

**MEDİKAL GÖRÜNTÜLERDEKİ DARBE GÜRÜLTÜSÜNÜN
MAKİNE ÖĞRENME TEKNİKLERİ İLE GİDERİLMESİ**

Yük. Müh. Cafer BUDAK

**Doktora Tezi
Elektrik-Elektronik Mühendisliği Anabilim Dalı
Doç. Dr. Mustafa TÜRK (F. Ü.)
KASIM-2014**

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

**MEDİKAL GÖRÜNTÜLERDEKİ DARBE GÜRÜLTÜSÜNÜN MAKİNE
ÖĞRENME TEKNİKLERİ İLE GİDERİLMESİ**

DOKTORA TEZİ

Yük. Müh. Cafer BUDAK

(091113202)

**Tezin Enstitüye Verildiği Tarih: 03 Kasım 2014
Tezin Savunulduğu Tarih: 28 Kasım 2014**

Tez Danışmanı: Doç. Dr. Mustafa TÜRK (F. Ü.)
Diğer Jüri Üyeleri: Doç. Dr. Necmettin SEZGİN (B.Ü.)
Doç. Dr. Servet TUNCER (F. Ü.)
Doç. Dr. Arif GÜLTEN (F. Ü.)
Doç. Dr. Bilal ALATAŞ (F. Ü.)

KASIM-2014

ÖNSÖZ

Bu tez çalışmasında darbe gürültüsünü yok etmekte kullanılan filtrelerin, imgelerdeki gürültüyü giderirken sebep oldukları bozucu etkileri en aza indirmek amacıyla yeni yöntemler sunulmaktadır. Önerilen yöntemler, makine öğrenme yöntemlerinden olan yapay sinir ağları ve Naïve Bayes sınıflandırıcıdan oluşmaktadır. Önerilen yöntemlerin başarısı, farklı test imgeleri üzerinde farklı filtreler ile gerçekleştirilen imge filtreleme deneyleri aracılığıyla değerlendirilmiştir.

Deneyisel sonuçlar, önerilen yöntemlerin darbe gürültüsü giderici imge filtrelerinin başarılarının artırılmasında ve bozucu etkilerinin azaltılmasında son derece etkin bir şekilde kullanılabileceğini göstermektedir.

Bu çalışmanın başlatılması, geliştirilmesi ve tamamlanmasında gerekli sabrı, rehberliği, tavsiyeleri ve desteğini esirgemeyen değerli danışmanım Sayın Doç. Dr. Mustafa TÜRK'e teşekkürlerimi sunarım.

Tez çalışmalarımda değerli fikirleriyle bana her aşamada yol gösteren Doç. Dr. Abdullah TOPRAK'a teşekkür ederim. Yine tez süresince yardımlarını gördüğüm Yrd. Doç. Dr. Faruk ERKEN ve burada adını saymadığım tüm arkadaşlarıma teşekkür ederim.

Doktora eğitimim sırasında gösterdiği sürekli sabır, sevgi ve özverisiyle her zaman yanımda olan beni her konuda destekleyen aileme teşekkür ederim.

Cafer BUDAK

Elazığ-2014

İÇİNDEKİLER

	Sayfa No
ÖNSÖZ	I
İÇİNDEKİLER.....	II
ÖZET	V
SUMMARY.....	VI
ŞEKİLLER LİSTESİ.....	VII
SEMBOLLER LİSTESİ	XII
KISALTMALAR LİSTESİ	XIII
1. GİRİŞ.....	1
1.1 Genel Bilgiler.....	1
1.2 Tezin Amacı.....	3
1.3 Tezin İçeriği.....	3
1.4 Literatür Taraması.....	4
2. İMGE İŞLEME.....	8
2.1 İmge İşleme ve İyileştirme Teknikleri	10
2.1.1 İki Boyutlu İmgenin Tanımı	10
2.1.2 Siyah Beyaz İmgenin Matematiksel Olarak Modellenmesi.....	12
2.1.3 Bir İmgenin Sayısal Hale Dönüştürülmesi	13
2.1.4 Renk Ölçeği.....	15
2.1.5 Sayısal İmgelerin Matris Olarak Gösterilmesi.....	16
2.1.6 Uzaysal Çözünürlük ve Gri Seviyesi.....	18
2.2 Sayısal İmge Çeşitleri.....	20
2.2.1 İkili (Binary) İmgeler	20
2.2.2 Yoğunluk İmgeleri (Grayscale İmge).....	20
2.2.3 Gerçek Renk (True Color - RGB) İmgeleri	21
2.2.4 İndeksli (Etiketli) İmgeler.....	22
2.3 İmge İyileştirmede Genel Bilgiler.....	24
2.4 Uzaysal Düzlemde İyileştirme Teknikleri	25
2.4.1 Piksel Bazında İmge İşlemleri	26
2.4.2 Doğrusal ve Doğrusal Olmayan İşlemler	27
2.4.3 İmgede Kompanzasyon	27
2.4.4 Dinamik Aralık değiştirilerek Yapılan İmge İyileştirme.....	28

2.4.5	İmgede Histogram Eşitlemesi	28
2.4.6	Lokal Operatör Kullanarak İmge İyileştirme	30
2.4.7	Gri Seviye Dönüşümleri Yapararak İmge İyileştirme	30
2.4.8	İmgenin Tümleyenini Alarak Görüntü İyileştirme	31
2.4.9	Kontrast Arttırma Dönüşümü ile İmge İyileştirme	33
2.5	Temel İmge Operatörleri	34
2.5.1	İmge Kaydırma:	34
2.5.2	İmge Kesme (Parça çıkarma):	35
2.5.3	İmge Aynalama	35
2.5.4	İmge Döndürme	37
2.5.5	Kenar Çıkarma	38
2.5.6	Sobel Kenar Çıkarıcı	39
3.	İMGEDE OLUŞAN GÜRÜLTÜLER	42
3.1	İmgelerde Doğal Yollarla Oluşan Gürültü Çeşitleri	42
3.1.1	Darbe Gürültüsü	43
3.2	İki Aşamalı Uyarlamalı Hızlı Medyan Filtre (DCFAMF)	44
3.3	Rastgele Değerli Darbe Gürültüsü Belirleme Süreci	45
3.4	Geliştirilmiş İki Aşamalı Uyarlamalı Hızlı Medyan Filtresi Kullanılarak Tıbbi İmgelerdeki Darbe Gürültüsünün Bastırılması	46
3.4.1	Simülasyon Sonuçları	48
3.4.2	Histogram Dağılımı	53
4.	YAPAY SİNİR AĞLARI İLE İMGENİN İŞLENMESİ	55
4.1	Yapay Sinir Ağları	55
4.1.1	Yapay Sinir Ağlarının Genel Özellikleri	57
4.1.2	Yapay Sinir Ağlarının Kullanıldığı Alanlar	59
4.1.3	Çok Katmanlı Algılayıcı (MLP) Yapısı	60
4.1.4	Aktivasyon Fonksiyonu	61
4.1.5	Doğrusal Aktivasyon Fonksiyon	62
4.1.6	Ara Katman Sayısı ve Proses Elemanlarının Sayısının Belirlenmesi	62
4.2	Yapay Sinir Ağından Filtre Oluşturulması	63
4.2.1	Yapay Sinir Ağının Eğitilmesi	64
4.2.2	Uyarlamalı Yapay Sinir Ağ Mimarisi	64
4.3	DeneySEL Sonuçlar ve Simülasyon Analizi	67

5.	OLASILIK VE BAYES YAKLAŞIMI.....	74
5.1	Olasılık ve Belirsizlik.....	74
5.1.1	Olasılığın Mühendislikteki Uygulamaları	75
5.2	Bayes Yaklaşımı ve Bayes Ağları.....	75
5.2.1	Temel Bilgiler	75
5.2.2	Bayes Teoremi	76
5.2.3	Bayes Yaklaşımın Matematiksel İfadesi	77
5.3	Önsel ve Sonsal Dağılımlar	81
5.3.1	Önsel Bilgi.....	82
5.3.2	Sonsal Bilgi.....	82
5.3.3	Önsel Dağılımın Seçimi	82
5.4	Bayes Yaklaşımı ile Klasik Yaklaşım Arasındaki Farklılıklar	83
5.5	Bayes Yaklaşımının Avantajları ve Dezavantajları.....	84
5.5.1	Birleşik Olasılık Dağılımı.....	85
5.5.2	Bayes Ağlarının Oluşturulması.....	85
5.5.3	Bayes Ağ Modellerinde Öğrenme.....	86
5.6	Uygulama Alanları	86
5.7	Naïve Bayes Sınıflandırıcı	86
5.7.1	Naïve Bayes Olasılık Modeli	87
5.8	Naïve Bayes Sınıflandırıcının Filtre Olarak Kullanılması.....	89
5.9	Deneysel Sonuçlar ve Simülasyon Analizi	92
6.	SONUÇLAR VE ÖNERİLER.....	99
6.1	Sonuçlar.....	99
6.2	Öneriler	100
	KAYNAKLAR	101
	ÖZGEÇMİŞ	107

ÖZET

İdeal bir filtrenin sayısal imgedeki ayrıntıları korurken, darbe gürültüsünü etkili biçimde yok etmesi istenmektedir. Standart sinyal işlemenin talebi, resmin detaylarına zarar vermeden darbe gürültüsünün yok edilmesidir.

Birinci bölümde, medyan tabanlı yeni bir filtre sunulmuştur. Bu metot anahtarlama medyan ile uyarlamalı medyan filtrenin hibrit halinden meydana gelmiştir. Sunulan filtre “İki Aşamalı Uyarlamalı Hızlı Medyan Filtre” (DCFAMF) olarak adlandırılmıştır.

DCFAMF, geleneksel filtrelerle kıyaslandığında yapı olarak daha basit, daha hızlı ve aynı zamanda daha iyi sonuçlar vermektedir. Bu metot darbe gürültüsünü yok etmenin yanında (aşırı bozulmuş imgelerde bile), imgenin detaylarını başarılı bir şekilde korumuştur. DCFAMF için herhangi bir parametre ayarlamasına gerek yoktur. Bu yüzden otomatik sistemlere daha uygun olup herhangi bir ön hazırlığa ihtiyaç duymamaktadır.

