

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**MEDİKAL GÖRÜNTÜLERDE GELENEKSEL
YÖNTEMLERİN VE EVRİŞİMSEL SİNİR AĞLARININ
İÇERİK TABANLI OLARAK KARŞILAŞTIRILMASI**

YÜKSEK LİSANS TEZİ

Yusuf ÖZTÜRK

**Enstitü Anabilim Dalı : ELEKTRİK - ELEKTRONİK
MÜHENDİSLİĞİ**

Enstitü Bilim Dalı : ELEKTRONİK

Tez Danışmanı : Dr.Öğr.Üyesi Gökçen ÇETİNEL

Eylül 2019

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**MEDİKAL GÖRÜNTÜLERDE GELENEKSEL
YÖNTEMLERİN VE EVRİŞİMSEL SİNİR AĞLARININ
İÇERİK TABANLI OLARAK KARŞILAŞTIRILMASI**


YÜKSEK LİSANS TEZİ

Yusuf ÖZTÜRK

Enstitü Anabilim Dalı : ELEKTRİK - ELEKTRONİK
MÜHENDİSLİĞİ

Enstitü Bilim Dalı : ELEKTRONİK

Bu tez 11.09.2019 tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile kabul edilmiştir.


Dr.Öğr.Üyesi
Gökçen ÇETİNEL
Jüri Başkanı

Dr.Öğr.Üyesi
Özhan ÖZKAN
Üye


Dr.Öğr.Üyesi
Mustafa Zahid YILDIZ
Üye

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Yusuf ÖZTÜRK

11.09.2019

TEŞEKKÜR

Yüksek lisans eğitimim boyunca değerli bilgi ve deneyimleriyle bana yol gösteren, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında beni yönlendiren değerli danışman hocam Dr.Öğr.Üyesi Gökçen ÇETİNEL'e teşekkürlerimi sunarım.

Tezin hazırlık sürecinde sabrını eksik etmeden bana destek ve motivasyon sağlayan eşime ve aileme teşekkür ederim.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	iv
ŞEKİLLER LİSTESİ	v
TABLolar LİSTESİ	vii
ÖZET	viii
SUMMARY	ix
BÖLÜM 1.	
GİRİŞ	1
1.1. İçerik tabanlı görüntü erişim sistemlerinin genel yapısı	1
1.2. Medikal Görüntü Çeşitleri ve Özellikleri.....	2
1.3. Sayısal Görüntüler ve Tanımlayıcılar	4
1.4. Literatür Taraması	5
BÖLÜM 2.	
MATERYAL VE YÖNTEM	10
2.1. Veri tabanı	10
2.2. Sunulan CBIR Sisteminin Genel Yapısı	10
2.3. Ön işleme.....	11
2.4. Özellik çıkarma.....	14
2.4.1 Renk özelliklerinin çıkarılması.....	14
2.4.1.1 Renk momentleri.....	15
2.4.1.2 Renk dağılımları.....	16
2.4.1.3 Ortalama RGB değeri.....	20
2.4.2 Doku özelliklerinin çıkarılması.....	20
2.4.2.1 Gri seviye eş oluşturma matrisleri (GLCM).....	21

2.4.2.2 Gabor filtreleri.....	23
2.4.3 Şekil özelliklerinin çıkarılması.....	27
2.5. Benzerlik ölçümü.....	33
2.5.1 Kosinüs benzerlik yöntemi.....	33
2.5.2 Öklit benzerlik yöntemi	34
2.5.3 Manhattan benzerlik yöntemi	34
2.6. Sonuç görüntüleri ve sistem başarımı.....	35
 BÖLÜM 3.	
DERİN ÖĞRENME	37
3.1. Yapay sinir ağları	37
3.2. Derin öğrenme	40
3.3. Evrişimsel sinir ağları (Convolutional Neural Networks, CNN).....	40
3.4. Önerilen derin öğrenme modeli.....	47
3.5. Sistem başarımı.....	48
 BÖLÜM 4.	
TARTIŞMA VE SONUÇLAR	50
4.1. Renk özelliklerinin hesaplanması ve karşılaştırılması.....	50
4.2. Doku özelliklerinin hesaplanması ve karşılaştırılması.....	53
4.3. Şekil özelliklerinin hesaplanması ve karşılaştırılması.....	55
4.4. Benzerlik hesaplamalarının karşılaştırılması.....	59
4.5. Derin öğrenme yöntemi ile görüntü benzerliklerinin bulunması.....	60
4.6. Geleneksel Yöntem ve Evrişimsel Sinir Ağları performanslarının karşılaştırılması.....	61
KAYNAKLAR	63
ÖZGEÇMİŞ	66

SİMGELER VE KISALTMALAR LİSTESİ

AgBr	: Gümüş Bromür
CBIR	: Content Based Image Retrieval
CMY(K)	: Cyan-Magenta-Yellow-Key
CT	: Computed Tomography
GLCM	: Gray Level Co-occurrence Matrix
HMMD	: Hue-Max-Min-Diff
HSV	: Hue-Saturation-Value
MR	: Manyetik Rozenans
NGLDM	: Neighborhood Grey Level Different Matrix
NLM	: National Library of Medicine
RGB	: Red-Green-Blue

ŞEKİLLER LİSTESİ

Şekil 1.1. İçerik tabanlı görüntü erişim sistemi genel yapısı	1
Şekil 1.2. Medikal görüntü çeşitleri.....	3
Şekil 2.1. Sunulan CBIR sisteminin genel yapısı.....	11
Şekil 2.2. Gürültülü tomografi görüntü örneği.....	12
Şekil 2.3. Gürültü bileşeni olmayan tomografi görüntüsü örneği.....	13
Şekil 2.4. RGB Renk uzayı.....	15
Şekil 2.5. RGB renk uzayı ile oluşturulmuş bir görüntü ve histogram grafiği.....	16
Şekil 2.6. Renkli bir görüntüye ait histogram dağılımları.....	17
Şekil 2.7. Koyu renk tonlamalı bir görüntü ve histogram grafiği.....	17
Şekil 2.8. Açık renk tonlamalı bir görüntü ve histogram grafiği.....	17
Şekil 2.9. Karşıt renk tonlamalarının bir arada olduğu bir görüntü.....	18
Şekil 2.10. Benzer renk tonlamalarının bir arada olduğu bir görüntü.....	18
Şekil 2.11. GLCM matrisi açılı yönleri ve ilgili pikseller.....	21
Şekil 2.12. Örnek bir görüntü için farklı yönlerdeki GLCM matrisleri	22
Şekil 2.13. Farklı açılı ve frekans bileşenleri ile oluşturulmuş Gabor filtreleri.....	25
Şekil 2.14. Eksenel şekil tanımlaması tekniği.....	28
Şekil 2.15. Dışbükey gövde gösterimi.....	29
Şekil 2.16. Sınır bilgilerine ait en uzun giriş.....	29
Şekil 2.17. Sınır bilgilerinin sığabileceği en küçük dörtkenar.....	30
Şekil 2.18. Sınır bilgileri üzerinden çizilen daire.....	31
Şekil 2.19. Sınır bilgisi noktalarının ağırlık merkezi.....	31
Şekil 2.20. Izgara tabanlı şekil gösterimi.....	32
Şekil 2.21. Izgara yöntemi ile hücrelere ayrılmış görüntü ve matris formu.....	32
Şekil 3.1. Biyolojik nöronun yapısı.....	37
Şekil 3.2. Biyolojik nöronun matematiksel modeli.....	38
Şekil 3.3. Aktivasyon fonksiyonlarının grafik gösterimleri.....	39

Şekil 3.4. Klasik sinir ağı modeli.....	39
Şekil 3.5. Evrişimsel sinir ağı 3 boyutlu katman yapısı.....	41
Şekil 3.6. Evrişimsel sinir ağı katmanları.....	41
Şekil 3.7. Evrişimsel sinir ağı için girdi örneği.....	42
Şekil 3.8. Görüntüye uygulanan filtre ve matematiksel işlem adımları.....	43
Şekil 3.9. Nöron çıkışlarına uygulanan işlemler.....	43
Şekil 3.10. Nöron çıkışına uygulanan ReLu fonksiyonu ve çıkış matrisi.....	44
Şekil 3.11. Max Pool havuzlama katmanından geçirilen bir görüntü.....	44
Şekil 3.12. Max Pool havuz katmanından geçirilen bir görüntünün renk kanalı...	45
Şekil 3.13. Son evrişim katmanında uygulanan düzleştirme işlemi.....	45
Şekil 3.14. Evrişimli sinir ağı işlem adımları.....	46
Şekil 3.15. Derin öğrenme modelinin öğrenme ve doğrulama oranlarının grafiği..	48
Şekil 3.16. Derin öğrenme modelinin kayıp oranlarının grafiği.....	49
Şekil 4.1. Gri tonlamalı tomografi görüntüsü ve şekil sınır bilgileri.....	56
Şekil 4.2. Eksenel tarama yöntemi ile şekil dış sınırlarının bulunması.....	56
Şekil 4.3. Şekil alanının ve sınırlarının ızgara yöntemiyle hücrelere ayrılması.....	58
Şekil 4.4. Izgara yöntemi ile şekil alanı ve sınırlarını matrislerinin oluşturulması.	58
Şekil 4.5. Veritabanındaki özniteliklerin sınıflandırılması.....	60

TABLolar LİSTESİ

Tablo 2.1. Farklı medikal görüntüler için hesaplanan Cosinüs, Öklit ve Manhattan benzerliklerinin sıralanması.....	35
Tablo 2.1. Farklı görüntü kategorilerinde yapılan sorgulamalarda hesaplanan hassasiyet ve geri getirme oranları.....	36
Tablo 3.1. Önerilen ağ modelinin katman yapısı.....	47
Tablo 3.2. Derin öğrenme yöntemi ile yapılan sorgular için elde edilen doğruluk oranları.....	49
Tablo 4.1. Farklı renk tonlarındaki görüntülere ait hesaplanan renk moment bileşenleri.....	51
Tablo 4.2. Benzer gri tonlamalı medikal görüntülerin renk moment hesaplamaları	51
Tablo 4.3. Farklı renk tonlamalarındaki görüntülere ait renk dağılımı bileşenlerinin değerleri.....	52
Tablo 4.4. Benzer görüntülere ait renk dağılımı bileşenlerinin değerleri.....	52
Tablo 4.5. Farklı görüntülere ait ortalama renk uzayı değerleri.....	53
Tablo 4.6. Farklı dokulara ait GLCM bileşenleri.....	54
Tablo 4.7. Farklı medikal görüntülere ait GLCM bileşenleri.....	54
Tablo 4.8. Benzer medikal görüntülerin GLCM matris bileşenleri.....	54
Tablo 4.9. Farklı medikal görüntü tipleri için gabor filtre konvolüsyonu sonucunda bulunan enerji değerleri.....	55
Tablo 4.10. Görüntünün şekil sınır bilgilerinden elde edilen parametreler.....	57
Tablo 4.11. Özellik benzerliği hesaplama süreleri.....	59
Tablo 4.12. Farklı görüntülere ait hesaplanan benzerlik değerleri.....	60
Tablo 4.13. Derin öğrenme yöntemi ile elde edilen tahmin bilgileri.....	61
Tablo 4.14. Geleneksel yöntem ve Evrimsel sinir ağı ile elde edilen sonuçların karşılaştırılması	62

ÖZET

Anahtar kelimeler: İçerik Tabanlı Görüntü Erişimi, Feature Extraction, Derin Öğrenme, Evrimsel Sinir Ağları

Son yıllarda bilgisayar teknolojilerinin gelişimi ve internet kullanımının hızla artmasıyla birlikte görüntü erişim sistemleri önem kazanmıştır. Bu tezde görüntü erişim hızını arttırmayı ve depolama alanı gereksinimini azaltmayı amaçlayan içerik tabanlı görüntü erişim sistemleri ele alınmıştır. İçerik tabanlı görüntü erişimi (Content based Image Retrieval, CBIR) sağlık da dahil olmak üzere birçok alanda yaygın olarak kullanılmaktadır.

Günümüzde birçok hastalığın teşhisinde medikal görüntüleme sistemleri yaygın olarak kullanılmaktadır. Ultrason, tomografi, röntgen, manyetik rozenans görüntüleme gibi farklı modeliteler uzmanlar tarafından yaygın olarak tercih edilmektedir. Bu modeliteler farklı çalışma prensiplerine sahip olsalar da farklı açılardan hastanın belirlenen bölgelerine ait görüntüler elde etme esasına dayalıdır. Bunun sonucu olarak medikal görüntü sayısı her geçen gün artmaktadır. Medikal görüntülere ihtiyaç duyulduğunda hızlı ve doğru bir şekilde erişebilmek için CBIR sistemleri kullanılabilir.

Sunulan tezde medikal görüntüler için iki farklı yöntem ile CBIR sistemi tasarlanması amaçlanmıştır. Birinci tasarımda medikal görüntüler için renk, doku ve şekil içeriklerini temsil eden öznitelikler çıkarılmıştır. Görüntüler arasındaki benzerliği ölçmek amacıyla basit metrikler vasıtasıyla öznitelikler karşılaştırılmıştır. İkinci tasarımda ise öznitelik çıkarma yerine derin öğrenme tekniklerine dayalı bir yol izlenmiştir. Her iki tasarım ile elde edilen sonuçlar tezde sunularak yorumlanmıştır. Önerilen sistem sayesinde sağlık birimlerinde çalışan personel ve doktorların hastalık teşhisinden önce benzer vakaları medikal görüntüler üzerinden hızlı bir şekilde incelemeleri kolaylaştırılmış olacaktır.

CONTENT BASED COMPARISON OF TRADITIONAL METHODS AND CONVOLUTIONAL NEURAL NETWORKS IN MEDICAL IMAGES

SUMMARY

Keywords: Content Based Image Retrieval, Feature extraction, Deep Learning, Convolutional Neural Networks.

In recent years, with the development of computer technologies and the rapid increase in internet usage, image retrieval systems have gained importance. In this thesis, content based image retrieval systems which aim to increase the speed of image access and decrease the storage space requirement are examined. Content-based image retrieval systems (CBIR) are widely used in many areas, including health.

Today, medical imaging systems are widely used in the diagnosis of many diseases. Different models such as ultrasound, tomography, x-ray, magnetic resonance imaging are widely preferred by experts. Although these models have different working principles, they are based on the acquisition of images of identified areas of the patient from different angles. As a result, the number of medical images increases day by day. CBIR systems can be used to access medical images quickly and accurately when needed.


In this thesis, it is aimed to design CBIR system with two different methods for medical images. In the first design, color, texture and shape features of medical images were extracted. Features were compared using simple metrics to measure similarity between images. In the second design, instead of feature extraction, deep learning techniques was followed. The results of both designs were presented and reviewed in the thesis. It will be easier for staff and doctors working in health units to quickly examine similar cases before medical diagnosis with the proposed system.

BÖLÜM 1. GİRİŞ

Bu bölümde içerik tabanlı görüntü erişim sisteminin genel yapısından bahsedilerek sistemin daha iyi anlaşılabilmesi için bazı kavramlar açıklanmıştır. Ayrıca tezin katkısını ve yerini belirlemek amacıyla yapılan literatür araştırması sunulmuştur.

1.1. İçerik Tabanlı Görüntü Erişim Sistemlerinin Genel Yapısı

İçerik tabanlı görüntü erişim sistemleri (Content Based Image Retrieval-CBIR), sorgu görüntüsünün tamamının yada görüntü içindeki nesnelerin görsel özelliklerine göre incelenerek benzer görüntülerin araştırılması esasına dayanır. Standart bir içerik tabanlı görüntü erişim sisteminde sorgu görüntüsü ilk olarak görsel açıdan incelenerek ayırt edici özellikleri tespit edilir. Daha sonra belirlenen ayırt edici özelliklere sahip olan diğer görüntüler veri tabanından geri getirilerek kullanıcıya sunulur. Şekil 1.1.'de standart içerik tabanlı görüntü erişim sistemlerinin genel yapısı verilmiştir. Ayırt edici özellik olarak görüntü içindeki nesnelerin şekilleri, görüntüyü oluşturan piksellerin renk değerleri ve sürekli tekrarlanan pikseller verilebilir.



Şekil 1.1. İçerik tabanlı görüntü erişim sistemi genel yapısı

İçerik tabanlı görüntü erişim sistemleri güvenlik, sağlık, ticaret ve internet ortamı olmak üzere birçok alanda kullanılmaktadır. Güvenlik birimleri şüpheli kişilerin yüzlerini tespit etme, doktorlar hastalık teşhisinden önce benzer vakaları inceleme, ticari firmalar ise ürünleri ile ilgili benzer tasarımları görme amacıyla içerik tabanlı görüntü erişim sistemlerinden yararlanabilmektedirler. İçerik tabanlı görüntü erişim sistemlerinin en büyük kullanım alanlarından biri de internet ortamındaki benzer görüntülerin bulunmasıdır. Günümüzde çok sayıda içerik tabanlı görüntü erişim sistemi mevcuttur ve birçok internet arama motoru bu özelliği kullanmaktadır. Bu tezde medikal görüntülere erişim amacıyla kullanılan CBIR sistemleri ele alınmıştır.


1.2. Medikal Görüntü Çeşitleri ve Özellikleri

Medikal görüntüler hasta vücut bütünlüğünü bozmadan vücut içindeki değişiklikler, hastalıklı dokular veya hasar hakkında bilgi edinebilmemizi sağlarlar. Kanseri, beyin-omurilik sistemi, kas-iskelet sistemi, damar- dolaşım sistemi gibi birçok alanda hastalıkların teşhisinde sıklıkla medikal görüntülere başvurulmaktadır. Medikal görüntüleme tekniklerinde 19. yüzyılın başlarından itibaren X ışınları kullanılmaya başlanmış, ilerleyen yıllarda elektromanyetik ve akustik teknolojilerin gelişmesiyle birlikte görüntüleme yöntemleri çeşitlilik kazanmıştır. Son yıllarda nükleer tıp adı altında yeni görüntüleme teknikleri de geliştirilmiştir. Tüm bu yöntemlerde ışınlar ve radyo frekansları kullanıldığı için bu alanda yapılan çalışmalar Radyoloji bilim dalı altında toplanmıştır.

