürün Bildirim Formu Sunuldu Mu?:	Evet