Ayrıca, aşırı bozulmuş imgeleri iyileştirmek için uyarlamalı bir yapay sinir ağı modeli geliştirilmiştir. Farklı gürültü yoğunluklarında eğitilmiş olan ağlar, gürültünün yoğunluğuna göre, gürültülü piksel yerine gelebilecek en uygun komşu pikseli tahmin etmektedir. Önerilen algoritma sayısal imgelerdeki darbe gürültüsünü etkili biçimde yok ederken, aynı zamanda detayları da korumaktadır.

Sayısal imgelerdeki darbe gürültüsünü yok etmek amacıyla filtre olarak Naïve Bayes sınıflandırıcı önerilmiştir. Burada kullanılan haliyle gürültü bulaşmış imge onarılmaya başlamadan önce, imge birden fazla parçaya ayrılmakta ve bu parçalarda gürültü bulaşmamış piksellerden bir öğrenme seti oluşturulmaktadır. Bozuk pikselin yerine geçecek olan pikseli tahmin etmek için, bu öğrenme seti kullanılmaktadır. Sunulan yöntem hem basit hem de uygulanması daha kolaydır.

Anahtar kelimeler: Darbe gürültüsü, İmge iyileştirme, Makine öğrenmesi, Naïve Bayes sınıflandırıcı, Yapay sinir ağları, Medyan tabanlı filtreler.

SUMMARY

Removal of Impulse Noise in Medical Images with Machine Learning Techniques

It is desired that an ideal filter preserves the details in the digital image while effectively removing impulse noise. The objective of standard signal processing is the elimination of impulse noise without harming details of the image.

In part 1, we propose a new Median-Based Method: Switching Median Filter with a hybrid of adaptive median filter combination. Hereon, the proposed filter will be named as “Double Checked Fast Adaptive Median Filter” (DCFAMF). DCFAMF gives faster, simpler and better results in comparison with the traditional Median-Based Filters. This method can get rid of impulse noise. Moreover, it can keep the necessary details of the image (this is also true when the input image is very badly ruined by noise). No adjustments are needed for DCFAMF. Thus, it is much more suitable for automated systems. We do not need a pre-preparation for this technique.

Besides, an adaptive artificial neural network model is developed in order to restore severely corrupted images. Networks trained at different noise intensities get activated according to intensity of the noise and estimate the most suitable neighboring pixel that can replace the noisy pixel. The proposed algorithm reduces impulse noise effectively while also protecting the details.

Naïve Bayes classifier filter for the removal of random impulse noise in digital grayscale image is recommended. It has especially been used more frequently in recent times in the field of signal processing. Prior to restoring the noisy pixels of the image as is used here, the image is separated into more than one piece, and a learning set is formed using the noise free pixels in these pieces. These learning sets that are different for each piece are used in order to estimate the pixel that will replace the noisy one. The presented method is both simple and easy to apply.

Keywords: Impulse noise, Image restoration, Machine learning, Naïve Bayes classifier, Artificial neural network, Median based filters

ŞEKİLLER LİSTESİ

Sayfa No

Şekil 1.1 İmge iyileştirme literatüründe sıklıkla karşılaştırmada kullanılan ‘Lena’ imgesi; a) Orijinal imge, b) %30 Darbe gürültüsüne maruz kalmış imge	3
Şekil 2.1 Ayın ilk fotoğrafı (31 Temmuz 1964). “Ranger 7” tarafından Ay ile çarpışmadan 17 dakika önce çekilmiştir	9
Şekil 2.2 Bir imgenin x ve y koordinatları boyunca almış olduğu gri değerleri gösteren matris formu	11
Şekil 2.3 Tek boyutlu ve iki boyutlu dizilerin matris görünümü ve grafikleri; a) Tek boyutlu matris, b) İki boyutlu matris	12
Şekil 2.4 Bir sayısal imgenin üretimi; a) Sürekli imge, b) A dan B' ’ye tarama çizgisi, sürekli imge, örnekleme ve nicelendirmenin kavramlarını göstermek için kullanılmıştır, c) Örnekleme ve nicelendirme, d) Sayısal tarama çizgisi	14
Şekil 2.5 Örnekleme ve nicelendirme; a) Sürekli görüntü, b) Sayısal hale getirilmiş görüntü	15
Şekil 2.6 Renk ölçeği; a) Gri ölçek, b) Renkli ölçek	15
Şekil 2.7 Sayısal imgeleri temsil etmek için kullanılan koordinat sistemi	16
Şekil 2.8 1024 x 1024, 8 bit bir imge 32 x 32 piksel boyuta alt örnekle küçültülmüş durumu	18
Şekil 2.9 Bir imgenin farklı çözünürlükteki versiyonları	19
Şekil 2.10 İkili bir imge ve piksel değerleri	20
Şekil 2.11 Bir yoğunluk imgesi ve piksel değerleri	21
Şekil 2.12 Gerçek bir renkli imge	22
Şekil 2.13 İndeksli renkli imge	23
Şekil 2.14 Standart renk küpü	23
Şekil 2.15 3 x 3 Bir imge içindeki nokta hakkında (x,y) komşu alan	24
Şekil 2.16 Kontrastın daha iyi hale getirilmesi için gri seviye dönüşüm fonksiyonları	25

Şekil 2.17 Histogram eşitlemesinden önceki imge ve histogramı	29
Şekil 2.18 Histogram eşitlemesi yapılmış imge ve histogramı	30
Şekil 2.19 Negatif alma işlemi	31
Şekil 2.20 İmge iyileştirmede kullanılan bazı basit dönüşüm fonksiyonları	32
Şekil 2.21 a) Orijinal sayısal mamogram b) Eş (2.24)'deki negatif dönüşümü kullanarak elde edilen negatif imge (G.E. Tıbbi sistemleri tarafından temin edilmiştir)	32
Şekil 2.22 Kontrast arttırmanın imge üzerinde oluşturduğu değişiklikler; a) Dönüşüm fonksiyonunun şekli, b) Düşük kontrastlı bir imge, c) Kontrastı arttırılmış imge, d) Eşiklenmiş imge	34
Şekil 2.23 İmge kaydırma; a) Orijinal imge, b) r_0 kadar sağa, c_0 kadar yukarı kaydırılmış imge	35
Şekil 2.24 İmgeden parça çıkarma; a) Orijinal imge, b) Parça çıkarma işlemi	35
Şekil 2.25 İmge aynalama işlemleri	36
Şekil 2.26 İmge döndürme; a) Orijinal imge, b) 90° döndürülmüş imge	37
Şekil 2.27 Sobel kenar çıkarmında konvolüsyon işlemi	40
Şekil 2.28 Sobel Gradienti kullanılarak gerçekleştirilen kenar bulma operasyonu	41
Şekil 3.1 İncelenen piksel yoğunluğu ve 3×3 penceredeki koordinatları	45
Şekil 3.2 Bazı filtrelerin iyileştirme sonuçları; a) Orijinal imge, b) Gürültülü imge, c) IDBA çıkışı, d) BDND çıkışı, e) CWMF çıkışı, f) AMF çıkışı, g) SMFAMF çıkışı, h) SNFF çıkışı, i) DCFAMF çıkışı	49
Şekil 3.3 Farklı filtrelerin çıkışının grafiksel gösterimi; a) PSNR (dB), b) MSE	51
Şekil 3.4 Beyin MR imgesinin %10-%90 arasındaki gürültü yoğunluğundaki görsel performansı	53
Şekil 3.5 Histogram dağılımı; a) Orijinal imgenin histogramı, b) Gürültü eklendikten sonraki histogramı, c) İyileştirilmiş resmin histogramı	54
Şekil 4.1 Biyolojik sinir sisteminin blok diyagramı	56
Şekil 4.2 Çok katmanlı yapay sinir ağ mimarisi	60

Şekil 4.3 Çok katmanlı yapay sinir ağı nöron yapısı ve aktivasyon fonksiyonun yeri.....	62
Şekil 4.4 Doğrusal Aktivasyon fonksiyonu.....	62
Şekil 4.5 Önerilen filtrenin genel şeması	64
Şekil 4.6 Ağın eğitimi	65
Şekil 4.7 Farklı gürültü yoğunluklarında eğitilmiş ağların birbirine göre karşılaştırılması	65
Şekil 4.8 ANNM'in akış şeması	66
Şekil 4.9 Network-1'in mimarisi	67
Şekil 4.10 Farklı filtrelerin grafiksel performansı;	
a) PSNR (dB), b) MSE	69
Şekil 4.11 Göğüs radyografi imgesinin farklı filtrelerin imge iyileştirme sonuçları sırasıyla %60 ve %90;	
a) Orijinal imge, b) bozulmuş imge, c) OCS çıkışı, d) IDBA çıkışı, e) TLIDE çıkışı, f) AMF çıkışı, g) CWMF çıkışı, h) DBA çıkışı, i) ANNM çıkışı.....	71
Şekil 4.12 Damar radyografi imgesinin farklı filtrelerin imge iyileştirme sonuçları sırasıyla %60 ve %90;	
a) Orijinal imge, b) bozulmuş imge, c) OCS çıkışı, d) IDBA çıkışı, e) TLIDE çıkışı, f) AMF çıkışı, g) CWMF çıkışı, h) DBA çıkışı, i) ANNM çıkışı.....	73
Şekil 5.1 Sınıflandırma görevinin görselleştirilmesi	89
Şekil 5.2 Eğitim setlerini oluşturmak için resmin parçalara ayrılması;	
a) Bozulmuş imge, b) parçalara ayrılmış imge	90
Şekil 5.3 Bozulmuş Beyin MR'ına ait rastgele bir kesit görülmektedir	91
Şekil 5.4 %40 gürültü eklenmiş Beyin MR imgesinin farklı filtreler ile imge iyileştirme sonuçları;	
a) Orijinal imge b) Bozulmuş imge, c) DBA filtre çıkışı, d) NFT filtre çıkışı, e) IDBA filtre çıkışı, f) CWMF filtre çıkışı g) AMF filtre çıkışı, h) DBSMF filtre çıkışı, i) SNFF filtre çıkışı, j) TLIDE filtre çıkışı, k) NBCF çıkışı.....	94
Şekil 5.5 Lena bmp. İmgesine ait farklı filtreler için PSNR (dB) değerleri.....	95
Şekil 5.6 Lena bmp. İmgesine ait farklı filtreler için PSNR (dB) değerleri.....	96
Şekil 5.7 Lena bmp. İmgesine ait farklı filtreler için MSE değerleri	96
Şekil 5.8 Lena bmp. İmgesine ait farklı filtreler için MSE değerleri	97