Medikal görüntüler, biyolojik yapıdan geçen radyasyon alanının zaman ve uzaydaki değişiminin belirlenmesi ve hesaplanması sonucu oluşturulurlar. Medikal görüntülemede ilk kullanılan yöntem röntgendir. Röntgen tekniğinde X ışınları hasta vücudundan geçirilir ve yayınım yapan ışık parçacıklarının röntgen filmine aktarılması ile görüntü elde edilir. Röntgen filmi, üzerine AgBr emülsiyonu sürülmüş ince ve şeffaf yapıda plastik bir malzemedir. Bu yöntemde görüntüler sayısal değildir ve röntgen filmi üzerindedir. Röntgen filmi üzerine düşürülen X ışınları AgBr moleküllerindeki bağların gevşemesini sağlayarak siyah ve beyaz görüntünün oluşmasını sağlarlar. Bu görüntüler sadece gri tonlamalıdır. Bilgisayarlı röntgen

teknolojisinin gelişmesiyle birlikte röntgen görüntülerinin sayısal olarak üretilmesi ve saklanabilmesi mümkün olmuştur.

Bilgisayarlı tomografi sayısal röntgen görüntülerinin oluşturulmaya başlamasından sonra geliştirilmiştir. Bilgisayarlı tomografide çok yüksek hızlı X ışınları kullanılarak hastalıklı bölgenin çok sayıda kesitsel (iki boyutlu) görüntüsü elde edilir. Bu kesitsel görüntüler bilgisayar yardımıyla üç boyutlu görüntüye dönüştürülebilirler. Bilgisayarlı tomografide görüntüler bilgisayar ortamında oluşturulduğu için reklendirilebilirler.



Şekil 1.2. Medikal görüntü çeşitleri, a) Ultrason, b) MR, c) Pataloji, d) X-Ray (Kaggle Dataset Archive - NIH National Library of Medicine)

Manyetik rezonans görüntüleme yöntemi protonların manyetik alan altındaki titreşimlerinden yola çıkılarak geliştirilmiştir. Bu yöntemde manyetik alan, radyo frekansları ve insan vücudunda bulunan su molekülleri etkileşime geçirilir. Vücuttaki su moleküllerindeki değişiklikler bilgisayar vasıtası ile görüntüye dönüştürülür. Manyetik rezonans çoğunlukla insan vücudundaki yumuşak dokuların görüntülenmesinde kullanılmaktadır.

Ultrasonografi, vücuda çok yüksek frekanslı ses dalgaları göndererek farklı doku yüzeylerinden gelen yansımaları saptama esasına dayanan bir görüntüleme yöntemidir. Yansıyan ses dalgalarının her biri ufak bir veri meydana getirir ve bu veriler bir araya geldiğinde elektronik görüntüyü oluşturur. Ultrasonografi genellikle gerçek zamanlı görüntüleme amacıyla kullanılmaktadır. Şekil 1.2.'de farklı teknikler ile elde edilmiş medikal görüntü çeşitleri verilmiştir.

Günümüzde medikal görüntülerin tamamı sayısal olarak oluşturulabilmektedir. Görüntülerin sayısal olarak elde edilmesi; verimli bir şekilde depolama, bilgisayar ile işlenebilme ve hızlı erişim sağlanması konularında kolaylıklar sağlamaktadır.

1.3. Sayısal Görüntüler ve Tanımlayıcılar

Sayısal görüntü, resimlerin çeşitli yöntemlerle bilgisayar ortamında saklanabilecek hale dönüştürülmeleri ile oluşur. Sayısal bir görüntü bir araya geldiklerinde ana resmi oluşturacak renk parçacıklarından meydana gelir. Bu parçacıkların her birine piksel adı verilir. Bilgisayar ortamında 8, 16, 24, 32 bitlik sayısal değerler olarak saklanan pikseller, resimdeki konumunun renk değerini sayısal olarak içerirler.

Görüntü erişim sistemlerinde görüntüye ait özgün parametrelerin bulunması için görüntü öznitelikleri kullanılır. Görüntü özniteliklerinin kullanılmasındaki temel amaç mevcut büyük veri kümesinden az miktarda ve özgün parametrelerin elde edilmesidir. Bu sayede hem hesaplama yükü hem de depolama için gereken alan azaltılmış olur.

Sayısal bir görüntüye erişmek için metinsel tanımlayıcılar ya da görsel tanımlayıcılar kullanılabilir. Metinsel tanımlayıcılar görüntünün belirgin özelliklerinin yazı ile ifade edilmesini sağlar. Örneğin, “sağ akciğer, kötü huylu lezyon içeren bir manyetik rozenans görüntüsü” tanımı yapılabilir. Metinsel tanımlayıcıların belirli kısıtlamaları vardır. Örneğin bir parmak izi resminin özneteliğini kelimeler ile ifade etmemiz mümkün değildir. Ayrıca tanımlayıcıların kelimeler ile ifade edilmesi dil problemlerini de beraberinde getirmektedir. Yapılan çalışmalarda metinsel tanımlayıcıların genellikle tek dil ile yapıldığı ve bu durumun farklı dil ile yapılan sorgulamalarda problem oluşturacağı belirtilmiştir [1].

Görsel tanımlayıcılar, diğer bir ifadeyle görsel tabanlı öznitelikler bir görüntünün tümünden ya da küçük bir piksel grubundan elde edilebilirler. Küçük bir piksel grubundan ilgili görüntüye ait özniteliklerin çıkarılabileceği önceki çalışmalarda gösterilmiştir [2]. Görsel tabanlı öznitelik çıkarımı düşük seviye ve yüksek seviye

olarak iki alt başlık altında gruplandırılır. Aritmetik işlemler ile hesaplanan kelime ve piksel tabanlı öznitelikler düşük seviyeli, evrimsel sinir ağları (Convolution Neural Network-CNNs) veya yapay sinir ağları (Artificial Neural Network-ANNs) gibi yöntemler ile hesaplanan öznitelikler yüksek seviyeli olarak gruplandırılmış ve farklılıkları yapılan çalışmalarda belirtilmiştir [3]. Görsel tanımlamada metinsel tanımlamada olduğu gibi kısıtlamalar bulunmamaktadır ve ayırt edici sayısal değişkenler olarak kullanılabilirler.

1.4. Literatür Taraması

CBIR sistemleri sayısal görüntü verilerinin çoğalması ve saklanabilir olmaları gereksiniminden dolayı önemli bir araştırma konusu olmuştur. Bilgisayarlı hesaplama tekniklerinin her geçen gün yenilikler getirmesi bu alanda yapılan çalışmaların hızla gelişmesine ve iyileşmesine olanak tanımaktadır.

Görüntü erişim sistemlerinden beklenen, geri getirme doğruluğunun yüksek olması ve daha az hesap yükü gereksinimine ihtiyaç duymasıdır. Bu kriterlerin iyileştirilmesi için donanımsal ve yazılımsal geliştirme çalışmaları devam etmektedir. Herkes tarafından ulaşılabilir çözümlerin yaygınlaşması için yazılımsal geliştirme çalışmaları yoğunlaşmıştır.

CBIR sistemlerinin ilk örneklerinde anahtar kelime tabanlı öznitelikler kullanılmıştır. Bu çalışmalarda arama yapan kişilerin farklı olmasından dolayı arama kelimelerinde standardın sağlanamayacağı ve aynı sorgu görüntüsü için farklı arama kelimelerinin kullanılabileceği belirtilmiştir [4]. Kelime tabanlı öznitelik çıkarımında parametrelerin oluşturulması kişilerden ve dil faktöründen bağımsız olmadığı için doğru sonuçların elde edilme olasılığı düşüktür. Sonraki çalışmalarda çoğunlukla görüntülerin renk, doku ve şekil özellikleri kullanılmıştır. Bu üç özelliğin kullanım oranlarının çok yüksek olması görüntü erişim sistemlerinde geleneksel yöntemler olarak kabul edilmelerini sağlamıştır.

Renk bilgisi görüntünün çözünürlüğünden bağımsız bir tanımlayıcı özellik olduğundan dolayı görüntü erişim sistemlerinde verimli bir şekilde kullanılmaktadır. Görüntüye ait renk uzayı ortalama değerleri büyük veri tabanındaki görüntülerin erken aşamada filtrelenmesi için kullanılabilirler. Ortalama renk değerlerinin tek başına ayırt edici özellik olarak kullanılmalarının yeterli olmayacağı ve farklı öznitelikler ile birlikte kullanılmamaları durumunda başarılı sonuçlar elde edilemeyeceği yapılan çalışmalarda belirtilmiştir [4]. İçerik tabanlı görüntü erişim sistemlerinde görüntüdeki nesnelerin yön, şekil ve konumları önemlidir. Renk dağılımlarını gösteren histogram eşitlikleri görüntü içindeki nesnelerin yönlerinden, şekillerinden ve konumlarından bağımsız olduklarından dolayı öznitelik olarak kullanılabilirler. Histogram eşitliklerinin büyük veritabanlarında ayırım yapabildikleri, farklı modeller ile kıyaslandığında %90 başarımlı oranın yakaladığı ve daima en iyi iki model eşleşmesinden biri olduğu görülmüştür [5]. Görüntünün arka planından, yönünden ve çözünürlüğünden bağımsız olarak hesaplanabilen renk momentleri de görüntü elde etme yöntemlerinde sıklıkla kullanılmıştır. Renk momentlerinin ayırt edicilik performansı mevcut diğer renk öznitelikleri ile karşılaştırılmış ve histogram eşitliğine göre daha iyi ayırt edici hassasiyet sonuçları verdiği görülmüştür [6].

CBIR sistemlerinde yaygın olarak kullanılan bir diğer öznitelik doku bilgisidir. Doku bilgisi arka planda sürekli olarak tekrarlanan benzer görüntü öbekleri hakkında bilgi edinilmesini sağlar. Doku bilgisinin kullanılmaya başlandığı ilk zamanlarda birinci ve ikinci derece istatistiksel hesaplamalar içeren yöntemler kullanılmıştır. İlerleyen yıllarda çeşitli doku özelliklerinin birlikte ortaya çıkma olasılıklarının hesaplanması için mekansal alan gri seviye birlikte oluşum matrisi (Spatial field Gray Level Co-occurrence Matrix, SDCM), komşu gri seviye bağımlılık matrisleri (Neighboring Gray Level Dependence Matrix, NGLDM) ve gri seviye eş oluşum matrisleri (Gray Level Co-occurrence Matrix, GLCM) kullanılmaya başlanmış ve ortalama %84,6 oranında doğru sınıflandırma sağlanmıştır [7]. Çeşitli araştırmalarda, görüntü üzerindeki belirli periyotlar ile tekrarlanan benzerliklerin saptanabilmesini sağlayan Gabor filtrelerinin öznitelik bulmada kullanılması farklı bir yaklaşım olarak

önerilmiştir. Diğer doku özellikleri ile yapılan karşılaştırmalarda, Gabor filtreleri ile elde edilen özniteliklerin en iyi doku doğruluğunu sağladığı görülmüştür [8].

Görüntü özneliği olarak kullanılan bir diğer özellik şekil bilgileridir. İki boyutlu görüntülerin sınır bilgileri üzerinden hesaplanabilen şekil öznitelikleri CBIR sistemlerinde yoğunlukla kullanılmıştır. Şekil bilgileri görüntü üzerindeki nesnelerin sınır bilgilerinin bulunması ve bu bilgiler üzerinde yapılan hesaplamalar sonucu elde edilirler. Literatürde çeşitli şekil tanımlayıcıları bulunmaktadır. Bu tanımlayıcılar genel olarak çevre tabanlı ve bölge tabanlı şekil tanımlayıcıları olmak üzere iki gruba ayrılır. Çevre tabanlı şekil tanımlayıcıları görüntü içindeki nesnelerin yalnızca sınır bilgileri üzerinden hesaplanır. Bölge tabanlı teknikte ise şekil bölgesindeki tüm piksel bilgileri kullanılarak hesaplama yapılır. Çevre tabanlı şekil tanımlayıcısı olarak tek boyutlu Fourier tanımlayıcıları, dalgacık tanımlayıcıları, eğrilik ölçeği alanları ve şekil imzaları örnek olarak verilebilir. Çevre tabanlı şekil tanımlayıcılarının yalnızca sınır bilgilerinden yararlandıkları için iç mekan şekillerini yakalayamayacakları, sınır bilgisinin bulunmadığı ayrık görüntülerde başarılı olamayacakları ve kullanımlarının sınırlı olduğu önceki çalışmalarda açıklanmıştır [9]. Bölge tabanlı yöntemler, şekli tanımlamak için moment tanımlayıcılarını kullanırlar. Bölge tabanlı şekil tanımlayıcısı olarak geometrik anlar, Legendre momentleri, Zernike momentleri ve sözde Zernike momentleri verilebilir. Zernike momentlerinin genel performans açısından diğer moment yöntemlerinden daha iyi performans gösterdiği gösterilmiştir [10]. İlerleyen yıllarda mevcut şekil bulma tekniklerinin dezavantajlarının üstesinden gelmek için genel Fourier tanımlayıcıları önerilmiştir. Genel Fourier tanımlayıcılarının geri getirme doğruluğu, düşük hesaplama karmaşıklığı ve performans gibi gereksinimlerin tümünü karşıladığı gösterilmiştir [11]. Önerilen yeni çalışmada kutup şekli görüntüsüne 2 boyutlu Fourier dönüşümü uygulanmış ve elde edilen test sonuçlarının tek boyutlu Fourier dönüşümü ve MPEG-7 şekil tanımlayıcılarını geride bıraktığı görülmüştür. Görüntüye ait geometrik şekil özellikleri de büyük farklılıkları ayırt etmek için kullanılabilirler. Geometrik şekil özellikleri olarak ağırlık merkezi, karesellik, dairesellik oranı, maksimum sınır dikdörtgeni, dışbükeylik ve giriş uzunlukları örnek verilebilir. Basit şekil tanımlayıcılarının da kullanıldığı bir çalışmada geometrik şekil

özellikleri, moment yaklaşımları, şekil imzaları ve ölçek uzayı yöntemlerinin üstün ve zayıf yönleri karşılaştırılmıştır [12]. Yapılan çalışmada uygulanan yöntemler işlem karmaşıklığına göre sınıflandırılmış ve tercih edilecek yöntem seçimini kolaylaştırmak için tablo oluşturulmuştur.

Son yıllarda derin sinir ağı tekniğinin görüntü tanıma alanında kullanılması ile başarılı sonuçların elde edildiği görülmüştür. 1998 yılında el yazısı harflerini tanımak için evrişimsel sinir ağı algoritması önerilmiş ve çok başarılı bir algoritma olduğu kanıtlanmıştır [13]. 2006 yılında öğrenme verilerinin boyutsallığını azaltmak için kodlayıcı yöntem geliştirilmiş ve önceki çalışmalarda %1.6 olan hata oranı %1.2 seviyelerine düşürülmüştür [14]. Bu şekilde düşük boyutlu kodlar ile çok daha iyi çalışan makine öğrenme sistemleri geliştirilebilir hale gelmiştir. İlerleyen yıllarda araştırmacıları teşvik etmek için yarışmalar düzenlenmeye başlanmıştır. 2012 yılında düzenlenen ImageNet Large-Scale Visual Recognition Challenge (ILSVRC) yarışmasında ImageNet görüntü veri tabanı üzerinden eğitilen sinir ağı ile % 15.3 hata oranı başarıyla yakalanmıştır [15]. Bu çalışmada rektifiye edilmiş doğrusal birimler (ReLU-Rectified Linear Unit) kullanılarak öğrenme süreleri kısaltılmış ve büyük veri kümelerinin kullanılması kolaylaştırılmıştır. 2013 yılında eğitilmiş ağ tarafından oluşturulan veriler görüntü etiketleri ve softmax sınıflandırıcıları ile birleştirilerek doğrudan görüntü tanımlaması yapabilen bir sistem geliştirilmiştir [16]. 2015 yılında medikal görüntü alanında ön eğitimli olarak yapılan ilk çalışmada sağlıklı ve anormal göğüs röntgeni arasında yapılan sınıflandırma çalışmalarında 0.79 doğruluk oranı yakalanmıştır [17]. Depolama alanının azaltılması amacıyla yapılan bir çalışmada evrişimsel sinir ağları ile elde edilen öznitelikler ikili sayı sistemine çevrilerek saklanmış ve depolama alanından 1/32 oranında kazanım sağlanmıştır [18]. 2016 yılında iki farklı görüntü arasındaki benzerlik oranının tespit edilmesi için siyam ağları ve bölge önerme ağlarının birlikte kullanıldığı yeni bir yöntem önerilmiş, karmaşık ön işleme ve ilave işlem gereksinimini ortadan kaldıran yeni bir yaklaşım olarak başarıyla gerçekleştirilmiştir [19]. 2017 yılında tüberkiloz görüntüleri üzerinde yapılan çalışmada evrişimli sinir ağları ile öznitelikler çıkarılmış, elde edilen öznitelikler sınıflandırma amacıyla destek vektör makinelerinin eğitilmesinde kullanılmıştır [20]. Çalışmada farklı görüntü veri

tabanları ile karşılaştırmalar yapılarak %92 doğruluk oranı yakalanmıştır. Son yıllarda evrimsel sinir ağları tanımlayıcılarını geliştirmek amacıyla yeniden eğitime yaklaşımı öne sürülmüştür. 2018 yılında yapılan yeniden eğitmeli bir çalışmada, ağ üzerinde bilgi bulunup bulunmamasına bağlı olarak kullanıcılara yeniden eğitime önerisi sunan bir sistem önerilmiş ve %83 doğruluk oranı yakalanarak benzer diğer çalışmalara göre başarılı olduğu gösterilmiştir [21].

İnsanların görme ve karar verme yetenekleri çok kuvvetlidir. Herhangi bir medikal görüntünün incelenerek hastalıkların teşhis edilmesi inceleme yapan kişinin bilgi birikimi ve tecrübesine göre farklılık gösterebilir. Bu şekilde oluşabilecek farklılıkların azaltılması için tüm dünyada, nicel ölçütlere dayalı tanı sistemlerinin geliştirilmesi üzerinde çalışılmaktadır. Bu sistemler doktorlara hastalığın tanısı konusunda yardımcı olmayı amaçlamaktadır.