Şekil 5.9 %60 Gürültü eklenmiş Lena imgesinin farklı filtreler ile imge iyileştirme

sonuçları;

a) Orjinal imge b)Bozulmuş imge, c) DBA filtre çıkışı, d) NFT filtre çıkışı, e)
IDBA filtre çıkışı, f) CWMF filtre çıkışı g) AMF filtre çıkışı, h) DBSMF filtre
çıkışı, i) SNFF filtre çıkışı, j) TLIDE filtre çıkışı, k) NBCF çıkışı 98

TABLÖLAR LİSTESİ

Sayfa No

Tablo 2.1 Farklı N ve k değerleri için saklama bit sayısı	18
Tablo 3.1 MR imgesinin farklı gürültü yoğunluklarında çeşitli filtrelerin PSNR ve MSE değerleri ile karşılaştırılması	50
Tablo 4.1 ‘Göğüs radyografi’ test imgesinin iyileştirme sonuçlarının PSNR (db) ve MSE karşılaştırılması	68
Tablo 5.1 Örnek küme nitelikleri.....	79
Tablo 5.2 Örnekte kullanılan veri kümesine ait olasılıklar	80
Tablo 5.3 Parça-1’deki öğrenme setine ait bir örnek.....	90
Tablo 5.4 Tablo 5.3 kullanılarak Eğitim seti-1’in yoğunluk değerlerinin oluşturulması ...	91
Tablo 5.5 x vektör elemanlarının hesaplanmış olasılık değerleri.....	92
Tablo 5.6 Beyin MR test imgesinin iyileştirme sonuçlarının PSNR (db) ve MSE karşılaştırılması	93
Tablo 5.7 Lena.bmp test imgesinin iyileştirme sonuçlarının PSNR (db) ve MSE karşılaştırılması	95

SEMBOLLER LİSTESİ

f	Sayısal imge
x, y	Düzlemsel koordinatları
L	Renk ölçeğinin boyutu
L_{min}	Minimum renk ölçeğinin boyutu
L_{max}	Maksimum renk ölçeğinin boyutu
M	Sayısal bir imgedeki satır sayısı
N	Sayısal bir imgedeki sütun sayısı
θ	Döndürme açısı
p	Gürültülü pikselin gelme olasılığı
$n_{i,j}$	Gürültü
$O_{i,j}$	Orijinal imge
$U_{i,j}$	Gürültülü imge
r	Orijinal imge
x	İyileştirilmiş imge
s	Noktanın negatif renk değeri
r	Noktanın renk değeri
T	Threshold
A	A olayının bağımsız olasılığı
B	B olayının bağımsız olasılığı

KISALTMALAR LİSTESİ

RGB	: Kırmızı, Yeşil, Mavi
CMY	: Yeşile çalan mavi, morumsu kırmızı, sarı
HIS	: Renk tonu, canlılık, yoğunluk
MRI	: Manyetik Rezonans Görüntüleme
CT	: Computed Tomography- Bilgisayarlı Tomografi
AMF	: Uyarlamalı Medyan Filtre
SMF	: Standart medyan Filtre
DWM	: Yönlü Ağırlıklı Medyan
OCS	: Open-close sequence filter
IDBA	: Geliştirilmiş Karar Tabanlı Algoritma
TLIDE	: Triangular-based linear interpolation with differential evolution
DBA	: Karar Tabanlı Algoritma
CWME	: Merkez-uyarlamalı Ağırlıklı Medyan Filtre
DCFAMF	: İki Aşamalı Uyarlamalı Hızlı Medyan Filtre
PSNR	: Peak Signal to Noise Ratio
MSE	: Mean Squared Error
ANNM	: Uyarlamalı Yapay Sinir Ağı
YSA	: Yapay sinir ağları
MLP	: Çok katmanlı algılayıcı
LM	: Levenberg-Marquardt
NBCF	: Naïve Bayes sınıflandırıcı Filtre
CRT	: Katot ışınli t�p
Na�ve	: Yalın
KOT	: Koşullu Olasılık Tablosu
K	: Boltzmann sabiti
T	: Sıcaklık
C	: Kapasite

1. GİRİŞ

1.1. Genel Bilgiler

Günümüzde ucuzlayan bilgi işlem maliyetleri, yüksek işlem gücü gerektiren imge işleme yöntem ve tekniklerinin bilim ve teknolojinin birçok alanında kullanılmasına yol açmıştır. Bilgisayar boyutlarının giderek küçülmesi, bellek kapasitelerinin ve veri işleme hızlarının artışı, imge işleme teknolojilerindeki gelişmeyi hızlandırmıştır. Sayısal görüntüleme teknolojisindeki hızlı gelişme ve bunun sonucunda ortaya çıkan maliyet düşüşleri, bu sistemlerin yaygınlaşmasına ve mevcut sistemlerin yerini almasına ayrıca katkıda bulunmaktadır. Bugün, başta tıp bilimleri, havacılık ve uzay bilimleri, malzeme bilimi vb. bilim alanları olmak üzere, birçok bilim ve teknoloji alanının sayısal görüntüleme teknolojileri olmaksızın düşünülmesi mümkün değildir. Sayısal görüntüleme sistemleri aracılığıyla elde edilen sayısal imgeler, imgenin elde edildiği sistem ya da süreç hakkında önemli bilgiler verir. Bu bilgiler sistemin karakterize edilmesinde veya bu sistemle ilgili bir takım problemlerin çözümünde önemli rol oynar.

Ancak birçok uygulamada, imgeleri üreten sayısal görüntüleme sisteminin ya da imgenin elde edilmesi/aktarılması esnasında kullanılan ortamın ideal olmaması sebebiyle sayısal imgeler çeşitli bozulmalara maruz kalır. Bu bozulmalar alınan imge üzerinde daha sonra gerçekleştirilecek olan kenar sezme, sınır belirleme, bölütleme, nesne tanıma, tanı ve teşhis vb. gibi daha üst düzey imge işleme işlemlerinin başarısını olumsuz yönde etkilemektedir. Bu sebeple elde edilen imgeden en iyi şekilde yararlanılabilmesi ve en fazla bilginin elde edilebilmesi için, imgedeki bozulmaların giderilmesi son derece önemlidir. İmge işleme tabanlı uygulamalarda karşılaşılan bozulmaların en önemlilerinden biri darbe gürültüsüdür.

Gürültü istenmeyen bilginin sayısal resme bulaşmasıdır. Darbe gürültüsü her yerde bulunabilen gürültünün özel bir çeşidi olup bunun birçok kaynağı olabilir. Darbe gürültüsü iki sınıfta incelenir. Birincisi; genellikle imgenin dinamik aralığı içinde minimum ya da maksimum değerleri alır (0 ya da 255) bu yüzden tuz ve biber gürültüsü olarak da adlandırılır. Maksimum ve minimum değerler aldığı için darbe gürültüsü imge üzerinde siyah veya beyaz olarak görünür. İkincisi; imgenin orijinal değerleri ile aynı aralıkta olup [0-255] herhangi bir değer alabilir, buna da rastgele değerli darbe gürültüsü denir [1]. İmge

içerisindeki gürültülü pikselleri belirleyip bunları da uygun piksel değerleri ile değiştirmek imge işlemenin hala önemli sorunlarından biridir. İmgelerdeki darbe gürültüsü bastırılırken detaylar ve iki bölge arasında sınır bölgelerin birbirine karışmaması oldukça önemlidir.

Darbe gürültüsü, imgeyi gürültü şiddetine bağlı olarak imge içerisindeki belli sayıda pikselin yoğunluk değerini rastgele değerler ile değiştirme şeklinde bozmaktadır. Bu şekilde bir bozulmanın olumsuz tarafı, bozulan piksellerin orijinal yoğunluk değerlerinin geri elde edilemeyecek şekilde kaybolmasıdır. Olumlu tarafı ise imge içerisinde halen belli miktarda bozulmamış, yani orijinal yoğunluk değerini koruyan piksel olmasıdır. Darbe gürültüsünün bu karakteristik özelliği sebebiyle darbe gürültüsü giderici imge filtreleri bozulan pikselleri onarken yakındaki bozulmayan piksellerin yoğunluk bilgisinden yararlanır [2].

Sayısal imgelerden darbe gürültüsünü gidermek için kullanılabilecek çok sayıda yöntem mevcuttur. Bu yöntemlerin çoğu medyan tabanlı filtrelere dayanmaktadır. Bu filtreleme yaklaşımında; filtrede kullanılan pencereleme ile içerisinde yer alan piksellerden belli bir kritere göre seçilen piksel filtre çıkışına aktarılmaktadır. Bu filtrelerin yapıları ve çalışma şekilleri oldukça benzer olup aralarındaki en temel fark gürültü belirleme algoritmalarıdır [2].

İdeal bir sayısal darbe gürültü giderici filtrenin, bir yandan darbe gürültüsüne maruz kalmış bir imgede gürültülü pikselleri onarken diğer yandan gürültüsüz pikselleri koruması istenir. Ancak uygulamada birçok filtre, birbiri ile çelişen bu iki kriteri aynı anda sağlayamaz. Birçok filtrenin gürültü bastırma özelliği artırılmaya çalışıldığında, filtrenin orijinal pikselleri bozma oranı da artmakta, bozucu özellikleri azaltılmaya çalışıldığında ise gürültü bastırma başarımı düşmektedir. Bu sorunun temelinde ise gürültünün sebep olduğu belirsizlik yatmaktadır [2].