Bu tezde röntgen, ultrason, magnetik rezonans, tomografi gibi farklı görüntüleme teknikleri ile elde edilmiş medikal görüntüler için CBIR sistemi geliştirilmiştir. Geliştirilen sistemin amacı, oldukça fazla sayıda olan ve sağlık birimlerinde depolanan medikal görüntülere hızlı bir şekilde erişim sağlamak ve bu görüntüleri temel özellikleri ile temsil ederek depolama alanını küçültebilmektir. Çalışma boyunca kullanılan farklı öznitelik bulma yöntemleri ile doğru görüntü bulma performansının iyileştirilmesi hedeflenmiştir. Önerilen sistem sayesinde sağlık birimlerinde çalışan uzmanların hastalık teşhisinden önce benzer vakaları medikal görüntüler üzerinden hızlı bir şekilde incelemeleri kolaylaştırılmış olacaktır.

BÖLÜM 2. MATERYAL VE YÖNTEM

Bu bölümde tezde kullanılan veri tabanından bahsedilerek sunulan sistemin temel blok diyagramı verilmiştir. Sistemin her bir adımında yapılan işlemler ve kullanılan teknikler sırasıyla açıklanmıştır.


2.1. Veri Tabanı

Tezde önerilen sistemin uygulama ve analiz aşamalarında kullanılmak üzere 10 farklı görüntüleme türünde 52669 adetlik medikal görüntü havuzu oluşturulmuştur. Kan hücresi görüntüleri (5208 adet), göğüs patoloji görüntüleri(5362 adet), akciğer röntgen görüntüleri (5216 adet) ve boyun ultrason görüntüleri (5535 adet), Kaggle Dataset Archive' den, beyin MR görüntüleri (5097 adet), NIH-National Library of Medicine'den, kolonoskopi görüntüleri (5102), Cancer Imaging Archive'den, tomografi görüntüleri (5242 adet), Mendeley veri tabanından, retina görüntüleri (5515 adet), IEEE Dataport ve Friedrich-Alexander University Fundus (HRF) veri tabanından, cilt kanseri görüntüleri (5194 adet), The International Skin Imaging Collaboration'dan, tiroid kanseri doku örneği görüntüleri (5198 adet), Stanford University Tissue Microarray Database ve National Taiwan University of Science and Technology Center of Computer Vision and Medical Imaging'den temin edilmiştir.

2.2. Sunulan CBIR Sisteminin Genel Yapısı

CBIR sistemleri temel iki amaca hizmet etmektedir. Bunlar görüntülerin saklanması durumunda gereken depolama alanının düşürülmesi ve görüntülere erişim hızının mümkün olduğunca artırılmasıdır. Bu amaçla CBIR sistemlerinde çeşitli teknikler kullanılır. Bu tezde CBIR sistemlerinin yüksek doğrulukla ve hızla en yakın

sonuçları getirme kabiliyetlerinin geliştirilmesi amaçlanmıştır. Sunulan sisteme ait yapı Şekil 2.1.'de verilmiştir.



Şekil 2.1. Sunulan CBIR sisteminin genel yapısı


İçerik tabanlı görüntü erişim sistemleri; bilgisayarlı hesaplama, verilerin sınıflandırılması ve saklanması gibi farklı işlem adımlarının bir araya getirilmesiyle oluşturulur. CBIR sistemlerinde kullanıcı belirli bir resim üzerinden benzer resimleri elde etmeyi amaçlar. Kullanıcının arama yaptığı bu resim sorgu (query) resmi olarak adlandırılır. Sistemden sorgu resmine en çok benzeyen resimlerin bulunarak kullanıcıya gösterilmesi beklenir. Önerilen sistem görüntü ön işleme, görüntü özelliklerinin çıkarılması, görüntü özelliklerinin saklanması, benzerlik ölçütlerinin hesaplanması ve benzer görüntülerin getirilmesi bölümlerinden meydana gelmektedir. Sistemden sorgulama yapılmak istendiğinde ilk olarak sorgu görüntüsünün özellikleri çıkarılır ve özellik vektörü oluşturulur. Elde edilen özellik vektörü halihazırda veritabanında bulunan özellik vektörleri ile karşılaştırılır ve sorgu görüntüsünün özelliklerine en yakın görüntüler saptanır. Son olarak benzer görüntüler kullanıcı arayüzü üzerinde kullanıcıya gösterilir.

2.3. Ön İşleme


Medikal görüntüler çeşitli ihtiyaçlara göre çok farklı teknolojiler ile üretilirler. Elektromanyetik alan, X ışınları ve ultrasonik ses dalgaları gibi yöntemler ile elde edilen medikal görüntülerde çok hassas ölçüm sistemleri kullanılmakta ve ölçüm

yapılan ortamdan kaynaklanan istenmeyen gürültü kirlilikleri oluşmaktadır. Biyolojik yapı üzerinde çalışılıyor olması da net görüntülerin elde edilmesini zorlaştırmaktadır. Bu sebeplerden dolayı medikal görüntüler üzerinde gürültüden kaynaklanan bozulmalar meydana gelmektedir. Bu durum görüntü içeriklerinin saptanmasını güçleştirir. Görüntü içeriğinin doğru bir şekilde belirlenebilmesi için gürültü bileşenlerinin giderilmesi gerekir. Literatürde gürültüden kaynaklanan bozunumların giderilmesi için bir çok farklı yöntem bulunmaktadır. Medikal görüntü çeşitlerinin fazla olması ve kullanılan teknoloji farklılıkları, standart bir gürültü giderme yönteminin seçilmesini olanaksız kılar. Medikal görüntünün türüne ve içeriğine göre dinamik yöntemlerin kullanılması gerekmektedir [22].

Eşik seviye uygulaması az hesaplama gereksinimine ihtiyaç duyması, karmaşık olmaması ve doğru sonuçlar vermesinden dolayı medikal görüntülerde gürültü giderme için yaygın olarak tercih edilmiştir. Eşik seviyesi uygulaması görüntü içindeki piksellerin sayısal değerlerine göre belirlenen sınır değerin alt ve üst aralıklarının istenilen değere yuvarlanması esasına dayanır. Medikal görüntüler değişken gri seviye karmaşıklığına sahip olduğu için sınır değerin belirlenmesi zordur. Bu yüzden eşik seviyesi uygulamasında sınır değerin belirlenmesi önem kazanmaktadır. Medikal görüntülerde bölge tespiti ile ilgili yapılan bir çalışmada standart eşik seviyesi uygulama tekniklerinin dezavantajları anlatılmış ve renk dağılımı tabanlı eşik seviyesi yöntemi önerilmiştir. Önerilen yöntem ile görüntü içindeki renk dağılımlarına göre dinamik ve otomatik olarak sınır değerinin bulunarak eşik seviyesi yönteminde kullanılması gösterilmiş, görüntüdeki gürültü değerlerini düşürdüğü belirtilmiştir [22].



Şekil 2.2. Gürültülü tomografi görüntü örneği. a) Gürültülü tomografi görüntüsü, b) Gürültülü görüntünün gri tonlamalı hali, c) Gri tonlamalı ve gürültülü görüntüye eşik seviyesi yönteminin uygulanmış hali, d) Eşik seviyesi yöntemi uygulanmış görüntüde Canny kenar bulma yöntemi ile kenar bilgilerinin bulunması



Şekil 2.3. Gürültü bileşeni olmayan tomografi görüntüsü örneği. a) Gürültü bileşenleri giderilmiş tomografi görüntüsü, b) Gürültüsüz görüntünün gri tonlamalı hali, c) Gri tonlamalı ve gürültüsüz görüntüye eşik seviyesi yönteminin uygulanmış hali, d) Eşik seviyesi yöntemi uygulanmış görüntüde Canny kenar bulma yöntemi ile kenar bilgilerinin bulunması

Medikal görüntülerde gürültünün varlığı görüntünün görsel kalitesini düşürür ve görüntü içeriği ile ilgili önemli bilgileri bozar. Gürültü bileşenlerinin yararlı bilgiyi yok etmeden önce görüntüden çıkarılması gerekmektedir.

Önerilen CBIR sisteminde medikal görüntülerin gürültülerinin giderilmesi ve içeriğinin daha doğru saptanabilmesi için sırasıyla Median filtreleme, gri tonlama renk çevrimi, eşik seviyesi uygulaması ve Canny kenar bulma yöntemleri kullanılmıştır. Median filtreleme yönteminde işlem yapılacak noktanın komşu piksellerinin sayısal değerleri büyükten küçüğe sıralanarak ortanca değer belirlenmiş ve işlem yapılan pikselin eski değeri ile değiştirilmiştir. Gri tonlama renk çevriminde pikselin sahip olduğu kırmızı, yeşil ve mavi renk değerleri gri tonlamaya çevrilerek şekil özelliklerinin bulunmasında kullanılmıştır. Eşik seviyesi uygulaması ile görüntüdeki istenmeyen bileşenler yok edilmiştir. Canny kenar bulma yöntemi ile görüntü içeriğindeki renk geçişleri belirgin hale getirilmiştir. Uygulanan ön işleme yöntemleri sayesinde görüntüler bir sonraki işlem adımına hazır hale getirilmiş ve görüntü içeriğinin tespiti kolaylaştırılmıştır. Belirtilen ön işleme adımları veri tabanındaki tüm görüntülere uygulanmış ve CBIR sistemi sorgu anındaki tüm sorgu görüntülerine uygulanacak şekilde tasarlanmıştır. Şekil 2.2.'de gürültü bileşenleri olan bir tomografi görüntüsü ve ön işleme yöntemleri sonucunda oluşan yeni görüntüler sırasıyla verilmiştir. Gürültü bileşenleri olan görüntüye eşik seviyesi ve kenar bulma yöntemleri uygulandıktan sonra görüntünün içerik bilgilerinin kaybolduğu görülmektedir. Şekil 2.3.'te ise gürültü bileşenleri giderilmiş tomografi görüntüsü ve ön işleme yöntemleri sonucunda oluşan yeni görüntüler sırasıyla verilmiştir. Gürültü bileşenleri giderilmiş olan görüntüye eşik seviyesi ve kenar

bulma yöntemleri uygulandıktan sonra görüntünün içerik bilgilerinin kaybolmadığı ve görüntü içindeki nesnelerin belirginleştiği görülmektedir.


2.4. Özellik Çıkarma

Özellik çıkarma, görüntüyü kendine has özellikleriyle ifade edebilecek bilgilerin tespit edilmesi ve bu bilgilerin işlem yapılabilir şekilde ifade edilmesidir. Özelliklerin tespit edilmesi ve kullanılmasındaki temel amaç büyük veri miktarının ve depolama için gerekli olan alan ihtiyacının azaltılmasıdır. CBIR sistemlerinde görüntü içeriğinde bulunan özelliklere göre araştırma yapılır. Bir görüntüyü temsil eden özellikler, görüntünün piksel yoğunluk (intensity) değerlerinden hesaplanabileceği gibi görüntüye bazı zaman-frekans uzay dönüşümleri uygulanarak da elde edilebilir. Özelliklerin piksel uzayında hesaplanması, CBIR sisteminin hesap yükünü azaltır. Görüntüden çıkarılan özgün özellik sayısının artması benzer görüntü özellikleri ile karşılaştırma esnasında daha iyi sonuçların alınması ile birlikte hesap yükünü de arttırır. Bu tezde geleneksel özellik çıkarma yöntemleri olarak da adlandırılan görüntünün renk, doku ve şekil özellikleri çıkarılmıştır. Görüntüden elde edilen özellikler kıyaslama yapılabilmesi için bir araya getirilerek özellik vektörü oluşturulmuş ve veri tabanında bu şekilde saklanmışlardır.

2.4.1. Renk özelliklerinin çıkarılması

Işık yansımaları sonucu oluşan renkler, insan duyu organları tarafından algılanan en önemli ve ayırt edici görüntü bileşenidir. Renk öznelikleri görüntü erişim sistemlerinde en fazla kullanılan yöntemlerin başında gelir. Renk öznelikleri veritabanında kolay bir şekilde saklanabilir, indekslenebilir ve erişilebilirler. Sayısal görüntülerde renkler farklı boyutlardaki renk uzayları ile belirtilirler. RGB (Red, Green, Blue), LUV (L-U-V axis), CMYK (Cyan, Magenta, Yellow, Key), HSV (Hue, Saturation, Value) ve HMMD (Hue Min Max Difference) renk uzaylarına örnek olarak verilebilir. Bunlardan en fazla kullanılanı RGB renk uzayıdır ve ismini meydana geldiği üç ana rengin İngilizce isimlerinin baş harflerinden alır. RGB renk uzayında ilgili pikselin renk değeri kırmızı (Red), yeşil (Green) ve mavi (Blue) ana

renklerinin belirli oranlardaki karışımı ile belirlenir. Kırmızı, yeşil ve maviden oluşan bu ana renklerin her birine renk kanalı denmektedir. Diğer renk uzayları RGB renk uzayının matematiksel işlemler ile dönüştürülmesiyle oluşturulabilirler. Şekil 2.4.'te RGB renk uzayının temsili yapısı gösterilmektedir.



Şekil 2.4. RGB Renk uzayı

2.4.1.1. Renk momentleri

Renk momentleri, görüntüdeki renk dağılımını istatistiksel olarak karakterize eden ölçütlerdir [5]. Görüntü özniteliklerinin çıkarılmasında başarılı bir yöntemdir. Renk momentleri üç değişkenden meydana gelir; Ortalama değer, standart sapma ve eğrilik. Görüntüdeki her bir pikselin sayısal renk değeri toplamalarının aritmetik ortalaması ortalama değer olarak adlandırılır. Standart sapma renk dağılımının varyansının kareköküdür ve piksel değerlerinin dağılımının hangi şekilde olduğu ile ilgili bilgi edinmemizi sağlar. Görüntüdeki piksel değerlerinin ortalama piksel değerlerine olan ilişkisini ifade etmek için kullanılır. Eğiklik dağılımdaki asimetri derecesinin bir ölçüsü olarak ifade edilir. Bu değişkenler RGB renk uzayındaki her bir renk kanalı için hesaplanır.

$$E_R = \frac{1}{N} \sum_{j=1}^N I_{R,j} \quad (2.1)$$


$$\sigma_R = \left[\frac{1}{N} \sum_{j=1}^N (I_{R,j} - E_R)^2 \right]^{\frac{1}{2}} \quad (2.2)$$

$$S_R = \left[\frac{1}{N} \sum_{j=1}^N (I_{R,j} E_R)^3 \right]^{\frac{1}{3}} \quad (2.3)$$

Denklem 2.1., Denklem 2.2. ve Denklem 2.3.'te renk momentleri değişkenlerinin hesaplama formülleri verilmiştir [23]. ER, σR, SR sırasıyla görüntünün ortalama değer, standart sapma ve eğrilik değişkenlerinin kırmızı renk kanalı için verilmiş olan hesaplama formülleridir. Bu değişkenler diğer renk kanalları (yeşil ve mavi) için de hesaplanır. N, görüntüdeki toplam piksel sayısını, IR, j indisli görüntü pikselinin kırmızı kanal için verilen sayısal renk değerini ifade eder. Görüntüye ait üç renk kanalı için ortalama değer, varyans ve eğrilik değişkenleri hesaplanarak renk momentleri başlığı altında 9 adet öznitelik elde edilmiştir.

2.4.1.2. Renk dağılımları


Renk dağılımları (Histogram), bir resimdeki renk değerlerinin (yoğunluk) adetlerine göre dağılımlarını gösteren veriler topluluğudur. Histogramlar genellikle Y ekseninde renk şiddetinin, X ekseninde de piksel adetinin bulunduğu grafikler şeklinde gösterilir. Y eksenini tüm olası renk tonlarını, X eksenini de ilgili renk tonundaki toplam piksel sayısını belirtir. Şekil 2.5.'te RGB renk uzayı ile oluşturulmuş bir görüntü, bu görüntünün gri tonlamalı hali ve görüntüye ait histogram grafiği gösterilmektedir.



Şekil 2.5. RGB renk uzayı ile oluşturulmuş bir görüntü ve histogram grafiği. a) RGB renk uzayı ile oluşturulmuş bir görüntü, b) Görüntünün gri tonlamalı hali, c) Gri tonlamalı görüntüye ait histogram grafiği


Histogram tekniği gri tonlamalı resimlere uygulanabildiği gibi renkli resimlere de uygulanabilir. RGB renk uzayındaki bir görüntü için kırmızı, yeşil ve mavi renk tonları için üç ayrı histogram grafiği bulunabilir. Şekil 2.6.'da RGB renk uzayına ait

bir görüntünün kırmızı, yeşil ve mavi renk kanallarına ait oluşturulan histogram grafikleri gösterilmektedir.




Şekil 2.6. Renkli bir görüntüye ait histogram dağılımları. a) Kırmızı renk kanalına ait histogram grafiği, b) Yeşil renk kanalına ait histogram grafiği, c) Mavi renk kanalına ait histogram grafiği

Histogram değerlerinin uzamsal dağılımını gözlemleyerek görüntünün parlaklığı hakkında genel bir fikir edinilebilir. Histogram değerleri sola doğru yoğunlaşıyor ise görüntünün koyu olduğu sonucu elde edilebilir. Şekil 2.7.'de koyu renk tonlamalı bir görüntü ve bu görüntüye ait histogram grafiği gösterilmektedir. Aynı şekilde histogram değerleri grafiğin sağına doğru yoğunlaşıyor ise görüntünün parlak olduğu çıkarımında bulunulabilir [24]. Şekil 2.8.'de açık renk tonlamalı bir görüntü ve bu görüntüye ait histogram grafiği gösterilmektedir.




Şekil 2.7. Koyu renk tonlamalı bir görüntü ve histogram grafiği




Şekil 2.8. Açık renk tonlamalı bir görüntü ve histogram grafiği

Herhangi bir görüntüde bir eşik değeri belirlenip bu değerin alt ve üst tarafındaki değerleri farklı yoğunluklara dönüştürerek gri tonlamalı bir görüntü elde edilebilir. Histogram tekniği eşik tanımlamak için iyi bir seçenektir.



Şekil 2.9. a) Karşıt renk tonlamalarının bir arada olduğu bir görüntü b) Görüntünün histogram grafiği

Karşıt renk tonlu görüntülerde piksel değerlerinin iki grupta yoğunlaştığı görülür. Eşik değeri bu iki grubun ortasında bir değer olacak şekilde seçilirse etkin gri tonlamalı çevrim sağlanabilir. Şekil 2.9.'da karşıt renk tonlamalarının bir arada olduğu bir görüntü ve histogram grafiği gösterilmektedir.