Bu tez çalışmasında darbe gürültüsü giderici filtrelerin, imgedeki gürültüyü giderirken sebep oldukları bozucu etkileri en aza indirmek amacıyla filtrenin süzme davranışını iyileştirmeye yönelik yeni yöntemler sunulmaktadır. Önerilen yöntemler makine öğrenme yöntemlerinden olan yapay sinir ağları ve Naïve Bayes sınıflandırıcıdan oluşmaktadır. Önerilen yöntemlerin başarısı, farklı test imgeleri üzerinde farklı filtreler ile gerçekleştirilen çeşitli imge filtreleme deneyleri aracılığıyla değerlendirilmiştir. Deneysel sonuçlar önerilen yöntemlerin darbe gürültüsü giderici imge filtrelerinin başarımlarının artırılmasında ve bozucu etkilerinin azaltılmasında son derece etkin bir şekilde kullanılabileceğini göstermektedir [2].

1.2. Tezin Amacı

Bu tezde; günümüzde hemen hemen her alanda kullanım alanı bulan sayısal imgelere bulaşan, darbe gürültüsünün azaltılmasına yönelik bir çalışma yapılmıştır.

Darbe gürültüsü, resmin kalitesini düşürerek daha sonradan üzerinde yapılacak olan çalışmaları engellemektedir. Özellikle, biyomedikal imgelerin gürültü bileşenlerinden arındırılması, hastalıklara teşhis koymada sağladığı kolaylık ve bu teşhislerin doğruluğunu artırması nedeniyle günümüzde biyomedikal sistemlerde mutlaka kullanılan ve aranılan bir özellik olmuştur. Çünkü hayati değerdeki biyomedikal bir imgede bazı detayların kaybolması, hem teşhiste güçlük, hem de yanlış tanı konulmasına sebep olabilmektedir.

Önerilen yöntemlerle gürültü giderici filtrelerin bir yandan darbe gürültüsünü gidermesi, diğer yandan imgenin sahip olduğu detayları koruması amaçlanmıştır. Elde edilecek sonuçlar deneysel olarak gösterilmesi amaçlanmaktadır.



a)



b)

Şekil 1.1 İmge iyileştirme literatüründe sıklıkla karşılaştırmada kullanılan ‘Lena’ imgesi;

a) Orijinal imge, b) %30 Darbe gürültüsüne maruz kalmış imge

1.3. Tezin İçeriği

Birinci bölümde teze giriş yapılmış, önceki çalışmalar, tezin amacı ve kapsamı anlatılmıştır.

İkinci bölümde imge işleme ile ilgili temel bilgilerden bahsedilmiş, temel imge işleme tekniklerine değinilmiştir.

Üçüncü bölümde etkili bir gürültü detektörü tasarlanıp, tasarlanan detektör ile tespit edilen bozuk piksellerde hibrit uyarlamalı medyan filtre kullanılarak iyileştirme sağlanmıştır.

Dördüncü bölümde yapay sinir ağları kullanılarak hem gürültü tespiti yapılmış, hem de iyileştirme için yapay sinir ağları kullanılmıştır.

Beşinci bölümde popüler makine öğrenme tekniklerinden olan Naïve Bayes sınıflandırıcı kullanılarak gürültünün yok edilmesi sağlanmıştır.

Altıncı ve son bölümde yüksek oranda darbe gürültüsüne maruz kalmış imgelerdeki gürültünün azaltılması amacıyla tezde uygulanan yöntemlerden elde edilen sonuçlar değerlendirilmiş ve ileriye dönük çalışmalar için önerilerde bulunulmuştur.

1.4. Literatür Taraması

Sayısal imgelere, imge sensörlerindeki hatalar ve iletişim kanallarındaki hatalardan dolayı darbe gürültüsü bulaşmaktadır [1]. Darbe gürültüsü, resmin kalitesini ciddi bir şekilde düşürüp bilgi ve detay kayıplarına yol açarak, örüntü tanıma, imge bölütleme ve imge sıkıştırma gibi sonradan yapılan işlemlerin başarısını düşürmektedir [3]. Sayısal imgelerdeki darbe gürültüsünü azaltmak, imge işleme araştırmacıları için hala araştırılması gereken ciddi bir konudur. Bozulan resmin yüksek kalitede restore edilirken resmin ayrıntılarını korumak önemli bir sorundur.

Özellikle, biyomedikal imgelerin gürültü bileşenlerinden arındırılması, hastalıklara teşhis koymada sağladığı kolaylık ve bu teşhislerin doğruluğunu artırması nedeniyle günümüzde biyomedikal sistemlerde vazgeçilmez bir özellik olmuştur. Kritik önem arz eden biyomedikal bir imgede bazı detayların kaybolması sonradan telafisi mümkün olmayan hatalara neden olabilmektedir. Bu yüzden darbe gürültüsü azaltma, hala araştırmacıların önemli konuları arasındadır.

Gürültü giderici filtrelerin bir yandan darbe gürültüsünü gidermesi, diğer yandan imgenin sahip olduğu detayları koruması gerektiğinden, imge verisinden gürültünün etkin bir şekilde giderilmesi oldukça zor bir işlemdir. Geleneksel gürültü yok etme tekniklerinin asıl imgenin sahip olduğu detayları bulanıklaştırma ve bilgi kaybına neden olma gibi istenmeyen yönleri mevcuttur

Literatürde çok sayıda darbe gürültüsünü yok eden filtre bulunmaktadır. Bunların çoğu hızlı ve etkilidirler. Ancak bu filtrelerin önemli bir dezavantajı gürültüyü yok ederken imgenin orijinalliğine önemli ölçüde zarar vermeleridir. Bu filtrelerde düşük gürültü oranlarında iyi sonuçlar elde edilirken, yüksek gürültü oranlarında imgenin kenar bölgelerinde bulanıklaşma meydana gelmesine neden olurlar. Literatürde çok sayıda darbe

gürültüsü azaltma teknikleri bulunmaktadır. Bu metotların çoğu verilen filtreleme penceresindeki pikselleri sıra bilgisine göre değerlendiren sıralı istatistik filtrelerdir. Özellikle, son zamanlarda medyan tabanlı doğrusal olmayan birçok filtre geliştirilmiş ve imge iyileştirme işlemlerinde sıklıkla kullanılmıştır. Uyarlamalı Medyan Filtre (AMF), doğrusal olmayan filtreler içerisinde en bilinen tekniktir. Ana yaklaşım, darbe gürültüsünü silmek için medyan tabanlı filtrelerin kullanılmasıdır. Çünkü doğrusal filtre teknikleri, darbe gürültüsünü silmek için etkili değildir.

Geleneksel medyan tabanlı sistemde uzaysal alanda, boyutu ixj olan bir pencereleme işlemi vardır. Buradaki i ve j tek sayıdır. Eğer giriş resmi f ve filtrelenmiş imge de g ise medyanı aşağıdaki gibi tanımlanır [4].

$$g(x, y) = \text{median}\{f(s, t)\}_{(s,t) \in S_{x,y}} \quad (1.1)$$

Genellikle imgeler düşük gürültü yoğunluklarında bozulmuşsa küçük pencereleme, yüksek oranda gürültüye maruz kalmışlarsa da büyük pencereleme işlemine tabi tutularak filtrelenirler. Standart medyan filtre (SMF), hatalı pikseli pencereleyerek, merkezdeki medyan değerini yerleştirir [5]. Ancak SMF'nin büyük bir eksikliği sadece düşük gürültü düzeylerinde etkili olmasıdır. Filtre küçük boyutlu pencereleme yaptığında yetersiz gürültü bastırma, büyük pencereleme yapıldığında ise imgede bulanıklaşma meydana gelmektedir. Özellikle, %50'nin üzerindeki gürültü oranlarında orijinal imgenin detaylarını koruyamamaktadır [6]. İmgenin kenarlarındaki yüksek frekans bileşenlerini kaybetmeksizin imgeyi yeniden oluşturmak oldukça önemlidir. Bu yaklaşım kabul edilebilir bir gürültü giderme başarımı göstermekle birlikte çok düşük gürültü yoğunluklarında bile ince çizgilerin kaybolmasına ve imgeye ait ayrıntıların bulanıklaşmasına sebep olmaktadır. Uyarlamalı Medyan Filtre (AMF), doğasında bulunan bu tür bozuklukların giderilmesi amacıyla, filtreleme penceresinde bulunan bazı pikselleri ağırlıklandıran, Ağırlıklı Medyan Filtre ya da Merkez-uyarlamalı Ağırlıklı Medyan Filtre (CWMF) önerilmiştir [7-8]. Bu filtrelerin gürültü giderme başarımında bir miktar azalma olmakla birlikte imgeye ait ayrıntıları korumada medyan filtreler göre daha iyi başarımlar göstermişlerdir [9]. İmgede bulunan gürültünün giderilmesi ile imgeye ait detay ve dokuların korunması işlemlerinin aynı anda gerçekleştirilmesi mevcut yöntemlerle yapılamamaktadır. Bu yüzden sonraki yöntemlerde medyan filtre ile gürültü detektörünün birleştirilmesi yoluna gidilmiş bu sayede filtreleme penceresindeki merkez pikselin gürültülü olup olmadığının anlaşılması ve buna göre işlem yapılması amaçlanmıştır [10-

12]. Sunulan bu Yönlü Ağırlıklı Medyan (DWM) filtresi kenar belirleme ve gürültü silmeyi beraber gerçekleştiren bir filtre türüdür. DWM filtresi incelenen piksel ile onun dört yöndeki komşuları arasındaki farkını aldıktan sonra, bir standart sapmaya bağlı olarak pikselin gürültü olup olmadığına karar verir [13]. Yine Karar–Tabanlı veya Anahtarlama Medyan Filtrelerde bozuk olan ve olmayan pikseller belirlenerek filtreleme işlemi uygulanır. Bunlar bozuk piksel medyan değeri ile değiştirilirken bozuk olmayan piksel ise değiştirilmez [14]. Bu filtrelerin temelinde önceden belirlenen bir eşik değeri vardır. Yine bu metotlardaki esas sorun eşik değeri ne olacaktır. Bunun yanında yüksek gürültülerde özellikle kenar ve ayrıntıların yeniden elde edilmesi sorunu giderilememiştir. Bu tarz filtreler genellikle iki aşamadan oluşur. Birinci aşama gürültü bulaşmış piksellerin tespit edilmesi, ikinci aşama ise bu piksellerin komşu değerlerinden biriyle değiştirilmesidir. Ancak bu tarz filtrelerin başarımı tamamen gürültü belirleme algoritmalarının başarımına bağlıdır [15].