Şekil 2.10. a) Benzer renk tonlamalarının bir arada olduğu bir görüntü b) Görüntünün histogram grafiği

Benzer renk tonlu görüntülerde histogramın sürekli olduğu görülür. Bu durum görüntünün eşik için uygun bir aday olmadığını ve ideal eşik değerini bulmanın zor olacağını göstermektedir. Şekil 2.10.'da benzer renk tonlamalarının bir arada olduğu bir görüntü ve histogram grafiği gösterilmektedir.

Görüntüye ait histogram grafiklerinden çeşitli bilgiler edinilebilir. Aşağıda bu çalışmada histogram bilgilerinden elde edilen özellikler sırasıyla açıklanmıştır.

Ortalama değeri: Görüntüyü meydana getiren piksellerin renk değerlerinin (yoğunluklarının) aritmetik ortalamasıdır.

Standart Sapma: Görüntüyü meydana getiren piksellerin renk değerlerinin, ortalama değeri ile olan farklarının karelerinin toplamının değeri dizisindeki eleman sayısının bir eksiğine bölümünün kareköküdür. Denklem 2.4.'te standart sapma hesaplama formülü verilmiştir.

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (X_i - X_{ort})^2} \quad (2.4)$$

Yukarıdaki formülde σ standart sapmayı, N değeri dizisindeki eleman sayısını, X_i değeri dizisinin i . elemanını, X_{ort} değeri dizisindeki sayıların aritmetik ortalamasını belirtir.

Orta değeri: Görüntüyü meydana getiren piksellerin renk değerlerinin düzenli (sıralı) bir listesinin tam ortasındaki değeri.

En büyük değeri: Görüntüyü meydana getiren piksellerin renk değerlerinin sayısal olarak en büyüğüdür.

En küçük değeri: Görüntüyü meydana getiren piksellerin renk değerlerinin sayısal olarak en küçüğüdür.

Toplam adet: Görüntüyü meydana getiren piksellerin farklı renk değerlerinin sayısını belirtir.

Yukarıda anlatılan değeri görüntüdeki tüm renk kanalları için ayrı ayrı hesaplanabilir. Bu çalışmada görüntüler ilk olarak ön işleme adımından geçirilerek gri tonlamalı görüntüler elde edilmiştir. Renk dağılımı özellikleri oluşturulurken her bir pikselin sahip olduğu gri renk değeri üzerinden hesaplama yapılması tercih

edilmiştir. Bu şekilde hesaplama yükünün azaltılması hedeflenmiştir. Renk dağılımları (histogram) başlığı altında 6 adet öznitelik oluşturulmuştur.

2.4.1.3. Ortalama rgb değeri

Ortalama RGB değeri görüntüdeki toplam renk yoğunluklarının ortalamasını ifade eder. Görsel öznitelik oluşturma açısından öznel sonuçlar vermez. Hesaplaması ve değişken haline getirilmesi kolaydır. En önemli kullanım amacı geniş veritabanı erişimlerinde kıyaslama yapılacak hedef görüntü kapsamını filtreleyerek azaltmaktır. Denklem 2.5.'te kırmızı renk kanalı için ortalama değer hesaplama formülü verilmiştir. Ortalama RGB değeri her bir renk kanalı için ayrı olarak hesaplanabileceği gibi üç renk kanalının toplam değeri için de hesaplanabilir. Denklem 2.6.'da ortalama RGB değerinin üç renk kanalının toplamı için kullanılan hesaplama formülü verilmiştir.

$$A_R = \frac{1}{N} \sum_{j=1}^N [(I_{R,j})] \quad (2.5)$$

$$A_{RGB} = \frac{1}{N} \sum_{j=1}^N [(I_{R,j} + I_{G,j} + I_{B,j})] \quad (2.6)$$

ARGB ortalama renk dağılımını, N görüntüdeki toplam piksel sayısını, IR, IG, IB her bir pikselin renk kanalı değerlerini ve j her bir pikseli ifade eder. Ortalama RGB değeri başlığı altında 4 adet öznitelik oluşturulmuştur.

2.4.2. Doku özelliklerinin çıkarılması

Doku özelliği görüntü tanımlamada kullanılan önemli bir özelliktir. Görüntünün yüzeyini ve yapısını temsil eden desen bilgisi olarak da tanımlanabilir. Bir resmin dokusu, çeşitli nesnelerden oluşan karmaşık görsel desenler veya parlaklık, renk, şekil, boyut vb. özelliklere sahip alt bileşenlerden oluşabilir [25].

2.4.2.1. Gri seviye eş oluşturma matrisleri (GLCM)

Gri seviye eş oluşum matrisleri (GLCM- Gray level co-occurrence matrix), görüntü dokusu için kullanılan en eski tekniklerden biridir. GLCM üzerinden hesaplanan çeşitli dokusal parametreler genel resim içeriği ile ilgili bir çok ayrıntıyı elde etmemizi sağlar.


GLCM, bir görüntünün komşu piksellerine ilişkin ikinci dereceden istatistiksel bilgileri içerir. Gri tonlamalı görüntüler üzerinden hesaplanan GLCM, herhangi bir pikselin gri tonlama yoğunluğu açısından bitişik piksellerde (dikey, yatay ya da çapraz) ne sıklıkta olduğunu hesaplar [26].

$K \times K$ boyutunda verilen bir I görüntüsü için, $G \times G$ GLCM matrisinin MCO elemanlarının hesaplanması Denklem 2.7.'de verilmiştir.

$$M_{CO} = \sum_{x=1}^K \sum_{y=1}^K \begin{bmatrix} 1, \text{ eğer } I(x,y) = i \text{ ve } I(x + d_x, y + d_y) = j \\ 0, \text{ diğer durumlarda} \end{bmatrix} \quad (2.7)$$

Verilen formülde i referans pikselin gri seviyeli tonunu, j komşu pikselin gri seviyeli tonunu, x ve y piksel koordinatlarını, dx ve dy ise bitişik piksele olan uzaklıkların koordinat düzlemindeki uzunluklarını belirtir.


GLCM hesaplaması, bitişik piksellerle olan benzerlik ilişkisi için çeşitli açılarda yapılabilir. Şekil 2.11.'de GLCM matrisinin dört farklı açı (0° , 45° , 90° , and 135°) için oluşturulmasında nasıl bir yol izleneceğine dair yöntem gösterilmiştir. Verilen açılar için hesaplamalarda hangi piksellerin kullanılacağı görülmektedir.



Şekil 2.11. GLCM matrisi açı yönleri ve ilgili pikseller

Şekil 2.12.'de gri seviye tonlarının 0 ile 3 arasında değiştiği, uzaklık değeri 1 olan, 4×4 büyüklüğündeki bir piksel grubunun dört farklı yönde oluşturulmuş GLCM

matris örnekleri gösterilmiştir. a matrisi referans piksel grubunun piksel değerlerini göstermektedir. b matrisi 0° için, c matrisi 45° için, d matrisi 90° için, e matrisi 135° için oluşturulan GLCM örnekleridir.



Şekil 2.12. Örnek bir görüntü için farklı yönlerdeki GLCM matrisleri

GLCM'nin boyutu referans görüntünün maksimum gri ton değerine göre belirlenir. Gri tonlama seviyesinin artması daha doğru dokusal bilgi çıkarılması anlamına gelir fakat bu durum hesap yükü gereksinimini arttıracığından sistem performansını olumsuz yönde etkiler.

GLCM üzerinden görüntünün dokusu ile ilgili çıkarılabilecek öznelilikler aşağıda sıralanmıştır.

Enerji: GLCM'deki elemanların karelerinin toplamıdır. Tekdüzelik veya açısal ikinci moment olarak da bilinir. Denklem 2.8.'de GLCM için enerji hesaplama formülü verilmiştir. g_{ij} GLCM matrisindeki her bir elemanı, i ve j piksel koordinat değerlerini ifade eder.

$$\text{Enerji} = \sum_i \sum_j g_{ij}^2 \quad (2.8)$$

Kontrast (Karşıtlık): Gri seviye eş oluşum matrisindeki yerel varyasyonları ölçer. Komşu pikseller arasındaki ortalama gri seviye farkı ile ilişkilidir. Denklem 2.9.'da

GLCM için kontrast hesaplama formülü verilmiştir. g_{ij} GLCM matrisindeki herbir elemanı, i ve j piksel koordinat değerlerini ifade eder.

$$\text{Kontrast} = \sum_i \sum_j (i - j)^2 g_{ij} \quad (2.9)$$

İlişki (Korelasyon): Belirtilen piksel çiftlerinin birleşme olasılığını ölçer. Denklem 2.10.'da GLCM için ilişki hesaplama formülü verilmiştir. g_{ij} GLCM matrisindeki herbir elemanı, i ve j piksel koordinat değerlerini, σ varyans değerini, P_{ij} MCO matrisindeki i ve j indislerindeki katsayıyı, μ GLCM ortalamasını ifade eder.

$$\text{İlişki} = \sum_{i,j=0}^{N-1} P_{ij} \frac{(i-\mu)(j-\mu)}{\sigma^2} \quad (2.10)$$

Homojenlik: GLCM'deki elemanların dağılımının GLCM diyagonaline yakınlığını ölçer. Denklem 2.11.'de GLCM için homojenlik hesaplama formülü verilmiştir. g_{ij} GLCM matrisindeki herbir elemanı, i ve j piksel koordinat değerlerini ifade eder.

$$\text{Homojenlik} = \sum_i \sum_j \frac{1}{1+(i-j)^2} g_{ij} \quad (2.11)$$

GLCM başlığı altında uzaklık değeri 1 birim ve hesaplama açısı 45° olan GLCM matrisi oluşturularak görüntüye ait 4 adet öznelik hesaplanmıştır.

2.4.2.2. Gabor filtreleri

Gabor filtreleri ilk olarak Dennis Gabor tarafından kullanılmıştır. Görüntüyü oluşturan piksellerin konumlarının doğası, oryantasyon seçiciliği ve frekans karakteristiğinden dolayı görüntü analizinde yaygın olarak kullanılmıştır [12]. Görüntü üzerinde tekrar eden görüntü parçacıklarını ve sabit değerleri yakalamaya çalışır. Denklem 2.12.'de Gabor filtresinin matematiksel ifadesi verilmiştir. Gabor filtresi, iki boyutlu bir Gauss zarfıyla modüle edilen, frekans ve taşıyıcılı bir sinüzoidal düzlem dalgasından oluşur.

$$g(x, y) = s(x, y) * w(x, y) \quad (2.12)$$

Buradaki taşıyıcı, Denklem 2.13.'te verilen kompleks sayı yapısında bir sinus dalgasıdır;

$$s(x, y) = \cos(2\pi \cdot (u_0 \cdot x + v_0 \cdot y) + \varphi) + i \cdot \sin(2\pi \cdot (u_0 \cdot x + v_0 \cdot y) + \varphi) \quad (2.13)$$

(u_0, v_0) kompleks sinüs dalganın frekansını, φ kompleks sinüs dalganın fazını göstermektedir. Zarf bir Gauss işlevidir:

$$w(x, y) = K \cdot \exp \left\{ -\pi \left(\frac{(x-x_0)^2}{\sigma_x^2} + \frac{(y-y_0)^2}{\sigma_y^2} \right) \right\} \quad (2.14)$$

Denklem 2.14.'te; K Gauss zarfının büyüklük ölçeği, σ_x, σ_y - Gauss zarfının iki ekseninin ölçeklendirme parametreleri, (x_0, y_0) Gauss fonksiyonunun maksimum değeri, θ Gauss zarfının dönüş açısını göstermektedir.

Gabor fonksiyonunun merkez frekansı (u_0, v_0) ile tanımlanır. Radyal Merkezi frekansı f_0 Denklem 2.15.'teki gibi ve yönlendirme açısı θ ise Denklem 2.16.'daki gibi ifade edilir.

$$f_0 = \sqrt{u_0^2 + v_0^2} \quad (2.15)$$

$$\theta = \tan^{-1} \left(\frac{v_0}{u_0} \right) \quad (2.16)$$

$g(x, y)$ 'nin 2 boyutlu Fourier dönüşümü denklem 2.17.'deki gibi ifade edilir,


$$G(u, v) = \frac{K}{\sigma_x \sigma_y} \cdot \exp(j(-2\pi(x_0(u - u_0) + y_0(v - v_0)) + \varphi)) \cdot \exp \left\{ -\pi \left(\frac{(u-u_0)^2}{\sigma_x^2} + \frac{(v-v_0)^2}{\sigma_y^2} \right) \right\} \quad (2.17)$$

Gabor filtreleri ile yapılan çalışmalarda filtre seçimi büyük bir önem taşır. Görüntüdeki her doku, enerjisinin çoğunu dar bir frekans ve taşıyıcı bandında içerir. Gabor filtresi, dokulu görüntüleri çoklu dar frekans ve yönlendirme kanallarına kodlar. Gabor filtresi yerel bant geçiş filtresi olarak işlev görür. Her filtre dört parametre seçilerek belirlenir: $\theta, f, \sigma_x, \sigma_y$ [12]. f frekansı, σ_x ve σ_y standart sapmayı, θ yönlendirme açısını ifade eder. Gabor filtresinin frekans bant genişliği denklem 2.18.'de, oryantasyonu ise denklem 2.19.'da verilmiştir.

$$B = \log_2 \left[\left(\frac{\pi f \sigma_x + \sqrt{\ln 2/2}}{\pi f \sigma_x - \sqrt{\ln 2/2}} \right) \right] \quad (2.18)$$

$$\Omega = \tan^{-1} \left[\frac{\sqrt{\ln 2/2}}{\pi f \sigma_y} \right] \quad (2.19)$$

Gabor filtre tanımlamadaki ilk adım parametrelerin ($\theta, f, \sigma_x, \sigma_y$) tanımlanmasıdır. Bu parametrelerin seçimi uygun özniteliklerin seçilebilmesi için çok önemlidir. Bu parametreleri değiştirerek, frekans alanını tamamen kapsayan filtre bankası elde edilebilir. Uygun filtre bankasının seçimi farklı araştırmalarda analiz edilmiştir. Şekil 2.13.'te farklı açı ve frekans bileşenleri ile oluşturulmuş Gabor filtreleri gösterilmektedir.



Şekil 2.13. Farklı açı ve frekans bileşenleri ile oluşturulmuş Gabor filtreleri

Bir I görüntüsünün Gabor dönüşümü, $g(x, y)$ Gabor filtresi ile $I(x, y)$ görüntüsünün konvolüsyon işleminin sonucunda bulunur [12]. Gabor dönüşümü uygulanmış görüntüyü $R(x, y)$ ile ifade edecek olursak, Gabor dönüşümü Denklem 2.20.'deki gibi ifade edilebilir.

$$R(x, y) = g(x, y) * I(x, y) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} g(m, n). I(x - m, y - n) \quad (2.20)$$

Yukarıdaki formülde $R(x, y)$ gabor filtresi uygulanmış görüntüyü, $*$ işlemi iki boyutlu doğrusal konvolüsyonu belirtir. M ve N , Gabor filtre maskesinin boyutlarıdır. Filtrelenen görüntünün $E(x, y)$ yerel enerjisi, filtrelenen ve dönüştürülmüş görüntü değerlerinin mutlak ortalama sapmasından (μ) Denklem 2.21.'deki gibi hesaplanabilir.

$$E(x, y) = \frac{1}{M} \sum_{(a,b) \in W} |R(x, y) - \mu| \quad (2.21)$$

Filtrelenen görüntüler sıfır ortalamaya sahiptir, bu nedenle doku enerjisi $E(x, y)$ Denklem 2.22.'deki gibi ifade edilebilir;

$$E(x, y) \cong \sum_{(x,y)} |R(x, y)|^2 \quad (2.22)$$

Bu denklemden yola çıkılarak görüntü dokusunun toplam enerjisi Denklem 2.23.'teki gibi ifade edilebilir;

$$E \cong \sum_1^n E(x, y) \quad (2.23)$$

Gabor filtreleri başlığı altında 9x9 boyutunda 0° , 45° , 90° ve 135° açı değerlerine sahip 4 farklı Gabor filtresi oluşturulmuş ve görüntü bu filtrelerden geçirilerek 4 adet öznitelik hesaplanmıştır.

2.4.3. Şekil özelliklerinin çıkarılması


Görüntüde bulunan nesne ve benzeri varlıkların şekilleri, görüntünün tanımlanması için önemli bir temel özelliktir. Şekil bulma yöntemleri sınır bilgilerine dayalı ve bölgeye dayalı olmak üzere iki grupta incelenebilir. Her iki grupta da şeklin bir bütün olarak mı yoksa segmentler halinde mi temsil edildiğine göre farklı yöntemler kullanılabilmektedir [13]. Görüntü erişim sistemlerinde genellikle şekil sınır bilgileri üzerinden öznitelik hesaplaması yapılmaktadır.

Sınır bilgilerine dayalı öznitelik çıkarımında ilk olarak görüntüde bulunan şekillerin sınır değerleri belirlenir. Belirlenen sınır değerleri ayrıca bütünsel yaklaşım ve yapısal yaklaşım olarak iki alt grupta incelenebilir. Bütünsel yaklaşımda, şekli alt kısımlara bölmeden ve sınır bilgilerinin tamamı öznitelik oluşturmak için kullanılır. Yapısal yöntemde, şekil sınır bilgileri alt bölümlere ayrılarak incelenir [12].

Görüntü üzerindeki bir nesnenin şeklinin tanımlanabilmesi için ilk olarak nesnenin görüntünün tamamından ayırt edilerek bağımsız şekilde incelenmesi gerekir. Görüntü üzerindeki nesne sınırlarının saptanmasında temel olarak keskin renk geçiş farklılıklarından yararlanılır.

Sınır bilgileri bulunurken dikkat edilmesi gereken konu görüntü üzerindeki gürültünün giderilmesidir. Gürültünün azaltılması sınır bilgilerinin bulunma kolaylığını ve doğruluğunu artırır. Sınır bilgileri bulunurken gri tonlamalı görüntüler sıklıkla kullanılmaktadır. Bu şekilde renk uzayı genişliği ve aritmetik işlem yükü azaltılmış olur.