Literatürde darbe gürültüsünü başarılı şekilde yok eden çok sayıda filtre bulunmaktadır. Bunlar içinde popüler olan bazıları; Uyarlama Anahtarlama Medyan (ASM) filtresi gürültülü pikselleri tanımlamada oldukça iyi performans göstermekte iken gürültü düzeyi özellikle %60'aştıktan sonra gürültü belirleme özelliği adım adım azalmaktadır [16]. Geliştirilmiş Anahtarlama Medyan (ISM) filtresi gürültü belirlemenin zor olduğu kenar bölgelerinde, gürültü belirlemek için bir boyutlu Laplacian operatörünü kullanmaktadır [17]. Sınır Ayırt Eden Gürültü Detektörü (BDND) algoritması oldukça etkili bir filtredir. Ancak algoritmanın karmaşıklığı sebebiyle fazla hesaplama zamanına gerektirmektedir. Ayrıca gürültü belirleme mekanizmaları rastgele değerli darbe gürültüsünü belirlemeye uygun değildir [18]. Karar Tabanlı Algoritma (DBA) aşırı derecede bozulmuş imgeleri restore etmek için kullanılan filtrelerdendir. Bu filtre bozuk pikselin etrafında 3x3 pencereleme kullanır. Düşük hesaplama zamanı ve iyi kenar belirleme ve detay koruma özellikleri ile etkili bir filtredir. Fakat gürültü yoğunluğunun artması ile imgenin görsel performansında önemli ölçüde azalma meydana gelmektedir [19].

Bu problemlerin üstesinden gelebilmek için Geliştirilmiş Karar Tabanlı Algoritma (IDBA) ortaya konmuştur. Gürültülü pikseller komşu piksellerin ortalaması ya da medyanı ile yenilenmektedir. Bu algoritma gürültüsüz piksellerle ilgili işlem yapmadığı için iyi sonuçlar vermektedir. Yine de gürültülü pikseli yenileme şemalarının yetersizliği sebebiyle imgenin detayları iyi bir şekilde korunamamaktadır [20]. Bulanık Mantık Tabanlı Anahtarlama Medyan (FBDA) filtresi bir pencere tarafından seçilmiş merkezi gürültülü

pikselin etrafındaki tüm komşu piksellerle farkını hesaplar ve merkez piksel ile en yüksek fark prensibine göre üyelik fonksiyonlarını oluşturur. Ama gerçek zamanda gürültü yoğunluğu bilinmediğinden seçilen sabit pencere boyutu gerçek zamanlı uygulamalar için çokta gerçekçi değildir [21]. Temel Nöro-Bulanık Filtresi (SNFF) darbe gürültüsü belirleme tabanlı bir filtredir. Önerilen detektör iki özdeş alt detektör ve bir karar vericinin bileşiminden oluşmaktadır. Alt detektörlerin iç parametreleri ağın eğitimi ile ayarlanmaktadır. İki alt detektör ve bir karar vericiden oluştuğu için filtrenin hesaplama zamanı artmaktadır. Bunun yanında gürültü düzeyi %50'nin üzerine çıktığında detektörün performansı önemli ölçüde düşmektedir [22]. Bunlara ek olarak araştırmacılar tarafından darbe gürültüsünü benzer şekilde yok eden birçok filtre literatürde bulunmaktadır [23-30].

Bu filtreler artan işlemsel karmaşıklıkla birlikte iyi filtreleme başarısı göstermektedir. Bu alanda esnek hesaplama yöntemlerine dayalı çok sayıda darbe gürültüsü giderme filtreleri [31-35] ile yukarıda bahsedilen filtrelerin arzu edilen özelliklerini birleştiren doğrusal olmayan filtreler de [36-42] bulunmaktadır. Bu filtreler genel olarak medyan tabanlı filtrelere göre daha karmaşık olmakla birlikte gürültü bastırma ve detay korumada daha iyi sonuçlar vermektedirler.

Bu yöntemlerin tamamı filtreleme esnasında imgeye ait detay ve dokuları bulanıklaştırmak gibi az ya da çok arzu edilmeyen özelliklere sahiptir. Bunun başlıca sebebi gürültünün beraberinde getirdiği belirsizliktir. İmgede bulunan gürültünün yoğunluğu arttıkça süzgecin normal pikselle gürültülü pikseli doğru bir şekilde ayırt etmesi güçleşmektedir. Belirsizlikten dolayı gürültülü piksellerin bir kısmı filtrelenmeden kalmakta, gürültülü olmayan pikseller de gürültülü gibi değerlendirilerek filtrelemeye tabi tutulmaktadır. Gürültülü piksellerin filtrelenmemesi onarılmış çıkış imgesinde çok sayıda gürültülü piksel kalmasına, gürültüsüz piksellerin filtrelenmesi ise bu piksellerin değerinin değişmesine, çıkış imgesinde istenmeyen bozulmalara ve bulanıklıklara sebep olmaktadır. Buna ek olarak bu yöntemlerin bir kısmı [10, 11, 42, 43] gürültü yoğunluğu tahmini, piksel ağırlıklandırma faktörü, sezme eşiği, vb. gibi sezgisel olarak kullanıcı tarafından belirlenen bir veya daha fazla harici parametreye ihtiyaç duymaktadır. Verilen imge ve gürültü yoğunluğu için en iyi sonucu verecek en uygun parametre setini hesaplamak, bu amaca yönelik analitik bir yöntem olmadığı için güçtür. Ayrıca iyi başarı sağlayan parametre seti, deneyde kullanılan imgeye ve/veya gürültü yoğunluğuna ait olmakla birlikte farklı imge ve gürültü yoğunluğunda aynı başarıyı sağlayamamaktadır [9].

2. İMGE İŞLEME

İmge iyileştirmenin temel hedefi; belirli bir uygulama için, resmi orijinal halinden daha iyi duruma getirmektir. Bu dönüştürme, bazen şeklin bütününe daha çok bozarken ancak ilgilenilen kısmı daha görünür hale getirebilir. İmge işleme tekniklerinin hiçbiri imgede olmayan yeni bir bilgiyi elde edemez, sadece mevcut imge bilgilerinin değişik işlemlerle daha kullanışlı hale getirilmesini sağlar. İmge iyileştirme, eldeki bir imgenin belli bir amaca uygun şekilde daha iyi anlaşılır hale getirilmesidir. Böylece şeklin istenilen özellikleri, insanın görsel sistemi için daha kolay anlaşılır ya da otomatik imge analiz sistemleri tarafından algılanması daha kolay hale gelir. İmge iyileştirme, orijinal imgede ilk bakışta gözlemlenebilir olmayan imge detaylarını göstermek ve gözlemcinin imgeyi daha iyi değerlendirebilmesi için gözlemciye iyi bir imkân sağlaması açısından önemlidir. Örnek olarak, imge yüksek düzey bir parazite sahip olduğunda ya da imgedeki karışıklık yetersiz olduğunda, verinin ve imgenin dinamik aralığının orantılı veya yeterli olmadığı bir durumda imge iyileştirmeden faydalanılır. Böylece orijinal imgede görülemeyen bazı detaylar görülebilir. Temel olarak imge iyileştirme, bir şeklin diğer bir şekle dönüştürülmesidir. Bu dönüşüm bire bir olmak zorunda değildir. Daha da genel olarak, bir şeklin çoklu iyileştirilmiş versiyonları üretilmek istenebilir. Böylece tek bir imgeden farklı amaçlar için değişik iyileştirme teknikleri kullanılarak birden çok imge elde edilebilir. Elde edilen her bir imge istenen farklı özellikleri için kullanılabilir. Bu durumda da iyileştirilmiş imgedeki bir özellik net bir şekilde gözlemlenirken diğer özellikler de başka iyileştirilmiş imge türlerinde net bir şekilde gözlemlenebilir. Zira bazen imgedeki bir ayrıntının netleşmesi sağlanırken, başka bir ayrıntının fark edilemez hale gelmesine neden olunabilir. Bu durum dikkate alınmadığı takdirde özellikle tıbbi uygulamalarda çok sakıncalı sonuçlar ortaya çıkabilir [44].

İmge iyileştirme sürecinde her durumda aynı işlemler tekrarlanmaz. Örneğin; X-ışını imgeleri ve uydu imgelerinde aynı iyileştirme yöntemlerinin uygulanması doğru olmayabilir. Her imgeye ve her amaca göre imge iyileştirme araçları o duruma uygun olarak kullanılmalıdır.

İmge kalitesinin artırılması için bilgisayar tekniklerinin kullanılması 1964'te ay fotoğrafları ile başladı. 1960'ların sonları 1970'lerin başlarında tıp alanında CAT

(Bilgisayarlı Tomografi) gibi imgeler, imge işleme tekniklerinin kullanılmasıyla yaygınlaşmaya başlanmıştır. İmge işleme günümüzde;

- Tıp ve biyoloji (x-ışınları, biyomedikal imgeler...),
- Coğrafi bilimler (hava ve uydu imgelerinden hava tahmini),
- Eski, hasar görmüş fotoğrafların onarılması,
- GPR-mayın tarama, arkeolojik kalıntıların tespiti,
- Oyun Programlama (bilgisayarla görü, 3-B modelleme),
- Fizik (spektrometreler, elektron mikroskobu),
- Uzay bilimleri (uydu, mikrodalga radar imgeleri...),
- Savunma sanayi (gece görüş, akıllı roket sistemleri...),
- Endüstriyel uygulamalar (süreç, ürün denetimi...),
- Tüketici elektroniği (video kayıt cihazları, cep telefonları...),
- Biyometrik tanıma ve güvenlik sistemleri (iris-parmak izi tanıma),
- Uzaktan algılama,

alanlarında sıklıkla kullanılmaktadır.