Medikal görüntüler çok sayıda küçük parçacıktan oluşabilir yada görüntüyü oluşturan piksel değerleri birbirine çok yakın sayısal büyüklüklere sahip olabilir. Bu durumlar medikal görüntülerde şekil sınır bilgilerinin bulunmasını zorlaştırır. Birbirine çok yakın piksel değerlerinin olması gri tonlamalı görüntülere eşik seviyesi uygulanmasını zorlaştırabilir. Bu çalışmada bu gibi zorlukların üstesinden gelebilmek için medikal görüntüler simetri eksenlerinden parçalara bölünerek her bir bölümdeki sınır bilgilerinin bulunması amaçlanmıştır. Bulunan sınır bilgileri daha sonra birleştirilerek nesnenin şekli belirlenmiş olur. Bu yöntem medial eksen dönüşümü olarak bilinmektedir [27]. Şekil 2.14.'te eksenel şekil tanımlamasının tekniği gösterilmektedir. Şekilde görüldüğü üzere görüntü üzerindeki pikseller 4 farklı yönden dıştan içe doğru taranarak saptanan ilk kenar ve nesne bilgisi belirlenmiş olur.




Şekil 2.14. Eksenel şekil tanımlaması tekniği

Alan, dairesellik, uzunluk, maksimum genişlik, maksimum yükseklik, ana eksen yönelimi vb. özellikleri basit şekil tanımlayıcıları olarak adlandırılırlar. Bu özellikler şekil sınır bilgileri üzerinden hesaplanabilirler. Basit şekil tanımlayıcıları büyük olan şekilleri ayırt etmede kullanılabilirler. Farklı şekillerin aynı basit şekil tanımlayıcıları ile ifade edilebilmeleri mümkündür bu yüzden özgün öznitelik olarak kullanılmaları doğru sonuç elde edilmesini zorlaştırabilmektedir.

Aşağıda bu çalışmada kullanılan şekil özniteliklerinin çıkarılma ve hesaplama yöntemleri sırasıyla açıklanmıştır.


Dışbukey gövde ve dışbukeylik: Dışbükey gövde, şekli içeren en küçük dışbükey sınır bilgi kümesidir. Convex Hull olarak da adlandırılır. Dışbukeylik dışbükey çevresinin şeklin tam çevresine olan oranıdır. Şekil 2.15.'te örnek bir görüntü ve bu görüntüye ait dışbukey gövde gösterilmektedir. Mavi çizgiler görüntüdeki sınır bilgilerini, turuncu çizgi ise görüntünün dışbukey gövdesini temsil etmektedir. Denklem 2.24.'te dışbukeylik hesaplama formülü verilmiştir.

$$Dışbukeylik = \frac{Dışbukey\ sınır\ uzunluğu}{Şeklin\ orjinal\ sınır\ uzunluğu} \quad (2.24)$$



Şekil 2.15. Dışbukey gövde. a) Örnek bir görüntü, b) Görüntüye ait dışbukey gövde

Uzak mesafe: görüntü sınır bilgilerindeki birbirine en uzak noktaların uzaklık bilgisidir. Görüntünün rotasyonundan bağımsız olduğundan öznitelik olarak kullanılabilir. Şekil 2.16.'da örnek görüntünün en uzun kirişi gösterilmektedir. Denklem 2.25.'te uzak mesafe hesaplama formülü verilmiştir. x_1 , x_2 , y_1 ve y_2 nokta koordinatlarını belirtmektedir.



Şekil 2.16. Sınır bilgilerine ait en uzun kiriş

$$D_{Uzak\ mesafe} = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (2.25)$$

Kirişler ve kiriş mesafesi: Kirişler görüntü sınır bilgisindeki her bir noktanın birbirinden uzaklığını gösterir. Sınır bilgilerindeki kirişlerin uzunluklarının ve açılarının dağılımı şekil özneliği olarak kullanılabilir [28]. Denklem 2.26.'da kiriş mesafesi hesaplama formülü verilmiştir. x_2 , ve y_2 nokta koordinatlarını, x_{cp} ve y_{cp} ağırlık merkezinin x ve y eksenlerindeki değerlerini belirtmektedir.

$$D_{Kiriş\ mesafesi} = \sqrt{(x_2 - x_{cp})^2 + (y_2 - y_{cp})^2} \quad (2.26)$$

Minumum sınır dörtgeni ve karesellik: Minumum sınır dörtgeni görüntüdeki nesnenin sığabileceği minimum büyüklükteki dörtgenin bulunması ile elde edilir. Sınır bilgilerindeki maksimum ve minimum x, y koordinat değerleri kullanılarak hesaplanır. Elde edilen dörtgen görüntünün büyüklüğü ile ilişkili olacağından öznitelik olarak kullanımında oranlanarak kullanılabilir. Dörtgen oranı Denklem 2.27.'deki gibi hesaplanabilir. W dörtgenin genişliğini, L uzunluğunu belirtmektedir. Karesellik oranı Denklem 2.28.'deki gibi hesaplanabilir. Şekil 2.17.'de örnek bir görüntünün sığabileceği en küçük dörtkenar gösterilmektedir.

$$O_{\text{Minimum sınır dörtgen oranı}} = 1 - \frac{W}{L} \quad (2.27)$$

$$Karesellik = \frac{\text{Şeklin alanı}}{\text{Minimum sınır dörtgen alanı}} \quad (2.28)$$



Şekil 2.17. Sınır bilgilerinin sığabileceği en küçük dörtkenar

Dairesellik oranı: Dairesellik oranı şeklin daireye benzerlik oranını belirtir. Dairesellik oranı aynı çevre uzunluğuna sahip daire ve şeklin alanlarının oranıdır. A_s , A_c daire ve şeklin alanları olmak üzere dairesellik oranı Denklem 2.29.'daki gibi hesaplanabilir. Şekil 2.18.'de örnek bir görüntünün çevre uzunluğu ile oluşturulabilecek daire gösterilmektedir.


$$C_{\text{dairesellik}} = \frac{A_s}{A_c} \quad (2.29)$$



Şekil 2.18. Sınır bilgileri üzerinden çizilen daire

Ağırlık Merkezi ve ağırlık merkezi uzaklığı: Ağırlık merkezi şekli meydana getiren sınır noktalarının ağırlık merkezini ifade eder ve centroid olarak adlandırılır. Ağırlık merkezinin konumu görüntüdeki nesnenin şekline göre değişir. Şekil 2.19.'da örnek bir görüntünün ağırlık merkezi gösterilmektedir. Ağırlık merkezi Denklem 2.30.'da verilen formül ile hesaplanabilir. N şekil üzerindeki nokta (piksel) sayısını, x ve y nokta koordinatlarını belirtir.

$$g_{(x,y)} = \begin{pmatrix} g_x & \frac{1}{N} \sum_{i=1}^N x_i \\ g_y & \frac{1}{N} \sum_{i=1}^N y_i \end{pmatrix} \quad (2.30)$$



Şekil 2.19. Sınır bilgisi noktalarının ağırlık merkezi


Ağırlık merkezi uzaklığı sınır bilgisindeki her noktanın ağırlık merkezi noktası ile olan uzaklıklarının toplamını belirtir. Denklem 2.31.'de verilen formül ile hesaplanabilir. x_s ve y_s sınırdaki noktaların, x_c ve y_c ise ağırlık merkezinin koordinatlarını belirtir.

$$D_{\text{ağırlık merkezi}}(s) = \sqrt{(x_s - x_c)^2 + (y_s - y_c)^2} \quad (2.31)$$

Sınır bölgesi alanı: Sınır bölgesinin alanı görüntü sınır noktalarının birleştirilmesi ile oluşturulan kapalı alanın yüzey alanının hesaplanması ile bulunur. Hesaplama formülü Denklem 2.32'de verilmiştir. x_i ve y_i sınır noktalarının koordinatlarını belirtmektedir.


$$A = \frac{1}{2} \left| \sum_{i=0}^{N-1} (x_i y_{i+1} - x_{i+1} y_i) \right| \quad (2.32)$$

Izgara tabanlı yöntem: Izgara tabanlı yöntemde görüntünün tamamı hücrelere ayrılır ve bu hücrelerde şeklin sınır parçacıklarının olup olmadığı kontrol edilir. Sınır parçacığı olan hücrelere 1, boş olan hücrelere 0 değeri atanarak bir matris oluşturulur. Izgara tabanlı yöntem yön ve açı biçiminden bağımsız değildir. Bu da öznetelik olarak kullanımı konusunda doğruluk problemlerini beraberinde getirir [13]. Şekil 2.20.'de örnek bir ızgara tabanlı yöntem gösterilmektedir.



Şekil 2.20. Izgara tabanlı şekil gösterimi

Izgara tabanlı diğer yöntemde şekil hücelere ayrılır ve bu hücrelerin şekli ne kadar kapsadığı kontrol edilir. Her bir hücre, şekli kapsama durumuna göre işaretlenir. Şekil 2.21.'de örnek bir ızgara tabanlı yöntem ve matris formu gösterilmektedir.



Şekil 2.21. Izgara yöntemi ile hücelere ayrılmış görüntü, a) Izgara yönteminin uygulanması, b) Görüntünün matris formu, c) Görüntünün ızgara yöntemi ile gösterimi

Izgara tabanlı yöntemde görüntü matris formundaki herbir satır için ayrı bir öznitelik oluşturulması tercih edilmiştir. Görüntü 8x8 matris formuna dönüştürülmüş ve 8 satır için 1 olan matris bileşenleri sayısal değere dönüştürülmüştür. Şekil öznitelikleri başlığı altında 17 adet öznitelik oluşturulmuştur.

2.5. Benzerlik Ölçümü

Sorgu görüntüsü üzerinden elde edilen özelliklerin veri tabanında önceden oluşturulmuş vektörler ile karşılaştırılabilmesi için benzerlik oranı bulma yöntemlerinden yararlanılmıştır. Benzerlik oranının bulunmasında karşılaştırılan vektör grubunun her bir eleman çifti için aradaki uzaklık bulunur ve elde edilen toplam sonuç oranlanır. Benzerlik oranlarının ölçülebilmesi için literatürde bir çok yöntem kullanılmış ve karşılaştırılmıştır [29]. Karşılaştırılması istenilen veri

grubunun uygunluğuna göre farklı yöntemlerin kullanılması mümkündür. Kullanılan özellik vektörlerinin tek boyutlu olması ve aritmetik işlem gereksinimleri dikkate alınarak Kosinüs, Öklit ve Manhattan benzerlik yöntemlerinin karşılaştırılmasına karar verilmiştir. Bu yöntemlerin başlıca tercih sebebi hesaplama gereksinimlerinin az olmasıdır. Cosinüs, Öklit ve Manhattan benzerlik yöntemleri aşağıda sırasıyla açıklanmıştır.

2.5.1. Kosinüs benzerlik yöntemi

Cosinüs benzerlik yöntemi karşılaştırılmak istenilen iki nokta arasındaki uzaklığı trigonometrik cosinüs fonksiyonu üzerinden hesaplar. Cosinüs uzaklığı koordinat sistemindeki iki noktanın orjin ile olan doğrularının arasındaki açı ile bağıntılıdır.

$$\cos(\theta) = \frac{\vec{A} \cdot \vec{B}}{\|\vec{A}\| \cdot \|\vec{B}\|} \quad (2.33)$$

Denklem 2.33'te cosinüs uzaklık benzerliği yönteminin kosinüs açısıyla olan bağıntısı verilmiştir. d vektör uzunluğu, A ve B karşılaştırılmak istenen vektörlerdir. Denklem 2.34.'te kosinüs uzaklık benzerliğinin hesaplama formülü verilmiştir. A_i ve B_i karşılaştırılmak istenen A ve B vektörlerinin elemanlarını, d vektör büyüklüklerini belirtmektedir.

$$d_{\cosinüs} = \frac{\sum_{i=1}^d A_i \cdot B_i}{\sqrt{\sum_{i=1}^d A_i^2} \cdot \sqrt{\sum_{i=1}^d B_i^2}} \quad (2.34)$$

2.5.2. Öklit benzerlik yöntemi

Öklit benzerlik yöntemi karşılaştırılmak istenilen iki nokta arasındaki uzaklığı öklit teoremini temel alarak hesaplar. İki nokta arasındaki uzaklık koordinat sistemi üzerindeki konumlarının farklarının kareleri ile orantılıdır.

$$d_{öklit} = \sqrt{\sum_{i=1}^d |\vec{A}_i - \vec{B}_i|^2} \quad (2.35)$$

Denklem 2.35.'te öklit uzaklık benzerliği yönteminin formülü verilmiştir. d vektör uzunluğu, A_i ve B_i karşılaştırılmak istenen vektörlerdir.

2.5.3. Manhattan benzerlik yöntemi

Manhattan benzerlik yöntemi karşılaştırılmak istenilen iki nokta arasındaki uzaklığı doğrusal çizgiler üzerinden hesaplar. İki nokta arasındaki uzaklık koordinat sistemi üzerindeki konumlarının farklarının büyüklüğü ile doğru orantılıdır.

$$d_{\text{Manhattan}} = \sum_{i=1}^d |A_i - B_i| \quad (2.36)$$

Denklem 2.36.'da Manhattan uzaklık benzerliği yönteminin formülü verilmiştir. d vektör uzunluğu, A_i ve B_i karşılaştırılmak istenen vektörlerin elemanlarıdır.

Bu tezde Cosinüs, Öklit ve Manhattan benzerlik yöntemleri görüntü özellik vektörlerine uygulanarak sonuçlar birbiriyle kıyaslanmıştır. Tablo 2.1.'de farklı medikal görüntülere için hesaplanan Cosinüs, Öklit ve Manhattan benzerlik değerlerinin sıralamaları verilmiştir. Hesaplanan benzerlik değerlerinin karşılaştırılmaları sonucunda Cosinüs ve Öklit benzerlik yöntemlerinin en doğru sonuçları verdiği görülmüştür. Hesaplama kolaylığı ve hız kriterleri açısından kosinüs benzerlik yönteminin kullanılması tercih edilmiştir.

Tablo 2.1. Farklı medikal görüntüler için hesaplanan Cosinüs, Öklit ve Manhattan benzerliklerinin sıralanması

Görüntü Tanımı	Cosinüs benzerliği	Öklit benzerliği	Manhattan benzerliği
Görüntü Id=1425	68.59	26.3	70,6
Görüntü Id=1467	68.91	26.4	53.8
Görüntü Id=1475	69.56	26.4	52.6
Görüntü Id=1476	68.66	26.4	52.7
Görüntü Id=1489	68.75	26.4	52.2

2.6. Sonuç Görüntüleri ve Sistem Başarımı

Şekil 2.1.'de blog diyagramı verilen sistemin çalışma performansını değerlendirmek için hassasiyet (precision) ve istenilen görüntüleri geri getirme (recall) oranı değerlendirilmiştir. Denklem 2.37. ve denklem 2.38.'de hassasiyet ve geri getirme oranlarının hesaplama formülleri belirtilmiştir.

$$Hassasiyet = \frac{\text{Bulunan benzer görüntü sayısı}}{\text{Bulunan toplam görüntü sayısı}} \quad (2.37)$$

$$Geri getirme oranı = \frac{\text{Bulunan benzer görüntü sayısı}}{\text{Veri tabanında bulunan benzer görüntü sayısı}} \quad (2.38)$$

Sistem başarımının hesaplanabilmesi için 5 farklı katogoride 250 adetlik görüntü havuzu oluşturulmuştur. Geleneksel yöntemler ile görüntüye ait 21 adet renk, 8 adet doku ve 22 adet şekil özelliği hesaplanarak özellik vektörü oluşturulmuştur. Özellik vektörleri veri tabanında saklanarak sorgu görüntüsü ile olan benzerliklerin hesaplanmasında kullanılmıştır.

Tablo 2.2. Farklı görüntü kategorilerinde yapılan sorgulamalarda hesaplanan hassasiyet ve geri getirme oranları

Kategori	Hassasiyet oranı	Geri getirme oranı
1. Katagori	0.78	0.53
2. Katagori	0.82	0.92
3. Katagori	0.85	0.53
4. Katagori	0.80	0.55
5. Katagori	0.58	0.61
Ortalama	0.76	0.62

5 farklı görüntü kategorisinde yapılan sorgu sonuçlarının hassasiyet ve geri getirme oranları Tablo 2.2.'de verilmiştir. Bu sonuçlara göre ilk sorgu görüntüsünde %78, ilk üç sorgu görüntüsünde %81, ilk beş sorgu görüntüsünde %76 başarımları yakalanmıştır.


Medikal görüntülerin genellikle gri tonlamalı olması ve keskin renk geçişlerini barındırmaması renk özelliklerinin çıkarımını zorlaştırdığı görülmüştür. Gri tonlamalı medikal görüntülerde renk özelliklerinin birbirine yakın olduğu ve ayırt ediciliklerinin azaldığı saptanmıştır. Renkli medikal görüntüler üzerinde çalışılması durumunda daha özgün renk özelliklerinin çıkarılabileceği sonucuna varılmıştır. Gabor filtreleme yönteminin fazla hesaplama ihtiyacı gerektirdiği görülmüş ve sınırlı sayıda filtre oluşturularak görüntülere uygulanabilmektedir. Görüntüdeki tekrarlanan bileşenlerin uygulanan Gabor filtreleri ile aynı açıda olmamasından dolayı bazı görüntülerde yeterli sayıda doku özelliği çıkarılamamıştır. Medikal görüntülerin çok parçacıklı yapıya sahip olması ve kenar çizgilerinin süreklilik oluşturmaması şekil özelliklerinin belirlenmesini güçleştirmiştir. Görüntü içeriğinin belirlenmesinde yararlanılan şekil kenar bilgilerinin çok sayıda ve karmaşık bir yapıya sahip olması görüntü içeriğinin en dış kenar bilgilerinin kullanılmasını zorunlu kılmıştır. Bu durum özellikle görüntünün merkezinde benzer büyüklükte nesne barındıran görüntülerde birbirine yakın şekil özelliklerinin bulunmasına sebep olmuştur. Görüntü özelliklerinin istenilen sayılarda ve özgün yapıda çıkarılamaması bazı medikal görüntü türlerindeki başarı oranlarının düşük çıkmasına sebep olmuş ve sistemin genel performansını olumsuz yönde etkilemiştir.