Şekil 2.1 Ayın ilk fotoğrafı (31 Temmuz 1964). “Ranger 7” tarafından Ay ile çarpışmadan 17 dakika önce çekilmiştir

2.1. İmge İşleme ve İyileştirme Teknikleri

İmge İşleme; insan gözü ile yapılan işlemlerin, görüntüleme cihazları ve akıllı yazılımlar kullanan makinelere yaptırılmasını amaçlayan bir bilim dalıdır. Cihazlardan algılanan imgelerin anlamlı hale getirilme işlemlerinin tümüne ise imge işleme teknikleri adı verilir [45]. Günümüzde birçok alanda gözlem ve incelemelerin gözle kontrolünün bazı dezavantajları vardır. İnsan performansı, her zaman en iyi düzeyde değildir. Ayrıca moral, hastalık ve benzeri ruhi durumlar kişinin performansına direkt olarak yansır. Sürekli aynı işi yapmak kişiyi sıkmakta ve çabuk yorulmasına, dikkatinin dağılmasına neden olmaktadır. Özellikle seri üretim yapan bir fabrikada birim zamanda üretilen ürün sayısının çok fazla olduğu durumlarda ürünlerin tümünün gözle kontrol edilmesi hem çok zaman almakta hem de pahalı olmaktadır. Bu bakımdan örnekleme yoluyla tüm ürünlerin kontrolü yerine seçilen belirli sayıdaki örnek ürün kontrol edilmekte ve elde edilen sonuçlar genelleştirilmektedir. Bu ise, kalitenin gittikçe önem kazandığı günümüzde %100 kalite kontrol yapan yöneticilere karşı rekabet gücünü oldukça zayıflatacaktır. Göz ile kontrol yavaş olduğundan birim zamanda üretilen ürün sayısı az olmaktadır. Bunun yerine endüstriyel alanda kullanılabilecek imge işleme sistemi kurulduğunda hız artacağından birim zamanda üretilen ürün sayısı da artacaktır. İmge işleme yöntemleri üzerine kurulan endüstriyel cihazların kullanımı, özellikle sanayi alanında hızla artmaktadır. Bu kullanım yaygınlaşması, üretimde verimliliğin artmasını ve maliyetlerin azalmasını sağlamaktadır [45]. Bunun yanında;


- Gerçek zamanlı ve aralıksız sayım,
- Düşük hata oranı ile güvenilir çözüm,
- Performans analizi ve istatistiksel raporlama,
- Günlük, aylık ve yıllık analizler,
- Merkez yazılım ile kablosuz iletişim,

gibi avantajları bulunmaktadır.

2.1.1 İki Boyutlu İmgenin Tanımı


İmge iki boyutlu $f(x, y)$ fonksiyonu olarak düşünülürse, x ve y değişkenleri ise resmin gerçek koordinatlarıdır, fonksiyonun (x, y) noktasındaki değeri resmin o noktadaki yoğunluğunu gösterir. Eğer f fonksiyonu, sonlu sayıdaki ayrık bileşenlerden oluştuğu zaman bu fonksiyonun temsil ettiği imgeye sayısal imge, bu ayrık değerlerin her birine

piksel veya imge elemanı denir. Eğer 8 bitlik bir resim kullanılıyorsa, f fonksiyonu (0 ile 255) arasındaki gri değerleri alabilecek bir ayrık fonksiyon olarak dikkate alınmıştır. Bundan sonra imge $f(x,y)$ formunda iki boyutlu fonksiyonlar şeklinde ifade edilmiştir. (x,y) uzaysal koordinatlarında f 'nin değeri veya genliği pozitif skaler bir değer olup asla negatif değerler alamaz. Bir imgenin x ve y koordinatları boyunca almış olduğu gri değerler bütününe gösteren matrissel formu Şekil 2.2'de görülmektedir [46].



Şekil 2.2 Bir imgenin x ve y koordinatları boyunca almış olduğu gri değerleri gösteren matris formu

İmge iki boyutlu (2D) ve (x,y) koordinatlarda belli bir gri seviyesi olan bir fonksiyonun matrisi şeklinde ifade edilebilir [47]. Bu durum matris ve grafiklerle Şekil 2.3'de gösterilmiştir.



a)

b)

Şekil 2.3 Tek boyutlu ve iki boyutlu dizilerin matris görünümü ve grafikleri;

a) Tek boyutlu matris, b) İki boyutlu matris

2.1.2 Siyah Beyaz İmgenin Matematiksel Olarak Modellenmesi

Siyah beyaz bir imge, ışık yoğunluğunu gösteren iki boyutlu bir fonksiyon olarak düşünülebilir. Siyah beyaz bir resmin (x, y) noktasındaki parlaklığına resmin bu noktadaki gri ton değeri adı verilir. Teoride $x, y \in \mathbb{R}$ 'dir ve $f(x, y)$ sıfırdan büyük, sonlu bir sayıdır. $f(x, y)$ 'nin iki bileşeni vardır;

- Ortamdaki ışığın miktarı (aydınlatma)
- Nesnenin ışığı yansıtma oranı (yansıtma)

Aydınlanmayı $i(x, y)$, yansıtmayı $r(x, y)$ ile gösterirsek $f(x, y)$ bunların çarpımı şeklinde yazılabilir [45]:

$$f(x, y) = i(x, y)r(x, y) \quad (2.1)$$

olup

$$0 < i(x, y) < \infty \quad (2.2)$$

$$0 < r(x, y) < 1 \quad (2.3)$$

Denklem (2.3), yansıtmanın 0 (tam emme) ve 1 (tam yansıtma) ile sınırlandığını gösterir. $i(x, y)$ 'nin niteliği aydınlatma kaynağı ile belirlenmektedir ve $r(x, y)$ görüntülenen nesnelerin nitelikleri tarafından belirlenmektedir. Bu anlatımların, göğüs röntgeni gibi bir ortam içinden geçebilen x-ışınları ile elde edilen imgelere de uygulanabileceği kaydedilmiştir [45]. Bu durumda, yansıtabilirlik yerine geçirebilirlik fonksiyonu kullanılmaktadır. Aynı şekilde sınırlar Denklem (2.3)'te olduğu gibi aynı olacak ve oluşan imge fonksiyonu, Denklem (2.1)'deki imge fonksiyonu $f(x, y)$ 'yi oluşturacaktır. Denklem (2.2) ve Denklem (2.3)'te verilen değerler, teorik sınırlar olup, bu sınırlara pratikte ulaşılması mümkün değildir. Herhangi bir (x_0, y_0) koordinatındaki tek renkli imgenin yoğunluğuna o düzeydeki gri düzeyi (ℓ) denir. Yani,

$$\ell = f(x_0, y_0) \quad (2.4)$$

Denklem (2.1)'den Denklem (2.3)'e kadar olan eşitliklerde, ℓ 'nin

$$l_{min} \leq l \leq l_{max} \quad (2.5)$$

arasında yer aldığı görülmektedir. Ancak bilinmesi gereken, l_{min} değerinin pozitif bir değer olması ve l_{max} değerinin ise sonlu olması zorunluluğudur. Pratikte bu durum şu şekilde ifade edilebilir.

$$L_{min} = i_{min}r_{min}$$

$$L_{max} = i_{max}r_{max}$$


$[L_{min}, L_{max}]$ aralığına gri ölçek denmektedir. Genel temayül, bu aralığı sayısal olarak $[0, L - 1]$ aralığına kaydırmaktır. Burada gri ölçek üzerinde $l = 0$ siyah ve $l = 1$ beyaz olarak kabul edilmiştir. Bütün ara değerler siyahtan beyaza grinin değişen tonları olmuştur.

2.1.3 Bir İmgenin Sayısal Hale Dönüştürülmesi

Sayısal bir imge oluşturabilmek için, sürekli olarak algılanan veriyi sayısal bir veri şekline dönüştürmek gerekir. Bu da örnekleme ve nicelendirme denen iki işlemle gerçekleştirilebilir. Örnekleme ve nicelendirmeyi anlamının en basit yolu Şekil 2.4 'de gösterilmektedir. Şekil 2.4.a sayısal forma dönüştürülmek istenen sürekli imge $f(x, y)$ 'yi göstermektedir. Bir imge x ve y koordinatlarına ve aynı zamanda genliğine göre süreklilik arz edebilir. Bunu sayısal forma dönüştürmek için, fonksiyonu hem koordinat hem de genliği açısından örnekleme gerekmektedir. Koordinat değerlerinin sayısal hale getirilmesine örnekleme, genliğin sayısal hale getirilmesine ise nicelendirme denir. Şekil 2.4.a'da gösterilen, AB segmenti çizgisi boyunca oluşan sürekli imgenin tek boyutlu fonksiyon genliği grafiği (gri düzey) değerleridir. Bu fonksiyonu örnekleme için, Şekil 2.4.c'de gösterildiği gibi, AB çizgisinde eşit aralıklı örnekler alınır [44].

Örnekler fonksiyonun üzerine eklenmiş küçük beyaz kareler olarak gösterilmiştir. Bu farklı konumların takımı, örneklenen fonksiyonu verir. Ancak, örneklerin değerleri hala gri düzey değerlerinde sürekli bir aralıkta (dikey) yayılmaktadır. Bir sayısal fonksiyon oluşturmak için, gri düzey değerlerinin farklı miktarlara dönüştürülmesi (nicelendirilmeleri) gerekmektedir. Şekil 2.4.c'nin sağ tarafı gri düzey ölçeğin, siyahtan beyaza uzanan dağılımını, 8 farklı düzeye bölünmüş olarak gösterir. Dikey im işaretleri, sekiz gri düzeyden her birine atanmış belirli değerleri gösterir. Sürekli gri düzeylerin nicelendirilmesi, basitçe her bir ayrı gri düzeyin her bir örneğe atanması ile oluşturulur. Atama, bir örneğin bir dikey im işaretine olan yakınlığına bağlı olarak yapılır. Hem örnekleme, hem de nicelendirmeden elde edilen sayısal örnekler, Şekil 2.4.d'de

gösterilmiştir. İmgenin en üstünden başlayarak bu işlemi çizgi çizgi devam ettirmek iki boyutlu bir sayısal imge ortaya çıkarır. Gerçekte, örnekleme yöntemi imgeyi üretmek için kullanılan algılayıcı tarafından belirlenmektedir. Mekanik farklılıklarda kullanılan algılayıcılara, mekanik değişimlerle başarılabilen yüksek çözünürlük ile uyumlu olmayan aydınlanma noktası, odaklanmış optiklerdeki kusurlardan dolayı bazı fiziksel sınırlar ortaya çıkarır [44].