BÖLÜM 3. DERİN ÖĞRENME


Klasik içerik tabanlı görüntü erişim sistemlerinde renk, doku, şekil vb. özniteliklerden yararlanılmıştır. Son yıllarda sinir ağları ve derin öğrenme yöntemlerinin gelişmesi ile birlikte bir çok uygulamada olduğu gibi görüntü erişim sistemlerine de mimari değişmiştir. Bu nedenle tezin bu bölümünde derin öğrenme tabanlı içerik tabanlı bir görüntü erişim sistemi tasarımında gereken altyapının oluşturulması amaçlanmıştır.

3.1. Yapay Sinir Ağları

Yapay sinir ağları biyolojik sistemin çalışma prensibini örnek alır. Yapay sinir ağları biyolojik sinir sistemlerinin modellenmesi amacıyla geliştirilmeye başlanmış fakat makine ve bilgisayar teknolojisinin gelişmesiyle birlikte mühendislik araştırma konusu haline gelmiştir. Beynin temel hesaplama birimi nörondur. İnsan sinir sisteminde yaklaşık 86 milyar nöron bulunur ve bunlar yaklaşık 10^{14} - 10^{15} sinaps ile birbirine bağlıdır. Şekil 3.1.'de biyolojik bir nöronun yapısı, Şekil 3.2.'de bu nörona ait matematiksel model gösterilmektedir.



Şekil 3.1. Biyolojik nöronun yapısı




Şekil 3.2. Biyolojik nöronun matematiksel modeli

Her bir nöron dendritlerinden giriş sinyallerini alır ve aksonu boyunca çıkış sinyalini üretir. Akson sonunda dallanır ve diğer nöronların dendritlerine sinapslar yoluyla bağlanır. Bir nöronun hesaplamalı modelinde, aksonlar boyunca hareket eden sinyaller (örneğin, X_0), o sinaptaki sinaptik kuvvetine (örneğin, W_0) dayanarak diğer nöronun dendritleri ile çarpımsal olarak (örneğin $W_0 \cdot X_0$) etkileşime girer. Buradaki fikir, sinaptik kuvvetlerin (ağırlıklar W) öğrenilebilmesi ve bir nöronun diğer nörona ileteceği gücü (pozitif veya negatif ağırlık) kontrol etmesidir. Temel modelde dendritler, sinyali topladıkları hücre gövdesine taşır. Son toplamın belirli bir eşiğin üstünde olması durumunda, nöron ateşlenir ve aksonu boyunca bir değer gönderir. Hesaplamalı modelde, zamanlamanın önemli olmadığı ve yalnızca ateşleme sıklığının bilgi ilettiği varsayılır. Bu varsayıma dayanılarak, nöronun atış hızı, akson boyunca sinyal sıklığını temsil eden bir f aktivasyon fonksiyonu ile modellenir. Aktivasyon fonksiyonu gerçek değerli bir girdi alır ve bu değeri 0 ile 1 arasında değişen bir değere dönüştürür. Özetlenecek olursa; her bir nöron, öncelikle bir giriş sinyali alır, bu sinyal ile ağırlıklar arasında nokta çarpımı gerçekleştirir, elde ettiği sonuca önceden öğrenilmiş bilgileri ekler ve doğrusal olmayan sigmoid (veya aktivasyon) işlevi uygulayarak 0 ile 1 arasında değişen bir değer üretir [30].

Matematiksel modelde nöron çıkışında bulunan aktivasyon işlemi için farklı yöntemler kullanılmaktadır. Sıklıkla tercih edilen yöntemlerin başında sigmoid fonksiyonu gelir. Sigmoid fonksiyonu doğrusal olmayan bir matematiksel ifadeye sahiptir. Sigmoid fonksiyonu gerçel değerli bir sayı alır ve onu 0 ile 1 arasında bir değere dönüştürür. Sigmoid fonksiyonu sonucunda büyük negatif sayılar 0, büyük pozitif sayılar 1 olur. Aktivasyon fonksiyonu olarak kullanılan diğer bir yöntem


hiperbolik tanjant (Tanh) fonksiyonudur. Tanh fonksiyonu girişine uygulanan değeri $[-1, 1]$ aralığında gerçel değerli bir sayıya dönüştürür. Tanh fonksiyonunun çıkışı sıfır merkezlidir. Aktivasyon fonksiyonu olarak kullanılan diğer bir yöntem ReLu (Rectified Linear Unit) fonksiyonudur. ReLu fonksiyonu son yıllarda popüler olmuş ve kullanım yoğunluğu artmıştır. Matematiksel olarak $F(x) = \max(0, x)$ fonksiyonunu hesaplar. Başka bir deyişle, aktivasyon sadece sıfırda eşiklenir.

Şekil 3.3.'de Sigmoid, Tanh ve ReLu aktivasyon fonksiyonlarının matematiksel ifadelerinin grafikleri verilmiştir.



Şekil 3.3. a) Sigmoid, b) Tanh ve c) ReLu aktivasyon fonksiyonlarının grafik gösterimleri

Her sinir ağı, sorunun karmaşıklığına bağlı olarak çok sayıda gizli katmana, bir giriş ve bir çıkış katmanına sahiptir. Veriler bu katmanlardan geçtikten sonra, katmanlardaki nöronlar nasıl çalışması gerektiğini öğrenir ve tanımlarlar. Yapay sinir ağlarında nöronların çıktıları diğer katmandaki nöronların girdisidir. Düzenli sinir ağları için en yaygın katman tipi, iki bitişik katman arasındaki nöronların tamamen çift olarak bağlandığı, ancak tek bir katmandaki nöronların hiçbir bağlantı paylaşmadığı, tam olarak bağlanan katmandır. Şekil 3.4.'te klasik sinir ağı modeli gösterilmektedir.



Şekil 3.4. Klasik sinir ağı modeli

N katmanlı bir sinir ağından bahsedilirken giriş katmanı N sayısına dahil edilmez. Bu nedenle, tek katmanlı bir sinir ağı, gizli katmanları olmayan bir ağı tarif eder (giriş, doğrudan çıkışa eşlenir). Bir sinir ağındaki tüm katmanların aksine, çıkış katmanı nöronları çoğunlukla bir aktivasyon fonksiyonuna sahip değildir. Bunun nedeni, son çıktı katmanının genellikle rasgele gerçek değerli sayılar veya sınıflandırma amaçlı kullanılmasıdır. Sinir ağındaki katmanların boyutu ve sayısı arttıkça ağıın kapasitesi arttırılmış olur.

3.2. Derin Öğrenme


Yapay sinir ağları görüntü sınıflandırma, nesne bulma, nesne takip etme gibi problemler için uygun bir çözüm yolu sunmakta fakat istenilen çözüme bağlı olarak fazla hesaplama yüküne ihtiyaç duymaktadır. Karmaşık problemlerin çözümü sinir ağındaki katman ve nöron sayısının arttırılmasını gerektirmektedir. Sinir ağındaki katman sayısı ve buna bağlı olarak ağıın derinliğinin artması verilerin daha detaylı incelenebilmesini sağlar. Bu şekilde çok sayıda gizli katmanı bulunan ağlar ile yapılan işlemler derin öğrenme olarak adlandırılmaktadır.

Çalışılacak veri sayısının artması ve veriden daha anlamlı bilgilere ulaşma gereksinimi yapay sinir ağları ile öznetelik oluşturulması konusunda yenilikler yapılmasını zorunlu kılmıştır. Büyük verilerin sinir ağları ile işlenmesi sırasında farklı işlem ve katman ihtiyacı artarken hesaplama yükünün azaltılması için işlenen verinin boyutlarının azaltılması ihtiyacı doğmuştur. Bu gibi problemlerin çözümü için LeCun evrişimli sinir ağı modelini önermiştir [31]. Bu modelde sinir ağı girişine uygulanan çok sayıdaki giriş verisi ağ katmanları arasında ilerlerken çeşitli işlemlere (evrişimlere-convolution) uğrayarak sayıca azaltılmış olur.

3.3. Evrişimsel Sinir Ağları (Convolutional Neural Networks, CNN)

Sinir ağları bir girdi (tek bir vektör) alır ve onu bir dizi gizli katmana dönüştürür. Evrişimsel sinir ağları normal bir sinir ağının aksine genişlik, yükseklik ve derinlik olmak üzere 3 boyutta düzenlenmiş katmanlara sahiptir. Şekil 3.5.'te evrişimsel sinir


ağının 3 boyutlu katman yapısı gösterilmektedir. Evrişimli sinir ağı modeli oluşturulmasında konvolüsyon katmanı, havuz katmanı ve tamamen bağlantılı katman olmak üzere üç ana katman tipi kullanılır. Bu katmanların her biri farklılaştırılabilir bir işlevle bir aktivasyon hacmini diğerine dönüştürür.



Şekil 3.5. Evrişimsel sinir ağı 3 boyutlu katman yapısı

Standart bir RGB görüntü kırmızı, yeşil ve mavi olmak üzere üç renk kanalından meydana gelir. Görüntü, her bir renk kanalında $N \times N$ boyutunda piksel değerlerini belirten matrisler şeklinde ifade edilebilir. Görüntünün bu şekilde ifade edilmesi evrişimsel sinir ağlarının verimli bir şekilde kullanılabileceğini göstermektedir.


Evrişimsel sinir ağları genel olarak *girdi*, *konvolüsyon*, *aktivasyon fonksiyonu*, *havuz katmanı* ve *tam bağlantılı katman* yapılarına sahiptirler. Şekil 3.6.'da örnek bir evrişimsel sinir ağının katmanları gösterilmektedir.



Şekil 3.6. Evrişimsel sinir ağı katmanları


Evrişimsel sinir ağını oluşturan yapılar ve işlevleri aşağıda sırasıyla açıklanmıştır.

Girdi: Görüntünün ham piksel değerlerinden oluşur. Üç renk kanalı (R, G, B) olan bir görüntü için $N \times N$ büyüklüğünde 3 adet matristen meydana gelir. Şekil 3.7.'de evrişimsel sinir ağında girdi olarak kullanılan 3 renk kanalına sahip 6×6 çözünürlükteki görüntünün girdi yapısı gösterilmektedir. 6×6 çözünürlüğündeki bir görüntünün girdi matrisi $[6 \times 6 \times 3]$ boyutundadır.



Şekil 3.7. Evrişimsel sinir ağı için girdi örneği.


Konvolüsyon katmanı: Konvolüsyon katmanı, girdideki yerel bölgelere bağlı nöronların çıkışını hesaplar. Konvolüsyon katmanının amacı görüntüye ait özniteliklerin bulunmasıdır. Belirlenen sayıdaki filtre ile konvolüsyon işlemini yaparak noktasal çarpım işlevini gerçekleştirir. Böylece seçilen filtrelere göre özniteliklerin oluşturulması sağlanmış olur. Şekil 3.8.'de konvolüsyon işlemi sırasında görüntüdeki piksele uygulanan filtre ve matematiksel işlem adımları gösterilmektedir. Örnekteki görselde ilgili piksele Sobel filtresi uygulandığı görülmektedir. Oluşturulmak istenen sinir ağına göre farklı büyüklük ve yapıda filtreler ağ tarafından kullanılabilir. Evrişimli sinir ağlarında kullanılan filtrelerin kullanıcı tarafından belirlenmesi mümkün değildir. Filtrelerin yapısı model eğitimi sırasında geri yayılım yöntemi ile otomatik olarak ağ tarafından gerçekleştirilir. Kullanıcı tarafından sadece parametreler belirlenebilir. Evrişimsel sinir ağının ilk katmanlarında (girdi görüntüsüne yakın olan katmanlar) daha az sayıda filtre bulunur. Katmanlar ağın sonuna yaklaştıkça öğrenilecek filtre sayısı artar. Ağdaki her katman ve filtreleme işlemi sonucunda farklı öznitelikler hesaplanır.



Şekil 3.8. Görüntüye uygulanan filtre ve matematiksel işlem adımları (Towards Data Science)

Evrişimli sinir ağlarında istenilen çıkarımlarda bulunmak için çok sayıda konvolüsyon katmanı kullanılır. Konvolüsyon işlemleri sırasında kullanılan filtrelerin boyutuna bağlı olarak işlem sonrasında giriş boyutu ve çıkış boyutu arasında farklılık oluşur. Bu boyutun istenilen büyüklüklerde ayarlanabilmesi için piksel ekleme, piksel kaydırma gibi ilave işlemler uygulanır. Bu şekilde bir sonraki katmanın girdi büyüklüğü ayarlanmış olur.


Aktivasyon fonksiyonu: Eşikleme işlevini uygular. Giriş görüntüsünde konvolüsyon katmanı sonucu oluşan değerleri yorumlar ve bu değere göre belirlenen işlemleri gerçekleştirerek yeni bir değer oluşturur. Şekil 3.9.'da aktivasyon işlemi sırasında sinir ağındaki nöron çıkışlarına uygulanan işlemler gösterilmektedir.



Şekil 3.9. Nöron çıkışlarına uygulanan işlemler


Evrişimli sinir ağlarında yoğunlukla kullanılan ReLu aktivasyon fonksiyonu giriş görüntüsündeki her negatif değer için 0, her pozitif değer için değerini kendisini döndürür. Şekil 3.10.'da örnek nöron değerlerini içeren matris uygulanan ReLu

aktivasyon fonksiyonu ve çıkış matrisi gösterilmektedir. Giriş matrisindeki negatif değerlerin çıkışta filtrelendiği ve 0 olarak değiştirildiği görülmektedir.



Şekil 3.10. Nöron çıkış değerlerine uygulanan ReLu aktivasyon fonksiyonu ve çıkış matrisi


Havuzlama katmanı: Havuzlama katmanı, uzamsal boyutlar boyunca (genişlik, yükseklik) bir alt örnekleme işlemi gerçekleştirerek hacimde küçülme sağlar. Sinir ağının bu katmanında öğrenme işlemi gerçekleşmez. Hesaplama karmaşıklığını azaltmak için giriş matrisinin yükseklik ve genişlik bilgisi azaltılır. Evrişimli sinir ağlarında genellikle MaxPool havuz katmanı kullanılmaktadır. Şekil 3.11.'de Max Pool havuzlama katmanından geçirilen bir görüntü görülmektedir. (224x224x64) büyüklüğündeki bir görüntü 2 boyutlu bir filtre üzerinden havuzlama katmanından geçirilmiş ve (112x112x64) boyutlarında yeni bir görüntü elde edilmiştir.



Şekil 3.11. Max Pool havuzlama katmanından geçirilen bir görüntü


Şekil 3.12.'de Max Pool havuzlama katmanından geçirilen bir görüntünün renk kanallarından bir tanesi sembolik olarak gösterilmektedir. 2x2 Max Pool havuzlama katmanından geçirilen görüntünün çözünürlüğünün azaldığı görülmektedir. Bu yöntemle göre görüntü yatay ve dikey eksenlerde 2 eşit parçaya bölünerek (2x2 Max Pool havuzlama katmanı kullanıldığı için) 4 farklı bölüm elde edilir. Elde edilen bu

bölümlerde en büyük değeri alan piksel havuzlama katmanının çıkışındaki görüntünün ilgili bölüme denk gelen parçasının piksel değerini temsil eder.



Şekil 3.12. Max Pool havuz katmanından geçirilen bir görüntünün renk kanalı

Tam bağlantılı katman: Tam bağlantılı katman, son katmandaki nöron sayısına bağlı olarak sınıf puanlarını hesaplar. Tam bağlantılı katmanda, son evrişim katının çıktısı düzleştirilir ve mevcut katmanın her bir düğümü bir sonraki katmanın diğer düğümüne bağlanır.




Şekil 3.13. Son evrişim katmanında uygulanan düzleştirme işlemi

Şekil 3.13.'te son evrişim katının çıktısına uygulanan düzleştirme işlemi görülmektedir. Son evrişim katının çıktı matrisi tam bağlantılı katmana bağlanırken tek boyutlu matrise çevrilir. Tam bağlantılı katmandaki nöronlar önceki katmandaki tüm aktivasyonlar ile tam bağlantıya sahiptir. Evrişimli sinir ağlarının son katmanı genellikle sınıf olasılık puanlarını hesaplayacak şekilde yapılandırılır. Sinir ağının çıktısı gruplandırma yapılacak sınıf sayısı büyüklüğüdür.

Evrişimli sinir ağlarının büyük veriler ile çalışılabilmesini kolaylaştırmasının ardından farklı model çalışmaları olmuştur. Lenet-5 modeli 1998 yılında yayınlanmış olan ve ilk başarılı sonucu veren evrişimli sinir ağı modelidir. Yann LeCun ve ekibi tarafından posta numaraları ve banka çekleri üzerindeki sayıların okunması için bu model geliştirilmiştir. Modelde aktivasyon fonksiyonu olarak sigmoid ve tanh kullanılmıştır [13]. AlexNet, 2012 yılında önerilmiş ve ImageNet ILSVRC (ImageNet Large Scale Visual Recognition Competition) yarışmasında sınıflandırma doğruluk oranını %74,3'ten %83,6 oranına yükseltmiştir. Aktivasyon fonksiyonu olarak ReLu, havuzlama katmanlarında Max-pooling kullanılmıştır [15]. VGG-16 basit bir ağı modeli olup önceki modellerden en önemli farkı evrişim katmanlarının 2'li ya da 3'li kullanılabilmesidir. Diğer modellerde olduğu gibi girişten çıkışa doğru matrislerin yükseklik ve genişlik boyutları azalırken derinlik değeri (kanal sayısı) artmaktadır.

Şekil 3.14.'te evrişimsel sinir ağlarında uygulanan işlem adımları ve sinir ağı çıkış bilgileri görsel olarak verilmiştir. Sinir ağının ilk birimi ham görüntü piksellerini (solda), son birimi sınıf puanlarını (sağda) tutar. Evrişim işlemleri boyunca her aktivasyon hacmi bir sütun olarak gösterilmiştir. Evrişimsel sinir ağlarının son katmanına genellikle sınıflandırıcılar eklenir. Görseldeki örnekte son katmanda her sınıf için puan bilgileri hesaplanmıştır ve bu bilgiler sınıf etiketleri ile eşleştirilmiştir.



Şekil 3.14. Evrişimli sinir ağı işlem adımları.

3.4. Önerilen Derin Öğrenme Modeli

Bu çalışmada görüntü işleme alanında getirdiği kolaylık ve verimlilik avantajları nedeniyle CNN mimarisinin kullanılması tercih edilmiştir. CNN mimarisi genellikle görüntü sınıflandırmada kullanılmaktadır. Bu çalışmada sınıflandırma yapabilecek bir CNN tasarımı oluşturulmuş ve çıktı olarak sorgulama yapılan görüntülerin sınıf bilgisi elde edilmiştir.

Evrişimli sinir ağının istenilen başarıyı sağlayabilmesi ağda kullanılacak katman ve parametrelerin önemle seçilmesini gerektirir. Bu çalışmada konvolüsyon işlemleri için 2 boyutlu Keras Conv2D filtreleme algoritmaları tercih edilmiştir. Konvolüsyon işlemleri için farklı parametreler ile uygun filtreleme katmanları oluşturulmuştur. Evrişim katmanlarının konvolüsyon işlemlerinde sırasıyla 32, 64 ve 64 adet 3x3 boyutlarında filtreler kullanılmıştır. Oluşturulan ağ modeli 3 adet gizli ve 1 adet tamamen bağlantılı katmandan oluşmakta ve 174243 eğitilebilir parametre içermektedir. Model sonuna eklenen sınıflandırıcı ile ilgili görüntünün sınıf bilgisi elde edilmiş ve benzer görüntülerin doğrulanmasında kullanılmıştır. Tablo 3.1.'de önerilen evrişimsel sinir ağı modelinin katman yapısı gösterilmektedir.

Tablo 3.1. Önerilen ağ modelinin katman yapısı


Katman Tipi	Katman Çıkışı Görüntü Boyutu	Parametre Sayısı
Konvolüsyon-1 (Conv_2d & ReLu)	(28 x 28 x 32)	896
Konvolüsyon-2 (Conv_2d & ReLu)	(26 x 26 x 32)	9248
Max Pooling-1 (2x2 Max Pooling)	(13 x 13 x 32)	0
Dropout-1	(13 x 13 x 32)	0
Konvolüsyon-3 (Conv_2d & ReLu)	(13 x 13 x 64)	18486
Konvolüsyon-4 (Conv_2d & ReLu)	(11 x 11 x 64)	36928
Max Pooling-2 (2x2 Max Pooling)	(5 x 5 x 64)	0
Dropout-2	(5 x 5 x 64)	0
Konvolüsyon-5 (Conv_2d & ReLu)	(5 x 5 x 64)	36928
Konvolüsyon-6 (Conv_2d & ReLu)	(3 x 3 x 64)	36928
Max Pooling-3 (2x2 Max Pooling)	(1 x 1 x 64)	0
Dropout-3	(1 x 1 x 64)	0
Düzleştirme (Flatten)	64	0

Tablo 3.1. (Devamı)


Katman Tipi	Katman Çıkışı Görüntü Boyutu	Parametre Sayısı
Dense-1	512	33280
Dropout-4	512	0
Dense-2	3	1539
Toplam parametre sayısı	: 174243	
Toplam eğitilebilir parametre sayısı	: 174243	
Eğitilemez parametre sayısı	: 0	

3.5. Sistem Başarımı

Tezde önerilen derin öğrenme modelinin uygulama ve analiz aşamalarında kullanılmak üzere 10 farklı görüntüleme türünde 52669 adetlik medikal görüntü havuzu oluşturulmuştur. Görüntülerin 1000 adeti modelin doğrulanması için kalan bölümü ise önerilen evrişimsel sinir ağının eğitilmesi için kullanılmıştır. Tablo 3.1’de model katmanları verilen derin öğrenme modelinin çalışma performansı öğrenme doğruluğu ve öğrenme sırasındaki kayıp oranları üzerinden değerlendirilmiştir. Şekil 3.15.’te önerilen derin öğrenme modelinin öğrenme ve doğrulama oranlarının grafiği verilmiştir. Şekil 3.16.’da önerilen derin öğrenme modelinin kayıp oranlarının grafiği verilmiştir.



Şekil 3.15. Önerilen derin öğrenme modelinin öğrenme ve doğrulama oranlarının grafiği.



Şekil 3.16. Önerilen derin öğrenme modelinin öğrenme ve doğrulama kayıp oranlarının grafiği

Önerilen derin öğrenme modelinin test edilmesi için 5 farklı görüntü kategorisinde 100'er adet görüntü kullanılmış ve % 99.2 doğrulama başarısı yakalanmıştır. Yapılan sorgular için elde edilen doğruluk oranları Tablo 3.2'de verilmiştir.

Tablo 3.2. Derin öğrenme yöntemi ile yapılan sorgular için elde edilen doğruluk oranları

Kategori	Doğru geri getirme oranı
1. Kategori	% 100
2. Kategori	% 100
3. Kategori	% 97
4. Kategori	% 100
5. Kategori	% 99
Ortalama	% 99.2

BÖLÜM 4. TARTIŞMA VE SONUÇLAR

Tezin bu bölümünde klasik ve derin öğrenme yöntemleri kullanılarak oluşturulan içerik tabanlı görüntü erişim sistemlerinin performans ve sonuçları değerlendirilmiştir. Kullanılan yöntemlerin farklı ve benzer görüntüler üzerinden değerlendirmesi yapılarak karşılaştırılmıştır.

4.1. Renk Özelliklerinin Hesaplanması ve Karşılaştırılması



Yapılan çalışma boyunca hesaplamalardaki işlem yükünün diğer renk uzaylarına göre daha az olması ve evrimsel sinir ağlarına uygun yapısından dolayı RGB renk uzayı tercih edilmiştir. Medikal görüntülerin genellikle gri tonlamalara sahip olması ve görüntünün geneline yayılmış bir gri skala olmasından dolayı görüntü ön işleme adımında eşik değerinin seçiminin zor olduğu görülmüştür. Eşik değerinin doğru seçilememesi durumunda görüntü içeriğindeki nesne ve objelerin tam olarak belirlenememesi durumu gözlemlenmiştir. Genellikle gri tonlamalı görüntülerin kullanılmasından dolayı benzer özneliklere sahip farklı resimlerin olduğu görülmüş ve bunun geri getirme oranlarını olumsuz yönde etkilediği saptanmıştır.

Görüntünün renk özelliklerini tanımlamak için ilk olarak renk moment bileşenleri hesaplanmıştır. Tablo 4.1.'de farklı renk tonlarındaki görüntülere ait hesaplanan renk moment bileşenleri gösterilmiştir.





Tablo 4.1.'de görüldüğü gibi farklı görüntülerde renk momentleri farklılaşmakta ve ayırt edici özellik kazanmaktadır. Farklı renk bileşenlerinde renk momentlerinin değiştiği gözlemlenmesine rağmen görüntü 3 ve 4'te görüldüğü üzere gri tonlamalı görüntülerin renk moment bileşenleri farklı renk uzaylarına göre değişmemektedir. Sadece gri tonlamalı medikal görüntülerde renk momentlerinin farklı renk uzayları

için hesaplanması benzerlik oranlarının hesaplanmasında olumlu etkiye sahip değildir.

Tablo 4.1. Farklı renk tonlarındaki görüntülere ait hesaplanan renk moment bileşenleri

	Görüntü 1	Görüntü 2	Görüntü 3	Görüntü 4
				
Ort.Değer(Kırmızı)	111,04	83,75	59,80	26,09
Ort.Değer (Yeşil)	91,94	98,62	59,80	26,09
Ort.Değer (Mavi)	56,35	115,14	59,80	26,09
Std.Sapma(Kırmızı)	87,91	70,91	52,16	40,87
Std.Sapma(Yeşil)	87,40	82,05	52,16	40,87
Std.Sapma(Mavi)	66,57	91,85	52,16	40,87
Çarpıklık(Kırmızı)	54,18	52,64	53,56	49,07
Çarpıklık (Yeşil)	62,57	58,38	53,56	49,07
Çarpıklık (Mavi)	62,51	61,38	53,56	49,07

Tablo 4.2. Birbirine benzer gri tonlamalı medikal görüntülerin renk moment hesaplamaları



	Görüntü 1	Görüntü 2	Görüntü 3	Görüntü 4
				
Ort.Değer(Kırmızı)	47,20	46,18	42,79	39,75
Std.Sapma(Kırmızı)	45,60	46,64	45,64	49,04
Çarpıklık(Kırmızı)	47,63	45,21	45,53	53,71

Tablo 4.2.'de birbirine benzer gri tonlamalı medikal görüntülerin renk moment hesaplamaları gösterilmektedir. Görüntüler gri tonlamalı oldukları için renk uzayları





arasında moment farklılıkları yoktur. Benzer görüntülerin renk moment bileşenlerinin birbirine yakın olduğu görülmüştür.

Görüntü üzerindeki renk dağılım istatistiklerinin bulunması için renk dağılımı (histogram) tekniğinden yararlanılmıştır. Tablo 4.3.'te farklı renk tonlamalarındaki görüntülere ait, Tablo 4.4.'te ise benzer görüntülere ait renk dağılımı bileşenlerinin değerleri verilmiştir.

Tablo 4.3. Farklı renk tonlamalarındaki görüntülere ait renk dağılımı bileşenlerinin değerleri




	Görüntü 1	Görüntü 2	Görüntü 3	Görüntü 4
				
His. Ortalama Değer	87,37	53,57	21,27	98,53
His. Std.Sapma	69,50	78,32	39,49	64,86
His. Orta Değer	97	1	1	102
His. En Küçük Değer	3	1	1	25
His. En Büyük Değer	148	123	40	153

Tablo 4.4. Benzer görüntülere ait renk dağılımı bileşenlerinin değerleri

	Görüntü 1	Görüntü 2	Görüntü 3	Görüntü 4
				
His. Ortalama Değer	47,19	46,18	42,79	39,76
His. Std.Sapma	45,83	46,85	45,82	49,17
His. Orta Değer	40	29	20	7
His. En Küçük Değer	5	5	4	5
His. En Büyük Değer	75	78	74	75

Görüntüdeki renk uzaylarının ortalama değerleri hesaplanarak geniş veritabanı aralığının verimli bir şekilde daraltılması sağlanmıştır. Tablo 4.5.'te farklı görüntülere ait ortalama renk uzayı (Kırmızı, yeşil ve mavi) değerleri verilmiştir.

Tablo 4.5. Farklı görüntülere ait ortalama renk uzayı (Kırmızı, yeşil ve mavi) değerleri

	Görüntü 1	Görüntü 2	Görüntü 3
			
Ortalama Kırmızı değer	111	67	49
Ortalama Yeşil değer	91	67	49
Ortalama Mavi değer	56	67	49
Ortalama RGB değeri	86	67	49

Tablo 4.5.'te görüldüğü üzere renkli görüntülerin ortalama renk uzayı değerleri (kırmızı, yeşil ve mavi) birbirinden farklı, gri tonlamalı görüntülerde ise aynıdır.




4.2. Doku Özelliklerinin Hesaplanması ve Karşılaştırılması

Görüntünün doku özneteliklerinin oluşturulmasında ilk olarak GLCM tekniğinden yararlanılmıştır. GLCM matrisi oluşturulurken 45^0 yönünde ve 1 piksel uzaklıktaki komşu pikseller kullanılmıştır.


Tablo 4.6.'da farklı dokulara, Tablo 4.7.'de ise farklı görüntülere ait GLCM bileşenleri verilmiştir. Tablolarda görüldüğü üzere farklı medikal görüntülerin GLCM bileşenleri birbirinden farklıdır ve ayırt edici özellik olarak kullanılabilirler. Tablo 4.8.'de benzer medikal görüntülere ait GLCM bileşenleri verilmiştir.

Tablo 4.8.'de görüldüğü üzere benzer medikal görüntülerin GLCM matris bileşenleri birbirine yakın değerler olarak hesaplanmıştır. Bu durum GLCM yönteminin benzer görüntüleri bulmada verimli bir şekilde kullanılabileceğini göstermektedir.




Tablo 4.6. Farklı dokulara ait GLCM bileşenleri

	Görüntü 1	Görüntü 2	Görüntü 3
			
Doku Enerjisi	0,00011	0,00064	0.00047
Doku Karşıtlığı	388.73	1737.56	1567.46
Doku Homojenliği	0.072	0.137	0.126
Doku Bağıntısı	0.990	0.951	0.965

Tablo 4.7. Farklı medikal görüntülere ait GLCM bileşenleri


	Görüntü 1	Görüntü 2	Görüntü 3
			
Doku Enerjisi	0.00330	0.00599	0.00097
Doku Karşıtlığı	240.77	260.44	212.73
Doku Homojenliği	0.236	0.268	0.242
Doku Bağıntısı	0.994	0.984	0.993

Tablo 4.8. Benzer medikal görüntülerin GLCM matris bileşenleri

	Görüntü 1	Görüntü 2	Görüntü 3
			
Doku Enerjisi	0.00692	0.0088	0.0113
Doku Karşıtlığı	127.60	110.20	92.97
Doku Homojenliği	0.337	0.346	0.366
Doku Bağıntısı	0.984	0.986	0.987

Doku özniteliklerinin bulunmasında diğer bir yöntem olarak Gabor filtreleri ve gabor dönüşümleri kullanılmıştır. Gabor filtrelerinin oluşturulmasında dört farklı parametre kullanılarak (θ , f , σ_x , σ_y) en uygun sonucu veren frekans ve açı değeri bulunmaya çalışılmıştır [22].

Tablo 4.9. Farklı medikal görüntü tipleri için gabor filtre konvolüsyonu sonucunda bulunan enerji değerleri


	Görüntü 1	Görüntü 2	Görüntü 3
			
Daku enerjisi (0°)	6.826	2.960	6.853
Daku enerjisi (45°)	6.789	2.944	6.816
Daku enerjisi (90°)	2.660	1.153	2.671
Daku enerjisi (135°)	-4.940	-2.142	-4.960

Tablo 4.9.'da farklı medikal görüntü tipleri için Gabor filtre konvolüsyonu sonucunda bulunan enerji değerleri verilmiştir. Gabor filtrelerinin farklı tipteki medikal görüntüler için özgün parametreler oluşturduğu görülmüştür.

4.3. Şekil Özelliklerinin Hesaplanması ve Karşılaştırılması

Görüntünün şekil özniteliklerinin bulunmasında çözünürlük ve piksel sayısı önemli bir faktördür. Görüntü üzerindeki nesnenin sınır bilgileri pikseller üzerinden hesaplandığından dolayı yüksek çözünürlükteki görüntülerde sınır noktalarının toplam uzunluğu daha büyük olacaktır. Görüntü çözünürlüğünde ölçekleme yapmadan hesaplanan parametreler benzer görüntülere ait farklı özniteliklerin bulunmasına sebep olacaktır. Ölçek problemlerinin önüne geçebilmek için geleneksel yöntemler ile yapılan tüm hesaplamalardan önce görüntü çözünürlükleri sabit bir değere dönüştürülmüştür.


Araştırmaya konu olan medikal görüntüler genellikle birbirinin tekrarı olan dalgalı dokulardan ve periyodik olarak keskin renk geçişlerini barındıran gri tonlamalı şekillerden oluşur. Keskin renk geçişlerinin çok olması görüntü üzerinde çok sayıda sınır bilgisinin oluşmasına, dalgalı doku barındırıyor olması da şekil sınır bilgilerinin devamsız olmasına neden olmaktadır.



Şekil 4.1. a) Gri tonlamalı tomografi görüntüsü b) Şekil sınır bilgileri

Şekil 4.1.'de medikal bir görüntü ve şekil sınır bilgilerine ait çizimler gösterilmiştir. Görüntüdeki doku bilgisinden dolayı şekil içinde bir çok sınır değer bilgisi oluşmuştur ve bu değerlerde devamsızlıklar mevcuttur.



Sınır bilgisine dayalı şekil özniteliklerinin çıkarılmasında görüntüdeki şeklin dış sınırlarının kullanılması önem taşımaktadır. Şeklin sadece dış kenar bilgilerinin bulunabilmesi için aksel tarama yöntemi önerilmiştir. Önerilen aksel tarama yönteminde ilk olarak görüntüdeki şeklin köşelerinden geçecek ve simetrik parçalar oluşturacak şekilde bölümler oluşturulur. Oluşan dört parça alan için görüntünün dış kenarlarından aksellerin kesişme noktasına doğru pikseller taranır. Tarama esnasında karşılaşılan ilk kenar noktası şekil sınır bilgisi olarak atanır ve şeklin iç tarafındaki kenar bilgileri silinir. Şekil 4.2.'de aksel tarama yöntemini gösteren çizimler gösterilmiştir.



Şekil 4.2. Aksel tarama yöntemi ile şekil dış sınırlarının bulunması a)Şekil sınır bilgileri, b) Görüntünün aksellerinden bölünmesi, c) Aksel tarama ile dış sınır bilgilerinin bulunması

Tablo 4.10.'da görüntünün şekil sınır bilgilerinden elde edilen parametreler gösterilmiştir.


Tablo 4.10. Görüntünün şekil sınır bilgilerinden elde edilen parametreler

	Görüntü 2	Görüntü 3	Görüntü 4
			
En uzun kiriş	61,14	45,45	82,68
Toplam kiriş uzunluğu	17791,07	18587,81	44641,69
En küçük dörtgen genişliği	119	131	254
En küçük dörtgen yüksekliği	157	171	203
En küçük dörtgen alanı oranı	62,65	50,79	94,07
Karesellik oranı (%)	0,24	0,23	-0,25
Dairesellik oranı (%)	0,32	0,34	0,29
Sınır bilgisi uzunluğu	212,25	199,00	289,85
Şekil alanı oranı (%)	50,44	42,41	78,95
Ağırlık merkezi X eksen oranı	72	104	131
Ağırlık merkezi Y eksen oranı	99	105	95
Ağırlık merkezi kiriş uzunluğu	14702,69	15315,61	32723,54
Dışbukey uzunluğu	185,79	154,21	237,91
Dışbukey - sınır uzunluğu oranı	0,88	0,77	0,82


Şekil parametrelerinin bölgesel alanlara göre hesaplanabilmesi için ızgara yönteminden yararlanılarak görüntüler 8 x 8 matris oluşturacak şekilde eşit oranlar kullanılarak (1/8) hücrelere bölünmüştür. Kullanılan bu oransal yöntemle farklı çözünürlükteki görüntülerin alan ve sınır uzunluklarının parametre hesaplamalarını etkilememesi amaçlanmıştır.