Şekil 2.4 Bir sayısal imgenin üretimi;

a) Sürekli imge, b) A dan B 'ye tarama çizgisi, sürekli imge, örnekleme ve nicelendirmenin

kavramlarını göstermek için kullanılmıştır, c) Örnekleme ve nicelendirme, d) Sayısal tarama çizgisi


Şekil 2.4.a'daki imgenin, örnekleme ve nicelendirme sonucunda, sayısal hale getirilmiş hali Şekil 2.5'te görülmektedir.



Şekil 2.5 Örnekleme ve nicelendirme;
a) Sürekli görüntü, b) Sayısal hale getirilmiş görüntü

2.1.4 Renk Ölçeği

Bir imgeyi oluşturan tüm renklerin bir yelpaze şeklinde yayılmış haline renk ölçeği denir. İmge siyah-beyaz ise Şekil 2.6.a'daki gibi ölçek siyahtan beyaza kadar giden gri yelpazedir. İmge renkli ise, Şekil 2.7.b'deki gibi ölçek morötesi ile kızlötesi arasında yer alan, tüm renklerin bulunduğu bir yelpazedir.




Şekil 2.6 Renk ölçeği;
a) Gri ölçek, b) Renkli ölçek

Bir ölçekte en büyük değer L ile gösterilir. Bu durumda imgedeki her bir nokta, 0 ile $L-1$ arasında genlik değeri ile ifade edilir. İki boyutlu bir imgede her bir noktayı betimleyen en az 3 adet değer (2 adet koordinat ve 1 adet genlik) bulunmalıdır. $[0, L-1]$ aralığına da imgenin dinamik aralığı denir.

2.1.5 Sayısal İmgelerin Matris Olarak Gösterilmesi

Sürekli görüntünün sayısal hale getirilmesi sonucu, gerçek bir sayı matrisi oluşur. Sayısal imgeleri temsil etmede iki esas yol izlenir. Bir imgenin $f(x,y)$ ile örneklendiği, elde edilen sayısal imgenin M satır ve N sütundan oluştuğu ve (x,y) koordinatlarının değerlerinin ayrık değerler halinde olduğu farz edilsin. Koordinatlar başlangıçta $f(x,y) = (0,0)$ 'dır. İmgenin birinci sıradaki koordinat değerleri $(x,y) = (0,1)$ ile temsil edilir. $(0,1)$ İşaretinin birinci sıradaki ikinci piksel değerini temsil etmektedir. Bu, imge örneklendiği zaman bunların fiziksel koordinatları olduğu anlamına gelmez. Şekil 2.7'de bu tezde kullanılan geleneksel koordinat sistemi görülmektedir.



Şekil 2.7 Sayısal imgeleri temsil etmek için kullanılan koordinat sistemi

Tanımlamadan yola çıkılarak, bir imge $M \times N$ sayısal imgesi matris formunda aşağıdaki gibi yazılabilir:

$$f = (x,y) = \begin{bmatrix} f(0,0), & f(0,1) \dots \dots & f(0,N-1) \\ f(1,0), & f(1,1) \dots \dots & f(1,N-1) \\ \vdots & \vdots & \vdots \\ f(M-1,0) & f(M-1,1) & f(M-1,N-1) \end{bmatrix} \quad (2.6)$$

Bu eşitliğin sağ tarafı tanımı itibarı ile bir sayısal imgedir. Bu matris dizisinin her elemanı; bir imge elemanı, bir resim elemanı ve bir pikseli göstermektedir. İmge elemanı ve piksel terimleri bütün tartışmalar boyunca bir sayısal imgenin elemanlarını ifade etmek üzere kullanılmıştır. Bazı konularda, bir sayısal imgeyi ve onun elemanlarını ifade etmek için Denklem 2.7 şekli ile kullanmak daha avantajlı olabilir:

$$A = \begin{bmatrix} a_{0,0}, & a_{0,1} \cdots \cdots & a_{0,N-1} \\ a_{1,0}, & a_{1,1} \cdots \cdots & a_{1,N-1} \\ \vdots & \vdots & \vdots \\ a_{M-1,0} & a_{M-1,1} & a_{M-1,N-1} \end{bmatrix} \quad (2.7)$$

Yukarıdaki iki matris tek matris halinde Denklem (2.8)'deki gibi gösterilebilir.

$$f(x, y) = \begin{bmatrix} f(0,0) = a_{0,0}, & f(0,1) = a_{0,1} \cdots \cdots & f(0, N-1) = a_{0,N-1} \\ f(1,0) = a_{1,0}, & f(1,1) = a_{1,1} \cdots \cdots & f(1, N-1) = a_{1,N-1} \\ \vdots & \vdots & \vdots \\ f(M-1,0) = a_{M-1,0} & f(M-1,1) = a_{M-1,1} & f(M-1, N-1) = a_{M-1,N-1} \end{bmatrix} \quad (2.8)$$

$a_{ij} = f(x = i, y = j) = f(i, j)$ 'dir. Böylece (2.7) ve (2.8) denklemlerinin aynı matris olduğu görülmektedir. Bu sayısal hale getirme işlemi, M , N ve L değerleri hakkında, her piksel için izin verilebilecek gri düzey seviyelerinin belirlenmesini gerektirir. Pozitif tamsayı olmaları dışında M ve N üzerinde başka bir işlem yapılmasına gerek yoktur. Bu işlem, saklama ve örnekleme donanımının gereksinimi nedeniyle, gri düzeyler tipik olarak 2 kuvvetinde bir tamsayıdır:

$$L = 2^k \quad (2.9)$$

Bazen gri ölçülerin yayıldığı değer aralığına bir imgenin dinamik aralığı denir. Dikkate alınacak kadar sayıda piksel bu özelliği sergilerse, imgenin yüksek kontrastı olacaktır. Aksine, düşük dinamik aralığı olan bir imgenin, donuk, silik gri görünüşü olacaktır. Tablo 2.1'de farklı N ve k değerleri için saklama bit sayısı görülmektedir. Bir sayısal imgeyi saklamak için gereken B , bit sayısı şöyledir.

$$B = M \times N \times k \quad (2.10)$$

$M = N$ olduğu zaman bu eşitlik aşağıdaki gibi olur.


$$B = N^2 k \quad (2.11)$$

Tablo 2.1 Farklı N ve k değerleri için saklama bit sayısı

N/k	1(L=2)	2 (L=4)	3(L=8)	4(L=16)	5(L=32)	6(L=64)	7(L=128)	8(L=256)
32	1.024	2.048	3.072	4.096	5.12	6.144	7.168	8.192
64	4.096	8.192	12.288	16.384	20.48	24.576	28.672	32.768
128	16.384	32.768	49.152	65.536	81.920	98.304	114.688	131.072
256	65.536	131.072	196.608	262.144	327.68	393.216	458.752	524.288
512	262.144	524.288	786.432	1.048.58	1.310.720	1.572.864	1.835.008	2.097.152
1024	1.048.576	2.097.152	3.145.728	4.194.304	5.242.880	6.291.456	7.340.032	8.388.608
2048	4.194.304	8.388.61	12.582.912	16.777.216	20.971.520	25.165.824	29.369.128	33.554.432
4096	16.777.216	33.554.432	50.331.648	67.108.864	83.886.080	100.663.296	117.440.512	134.217.728
8192	67.108.864	134.217.728	201.326.592	268.435.456	335.544.320	402.653.184	469.762.048	536.870.912


2.1.6 Uzaysal Çözünürlük ve Gri Seviyesi

Bir imgenin uzaysal çözünürlüğü o imgeye ait bir pikselin fiziksel büyüklüğüne eşittir. Yani bir resmin detaylanabilir en küçük parçasıdır. Pikselin kendi başına en ve boy değerleri yoktur. Dikdörtgen biçimindeki tek bir piksel 1x1 mm olabileceği gibi, 1x1 cm boyutlarında da olabilir. Aksi belirtilmedikçe piksellerin en ve boy oranı eşittir. Çözünürlüğün genel olarak kullanılan bir tanımı basitçe şöyledir: Mesafe birimi başına fark edilebilen çizgi çifti; örneğin, milimetre başına 100 çizgi çifti gibi. Gri düzey çözünürlüğü, benzer şekilde gri düzeydeki fark edilebilen en küçük değişikliğe denir. Şekil 2.8, gri düzeyleri 8 bit ile temsil edilen 1024x1024 piksel bir imgeyi göstermektedir. Aynı zamanda Şekil 2.8 'da gösterilen diğer imgeler, imgenin 1024x1024 ile alt örnekleme neticesidir.



Şekil 2.8 1024 x 1024, 8 bit bir imge 32 x 32 piksel boyuta alt örnekle küçültülmüş durumu

Bu imgeler farklı örnekleme yoğunlukları arasındaki boyutsal oranları göstermektedir. Fakat boyutsal farklılıkları, örneklerdeki azaltılmış sayıların sonuç üzerindeki etkilerini görmeyi zorlaştırmaktadır. Şekil 2.8’da görüldüğü gibi piksel sayısı düştükçe resmin boyutu da küçülmekte ve dolayısıyla resmin büyütülmesi durumunda da imgedeki ayrıntılar kaybolmaktadır. Genel olarak; “çözünürlük ne kadar yüksekse, görüntü kalitesi o kadar yüksektir” denilebilir. Ancak piksel değeri büyüdüğü zaman bilgisayar hafızasında çok fazla yer işgal etmekte ve bilgisayarla işlenmesi durumunda ise işlem uzun zaman almaktadır. Bu nedenlerden dolayı bu tezde kaliteden fazla ödün vermeden ve yapılacak işlemlerinde hızlı olmasını sağlamak amacı ile 512 x 512 piksel imgeler kullanılmıştır.



Şekil 2.9 Bir imgenin farklı çözünürlükteki versiyonları.

Çözünürlüğün azalmasına bağlı olarak imgedeki kalitede düşer. Çözünürlük ise imge kalitesini etkileyen başka bir faktör olup bu durum Şekil 2.9’da rahatlıkla gözlemlenebilir.