Izgara yöntemini karakterize etmek için 8 x 8 matrisler oluşturularak sınır ve alan bilgileri sayısal ortama dönüştürülmüştür. Hücrelere ayrılan görüntülerde her bir

hücreye karşılık gelen alanda sınır çizgisi varsa ya da ilgili bölge şekil alanı içinde kalıyorsa bölge matris üzerinde 1 olarak işaretlemiştir.



Şekil 4.3. a) Şekil alanının b) Şekil sınırlarının ızgara yöntemiyle hücrelere ayrılması



Şekil 4.4 ızgara yöntemi ile a) Şekil alanı b) Şekil sınırı matrislerinin oluşturulması

Oluşturulan ızgara matrislerini özniteliklere dönüştürebilmek için her bir matris satırının ikili sayı sistemine göre kodlanarak ondalık tabandaki karşılıklarının hesaplanması ve öznitelğe dönüştürülmesi önerilmiştir. Böylelikle her bir satır için farklı şekil bilgilerinin özgün değerler oluşturması amaçlanmıştır.

Şekil 4.3. ve Şekil 4.4.'te sınır ve alan bilgilerinden yararlanılarak oluşturulan ızgara matrisleri gösterilmektedir. Her bir matrisin ilk satırları için örnek hesaplama yöntemi aşağıda gösterilmiştir.

$$MA,1.satır=[00011000]=0.27+0.26+0.25+1.24+1.23+0.22+0.21+0.20=24$$

$$MB,1.satır=[00011000]=0.27+0.26+0.25+1.24+1.23+0.22+0.21+0.20=24$$

Bu hesaplamalar matrislerin tüm satırları için yapılarak ızgara tabanlı yöntem üzerinden görüntü ile alakalı 8'er adet özellik çıkarılmıştır.

4.4. Benzerlik Hesaplamalarının Karşılaştırılması

Görüntüleri ayırt edici bir şekilde tanımlayabilmek için elde edilen sayısal parametreler bir araya getirilerek özellik vektörleri oluşturulmuştur. Her bir görüntü için renk, doku ve şekil olmak üzere üç farklı özellik vektörü kullanılmıştır. Aşağıda oluşturulan örnek bir özellik vektörü gösterilmiştir.

$$V_{Öznitelik(Renk)} = [19.13, 33.49, 41.18, 19.52, 33.55, 2, 202, 19]$$

Önerilen klasik içerik elde etme sisteminde veri tabanının önceden oluşturulmuş ve sorguların bu veritabanı üzerinden yapılacağı öngörülmüştür. Benzer görüntülere ulaşmak için veri tabanındaki özellik havuzu ile sorgu görüntüsünden anlık olarak elde edilen özellik vektörünün benzerlik oranının karşılaştırılması gerekmektedir. Her sorgu sırasında veri tabanındaki tüm kayıtlar için benzerlik uzaklığı hesaplaması yapılacağından sorgu süresi ve yöntemi önem kazanmaktadır.

Çalışma anında sorgu görüntüsünden elde edilen öznitelikler veri tabanındaki özellik havuzundaki tüm kayıtlar ile karşılaştırılarak benzerlik katsayıları bulunmuştur. Kullanılan özniteliklerin tek boyutlu olması ve aritmetik işlem gereksinimleri dikkate alınarak cosinüs, öklit ve manhattan benzerlik hesaplama yöntemlerinin karşılaştırılmasına karar verilmiştir. Bu yöntemlerin başlıca tercih sebebi hesaplama gereksinimlerinin az olmasıdır.

Tablo 4.11. Özellik benzerliği hesaplama süreleri


	Tek görüntü için	250 adet görüntü için
Kosinüs uzaklık benzerliği	~15 msn	2,52 sn
Öklit uzaklık benzerliği	< 2 msn	2,51 sn
Manhattan uzaklık benzerliği	< 2 msn	2,49 sn

Tablo 4.11’de özellik benzerliği hesaplama süreleri gösterilmektedir. Veri tabanında bulunan 250 adet görüntü özniteliği için yapılan hesaplamaların birbirine yakın sürelerde tamamlandığı görülmektedir. Tablo 4.12.’de farklı görüntülere ait hesaplanan benzerlik değerleri gösterilmektedir.

Tablo 4.12. Farklı görüntülere ait hesaplanan benzerlik değerleri

Görüntü Tanımı	Cosinüs uzaklık benzerliği	Eucludian uzaklık benzerliği	Manhattan uzaklık benzerliği
Görüntü Id=1425	68.59	26.3	70.6
Görüntü Id=1467	68.91	26.4	53.8
Görüntü Id=1475	69.56	26.4	52.6
Görüntü Id=1476	68.66	26.4	52.7
Görüntü Id=1489	68.75	26.4	52.2

Bölüm 2’de önerilen klasik içerik tabanlı görüntü erişim sistemindeki sorgu senaryosunda ilk olarak sorgu görüntüsünün öznitelikleri hesaplanır. Veritabanındaki her bir kayıt için sorgu görüntüsü ile olan benzerlik katsayıları hesaplanarak benzerlik sıralamaları oluşturulur. Her bir özellik grubu kendi içinde belirli bir ağırlık katsayısı ile oranlanarak filtrelenir. Bu şekilde belirli bir benzerlik seviyesinin altındaki görüntülerin elenmesi sağlanır. Son aşamada renk, doku ve şekil olmak üzere üç farklı grupta filtrelenen öznitelikler birleştirilerek özellik kesişim kümesinden benzer görüntüler elde edilir. Şekil 4.5.’te benzer görüntülerin veri tabanından getiriliş yöntemi görsel olarak gösterilmiştir.



Şekil 4.5. Veritabanındaki özneliliklerin sınıflandırılması

4.5. Derin Öğrenme Yöntemiyle Görüntü Benzerliklerinin Bulunması

Geleneksel yöntemler ile elde edilen sonuçların iyileştirilmesi amacıyla yapay sinir ağlarının kullanılması ve derin öğrenme yöntemi ile benzerlik oranlarının hesaplanması önerilmiştir. Derin öğrenme yönteminde ilk olarak evrimsel sinir ağı

modeli oluşturulmuştur. Oluşturulan ağ her biri ortalama 5000 medikal görüntüden oluşan 10 farklı kategorideki toplam 52669 medikal görüntü ile eğitilmiştir. Eğitilen evrişimsel sinir ağının doğruluk sınaması 10 farklı kategorideki 1000 görüntü üzerinden yapılmıştır. Oluşturulan derin öğrenme yönteminin son katmanına sınıflandırıcı eklenerek model çıktısı olarak tahmin sonuçları alınmıştır. Örnek bir sorgu görüntüsü için derin öğrenme yöntemi ile elde edilen tahmin bilgileri Tablo 4.13.'de verilmiştir. Bu tahmin bilgileri kullanılarak veri tabanındaki benzer görüntülerin geri getirilmesi sağlanabilecektir.

Tablo 4.13. Derin öğrenme yöntemi ile elde edilen tahmin bilgileri

Görüntü Tanımı	Benzerlik oranı (%)	Kategori Adı
Görüntü Id=993	0	1- Ultrason Neck
Görüntü Id=993	1.24	2-BloodCell
Görüntü Id=993	85.13	3-Brain
Görüntü Id=993	0	4-Breast Phatology
Görüntü Id=993	10.44	5-Chest
Görüntü Id=993	0	6-Colonoskaopi
Görüntü Id=993	0	7-Optical Coherence Tomography
Görüntü Id=993	0	8-Retina
Görüntü Id=993	3.19	9-Skin Cancer
Görüntü Id=993	0	10-Thyroid Cancer

Büyük veriler ile çalışırken hesaplama miktarını azaltmak ve doğruluk oranlarını yükseltmek için evrişimsel sinir ağı modeli önerilmiş ve ortalama %99.2 başarımlı oranı yakalanmıştır.

4.6. Geleneksel Yöntem ve Evrişimsel Sinir Ağları Performanslarının Karşılaştırılması

Geleneksel yöntemler ve evrişimsel sinir ağı ile elde edilen sonuçlar hassasiyet ve geri getirme oranları üzerinden karşılaştırılmıştır. İki yöntemin karşılaştırılması için her kategoride 100 adet olmak üzere 10 farklı kategoride toplam 1000 adetlik

veritabanı oluşturulmuştur. Yöntemlerin karşılaştırılması sonucu elde edilen hassasiyet ve geri getirme başarımları Tablo 4.14.'te verilmiştir.

Tablo 4.14. Geleneksel yöntem ve evrimsel sinir ağı ile elde edilen sonuçların karşılaştırılması

Görüntü Kategorisi	Geleneksel Yöntemler		Evrimsel Sinir Ağı	
	Hassasiyet	Geri Getirme	Hassasiyet	Geri Getirme
1- Boyun ultrasonu	% 78	% 66	% 99.99	% 100
2- Kan hücresi	%63	% 51	% 99.51	% 100
3- Beyin MRI	% 66	% 58	% 95.73	% 97
4- Göğüs patalojisi	% 53	% 59	% 96.44	% 100
5- Akciğer röntgen filmi	% 54	% 46	% 98.39	% 99
6- Kolonoskopi MRI	% 86	% 82	% 100	% 100
7- Optik koherens tomografisi	%58	% 63	% 97.75	% 99
8- Optik retina görüntüsü	%85	% 59	% 99.99	% 100
9- Cilt kanseri	%80	% 63	% 93.94	% 94
10- Tiroid kanseri	% 82	% 76	% 99.95	% 100
Ortalama Değer	% 70.5	% 62.3	% 98.16	%98

Medikal görüntülerin bir kısmını gri tonlamalı görüntülerin oluşturması ve bilgisayarlı işlem gereksinimlerinin azaltılması amacıyla gri tonlamalı görüntüler üzerinden çalışma yönteminin tercih edilmesi renk özneliklerinin yeterli sayıda ve özgünlükte çıkarılamamasına sebep olmuştur. Medikal görüntülerde keskin renk geçişlerinin olmaması da öznelik çıkarımlarını zorlaştırmıştır. Bahsedilen kısıtlamalardan dolayı geleneksel yöntemlerin kullanıldığı geri getirme yönteminde yüksek başarı oranları yakalanamamıştır. Geleneksel yöntemlerin kullanıldığı medikal görüntüler üzerinden hesaplanan özneliklerin birbirine yakın değerlerde olduğu görülmüştür. Ayırt ediciliği yüksek olmayan bu öznelikler üzerinden ortalama %62 doğruluk ve %70.5 hassasiyet oranları hesaplanmıştır. Renk, doku ve şekil özneliklerinin çıkarılmasında pikseller üzerinden çok sayıda aritmetik işlem yapılmasının fazla hesaplama gerektirdiği ve sorgu sürelerini uzattığı görülmüştür. Geleneksel yöntem ile öznelik çıkarımının yüksek bilgisayarlı hesaplama ihtiyacı gerektirmesinden dolayı son kullanıcı bilgisayarlarında verimli bir şekilde gerçekleştirilemeyeceği değerlendirilmiştir. Evrimsel sinir ağlarının kullanıldığı

diğer yöntemde sorgu sürelerinin kısa ve başarımlarının yüksek olduğu gösterilmiştir. Derin öğrenme yönteminin kullanıldığı evrimsel sinir ağlarında model iyi eğitildiği takdirde yüksek başarımlar yakalanarak geleneksel yöntemlerin olumsuz yönleri giderilebilecektir. CNN mimarisinde sistemin eğitimi uzun sürmesine rağmen bu işlemin tek seferde ve sunucu üzerinde yapılacak olması bu olumsuzluğu ortadan kaldırmaktadır. Derin öğrenme yöntemi ile yapılan çalışmada model eğitiminde %99.2 doğru görüntü getirme başarımları yakalanmıştır.

Önerilen sistem bu haliyle sorgulama yapılan görüntünün içeriğine göre benzer görüntüleri kullanıcıya sunabilecektir. Hastalık tanısı ve doktor yorumları gibi değerli bilgilerin sisteme dahil edilerek görüntüler ile eşleştirilmesi durumunda hastalık teşhisinde otomasyon yapısı oluşturulabilir, medikal görüntüleme alanındaki tecrübelerin hızlı bir şekilde paylaşılması sağlanabilir.

KAYNAKLAR

- [1] S., Singh, A., Saini, S., Sharma, Evaluation of Feature Extraction Techniques in Content Based Image Retrieval (CBIR) System, IJECT, 2013.
- [2] R., Datta, D., Joshi, J., Li, J., V., Wang, Image retrieval: Ideas, influences and trends of the new age, ACM Computing Surveys, Nisan 2008.
- [3] S., Kaur, P., Verma, CBIR: Integration of Neural Networks Using Speed-Up Robust Feature and SVM, International Journal of Computer Science and Information Technologies, 2015.
- [4] J., Shukla, J., Vania A Survey on CBIR Features Extraction Techniques, International Journal Of Engineering And Computer Science, 2014.
- [5] M., J., Swain, D., H., Ballard, Indexing Via Color Histograms, Department of Computer Science University of Rochester, IEEE xplore, 2009.
- [6] J., L., Shih, L., H., Chen, Color Image Retrieval Based on Primitives of Color Moments, , Department of Computer and Information Science, National Chiao Tung University.
- [7] D., Gadkari, Image quality analysis using GLCM, Master of thesis, University of Pune, 2000.
- [8] B., S., Manjunath, W., Y., Ma, Texture Features for Browsing and Retrieval of Image Data, IEEE transactions on pattern analysis and machine intelligence, 1996.
- [9] A., Amanatiadis, V., G., Kaburlasos, A., Gasteratos, S., E., Papadakis, Evaluation of Shape Descriptors for Shape-Based Image Retrieval, IET image processing.
- [10] M., Yang, K., Kpalma, J., Ronsin, A Survey of Shape Feature Extraction Techniques, Pattern Recognition, IN-TECH, 43-90, 2008.

- [11] M., N., Patel, P., Tandel, A Survey on Feature Extraction Techniques for Shape based Object Recognition, International journal of computer applications, 2016.
- [12] S., Loncaric, A Survey of Shape Analysis Techniques Faculty of Electrical Engineering and Computing, University of Zagreb.
- [13] Y., LeCun, L., Bottou, Y., Bengio, P., Haffner, Gradient Based Learning Applied to Document Recognition, IEEE, 1998.
- [14] J., Wan, D., Wang, S., C. H. Hoi, P., Wu, J., Zhu, Deep Learning for Content Based Image Retrieval: A Comprehensive Study, Institutional Knowledge at Singapore Management University, 2014.
- [15] A., Krizhevsky, I., Sutskever, G., E. Hinton, ImageNet Classification with Deep Convolutional Neural Networks, ImageNet LSVRC, 2010.
- [16] K., Simonyan, A., Zisserman, Very Deep Convolutional Neural Networks for Large Scale Image Recognition, ICLR, 2015.
- [17] Y., Bar, I., Diamant, L., Wolf, H., Greenspan, Deep Learning With Non-Medical Training Used With Chest Pathology Identification, Department of Biomedical Engineering, Tel-Aviv University, 2015.
- [18] G., E. Hinton, R., R. Salakhutdinov, Reducing the Dimensionality of Data with Neural Networks, Science Magazine, Vol 313, 2006.
- [19] Y., A. Chung, W., H. Weng, Learning Deep Representations of Medical Images using Siamese CNNs with Application to Content-Based Image Retrievals, Conference on Neural Information Processing Systems, 2017.
- [20] U., K. Lopes, J., F. Valiati, Pre-Trained Convolutional Neural Networks as Feature Extractors for Tuberculosis Detection, Computers in Biology and Medicine, 2017.
- [21] F., Perronnin, D., Larlus, Fisher Vectors Meet Neural Networks: A Hybrid Classification Architecture, IEEE Xplore, 2015.
- [22] S., Renukalatha, K., V. Suresh, Automatic ROI Extraction In Noisy Medical Images, ICTACT Journal On Image and Video Processing, 2017.
- [23] S.M., Singh, K., Hemachandran, Image Retrieval based on the Combination of Color Histogram and Color Moment, International journal of computer applications, 2012.

- [24] H., L., Sneha, Pixel intensity histogram characteristics: basics of image processing and machine vision, allaboutcircuits.com/technical-articles, 2017.
- [25] U., Marmol, Use of gabor filters for texture classification of airborne images and lidar data, *Archives of Photogrammetry, Cartography and Remote Sensing*, 2011.
- [26] B., Pathak, D., Barooah, Texture analysis based on the GLCM considering possible orientations, *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, 2013.
- [27] N., Arica, Shape: representation, description, similarity and recognition, thesis of the Middle East Technical University, 2003.
- [28] S., H., Cha, Comprehensive Survey on Distance/Similarity Measures between Probability Density Functions, *International journal of mathematical models and methods in applied sciences*, 2007.
- [29] W., K., Kong, D., Zang, W., Li, Palmprint Feature Extraction Using 2-D Gabor Filters, Biometrics Research Centre Department of Computing, The Hong Kong Polytechnic University.
- [30] Convolutional Neural Networks for Visual Recognition, Stanford University Course Syllabus, 2019.
- [31] Y., LeCun, Y., Bengio, Convolutional Networks for Images, Speech and Time Series, AT&T Bell Laboratories, 1998.

ÖZGEÇMİŞ

Yusuf Öztürk, 01.09.1986'da Sakarya'da doğdu. İlk, orta ve lise eğitimini Kocaeli'nde tamamladı. 2005 yılında Kocaeli Sabancı Anadolu Teknik Lisesi'nden mezun oldu. 2007 yılında Kocaeli Üniversitesi Gebze Meslek Yüksek Okulu Endüstriyel Elektronik bölümünden mezun oldu. 2007 yılında başladığı Gebze Yüksek Teknoloji Enstitüsü Elektronik Mühendisliği Bölümü'nü 2012 yılında bitirdi. 2014 yılında Sakarya Üniversitesi Elektronik Mühendisliği Bölümü'nde yüksek lisans eğitimine başladı. 2012 yılında başladığı aktif çalışma hayatına telekomünikasyon ve haberleşme sektöründe devam etmektedir.