İnç başına düşen piksel sayısı arttıkça görüntü netliği de yükselir. Bir piksel sadece bir renk değeri aldığı için piksellerin sayısının çok olması, renk tonları arasındaki farkı zenginleştirerek, resme daha canlı ve net bir görünüm kazandırır. Ters durumda ise piksellere paralel olarak renk tonları arasındaki fark da azalacağı için resim canlılığını ve netliğini yitirmektedir.

2.2. Sayısal İmge Çeşitleri

2.2.1 İkili (Binary) İmgeler

İkili imgeler, sadece iki farklı renk içeren imgelerdir. İkili bir imgedeki pikseller, genelde siyah ve beyaz renkler ile temsil edilir. Ancak bu bir zorunluluk değildir. İstenilen herhangi iki farklı renk bu imgeleri temsil etmekte kullanılabilir. İkili imge, sayısal imgeler arasında en basit olanıdır. İki adet değişkene sahiptir. İkili imgede her bir piksel 1 bitlik değer ile gösterilir. Bunlar genel olarak “siyah” ve “beyaz” ya da “0” ve “1” ile temsil edilirler. Şekil 2.10’da ikili bir imge görülmektedir. Bu imgedeki her bir piksel 0 veya 1 şeklindeki iki değerden yalnızca birinin değerini alabilir. Ara değer yoktur. İkili imgeler genelde gri-seviyeli imgelerden üretilir. Burada belirlenen eşik değerinin üzerinde olan her piksel “1”, aşağısında olan “0” değerini alır [2].


1	1	1	1	1	1	1	1	1	1
1	0	0	0	1	1	0	0	0	1
1	1	0	1	1	1	1	0	1	1
1	1	0	1	1	1	1	0	1	1
1	1	0	1	1	1	1	0	1	1
1	1	0	0	0	0	0	0	1	1
1	1	0	1	1	1	1	0	1	1
1	1	0	1	1	1	1	0	1	1
1	1	0	1	1	1	1	0	1	1
1	0	0	0	1	1	0	0	0	1
1	1	1	1	1	1	1	1	1	1

Şekil 2.10 İkili bir imge ve piksel değerleri

2.2.2 Yoğunluk İmgeleri (Grayscale İmge)

Yoğunluk imgesi gri renk tonlarına sahip görüntüyü ifade eder. Yoğunluk imgeleri renk bilgisi içermez ve sadece parlaklık bilgisini tanımlar. Her pikseli tanımlamak için

kullanılan değerler farklı parlaklık seviyelerinin sayısı ile tanımlanır. Genelde doğrudan görülemeyen nesnelerin elektromanyetik dalga, ses dalgası vb. dalgalar yardımıyla görüntülenmesi işlemlerinde yoğunluk imgeleri kullanılır. Bir bölgeye gönderilen elektromanyetik dalga veya ses dalgasının o bölgeden yansımaları sonucunda elde edilen değerlerin bir renk haritası üzerindeki değerler ile eşleştirilmesi sonucu ortaya çıkarılan imgelerdir. Ultrason (ultrasound), MRI (Magnetic Resonance Imaging, Manyetik Rezonans Görüntüleme) veya CT (Bilgisayarlı Tomografi, Computed Tomography) bu tür imgelerdendir. Şekil 2.11’de bu imge türüne ait bir örnek görülmektedir. Yoğunluk imgeleri, bir değişim aralığındaki değerlerden oluşan bir veri matrisidir. Tipik bir yoğunluk imgesi her piksel için 8-bit bilgi içerir ve bu da 256 farklı parlaklık (gri renk) seviyesine sahip olunmasını sağlar. İkili imgelere göre daha fazla bilgi içeren bu imge türü, bunun doğal bir sonucu olarak ikili imgelerden daha fazla yer kaplar. Buna ek olarak yoğunluk imgelerinin işlenmesi esnasındaki fazla işlem yükü ikili imgelere göre daha fazladır [2].




Şekil 2.11 Bir yoğunluk imgesi ve piksel değerleri

2.2.3 Gerçek Renk (True Color - RGB) İmgeleri

Gerçek renk imgeleri bütün pikseller için üç ya da daha fazla değer içeren renk modelleri kullanılarak ifade edilir. Bu yüzden gerçek renk imgelerini ifade etmek için en az üç tane iki boyutlu matris kullanılmalıdır. En çok kullanılan renkli imge sistemlerinin RGB (Kırmızı, Yeşil, Mavi), CMY (yeşile çalan mavi, morumsu kırmızı, sarı) ve HIS (renk tonu, canlılık, yoğunluk) olduğu görülmektedir. Şekil 2.12’de bu şekilde elde edilmiş renkli bir imge görülmektedir. Gerçek renk imgelerinde her bir pikseli tanımlamak için,

bütün renk bantları (Kırmızı, yeşil, mavi) için 8 bitlik değerler kullanılırsa 24 bitlik bir değer gerekli olmaktadır [2].




Şekil 2.12 Gerçek bir renkli imge

2.2.4 İndeksli (Etiketli) İmgeler

İndeksli imgeler çoğunlukla aslında görsel olmayan sayısal verilere görsel bir nitelik kazandırmak için kullanılır. Böylece orijinal sayısal verinin doğrudan incelenmesi ile elde edilmesi oldukça güç olan örüntüler bu verinin imgeye dönüştürülmesi sayesinde kolayca bulunabilir. Bu yönüyle indeksli imgelerin en çok uygulandığı yerlerden birisi gri seviyeli yoğunluk imgelerinin yapay olarak renklendirilmesidir. İndeksli imgeler gerek yoğunluk ve gerekse gerçek renk (RGB) imgelerinin nispi renk değerleri kullanılarak oluşturulmasını sağlayan özel bir imge formatıdır. Bu tür imgeler imge matrisi ve renk matrisi (paleti) olmak üzere iki matrisin birleşiminden meydana gelir. Renk matrisi imgedeki farklı renk sayısı kadar satıra ve üç adet sütuna sahiptir. Renk matrisinin her bir satırı üç adet sayısal elemana sahip olup bunlar bir rengi oluşturan kırmızı, yeşil ve mavi bileşenleri ifade


etmektedir. Böylece renk matrisindeki her bir satır, farklı bir rengi tanımlamaktadır. İmge matrisi ise değerleri 1 ile renk matrisindeki satır sayısı arasında değişen tam sayıların oluşturduğu bir matristir. Yani bu sayısal değerlerden her biri, renk matrisindeki ilgili rengin satır numarasını temsil eder.

İmgeleme esnasında bu sayıların her biri renk matrisindeki ilgili renk ile değiştirilerek renkli imge elde edilir [2]. Şekil 2.13'te indeksli bir imge görülmektedir.



Şekil 2.13 İndeksli renkli imge

Gerçek renk imgelerindeki renk değerlerini belirtmek için kullanılan standart renk küpünde siyah ile kırmızı arasında, siyah ile yeşil arasında ve siyah ile mavi arasında 256 değer vardır. Standart renk küpü şekil 2.14'teki gibidir [2].



Şekil 2.14 Standart renk küpü


2.3. İmge İyileştirmede Genel Bilgiler

Piksellerden oluşan imge uzayına uzaysal düzlem denir. Uzaysal alan yöntemleri doğrudan bu pikseller üzerinde işlemde bulunan prosedürlerdir. Uzaysal koordinatlarda işlenen görüntü fonksiyonları Denklem (2.12) ile gösterilecektir [44].

$$g(x, y) = T[f(x, y)] \quad (2.12)$$

Burada $f(x, y)$ girdi imgesi, $g(x, y)$ ise işleme tabi tutulmuş imgedir ve T ise f üzerinde bir operatör olup (x, y) 'nin komşu alanı üzerinden tanımlanmıştır. Buna ilaveten T , bir küme girdi imgesi üzerinde işlemde bulunabilir. Bir nokta hakkında (x, y) komşu alanı tanımlamak için ana yaklaşım, Şekil 2.15'da gösterildiği gibi (x, y) noktasında merkezileşmiş bir kare ya da dikdörtgen alt imge kullanmaktır.


Alt imgenin merkezi, örneğin üst sol köşeden başlamak üzere pikseller sıra ile oynatılacaktır. Çıktı g 'yi o noktada oluşturmak için her bir (x, y) mahallinde operatör T uygulanacaktır. (x, y) 'nin komşularını belirtmek için kullanım kolaylıklarından dolayı merkezi (x, y) 'de olan kare ve dikdörtgen matrisler kullanılır. (x, y) piksel piksel kaydırılarak tüm resmin taranması sağlanır. Bu matrisin boyutu en az 1×1 olabilir ve bu da ilgilenilen (x, y) koordinatlarındaki piksele karşılık gelir.



Şekil 2.15 3 x 3 Bir imge içindeki nokta hakkında (x, y) komşu alan

T 'nin en basit şekli, komşunun 1×1 boyutunda, yani tek piksel olduğu zamandır. Bu durumda g , sadece (x, y) noktasında f 'in değerine bağlıdır ve T , şeklin *gri-seviye* (ayrıca yoğunluk veya haritalama olarak da adlandırılır) dönüşüm fonksiyonu haline gelir [44].

$s = T(r)$ olması durumunda, gösterimi basitleştirmek için, r ve s değişkenleri sırası ile f 'nin (x, y) ve g 'nin (x, y) noktasındaki gri seviyesini göstermektedir. Örneğin Şekil 2.16.a da m değerinin altındaki değerlerin kontrastının genişletilmesi ile gri ton değerlerinin azaltılıp daha karanlık yapılması ve m değerinin üstündeki değerlerin ise seviyelerinin parlaklığının artırılması ile daha aydınlık yapılması işlemi yapılmaktadır. Buradaki uç durum ise 2.16.b şıkında görülmektedir. Burada m değerinin altında kalan giriş değerleri için çıkış hep “sıfır” yani siyah, üstünde kalan giriş değerleri için ise çıkış “bir” yani beyazdır. Görüntü siyah-beyaz ‘a dönüşmüştür. Bu işlem eşik fonksiyonu olarak adlandırılır. Her iki şıkta anlatılan işlemler yapılırken bir çıkış görüntüsünde oluşturulan pikselin değeri yalnızca giriş görüntüsündeki ilgilenilen pikselden etkilenir. Bir imgeyi daha iyi hale getirmek, sadece o noktadaki gri seviyeye bağlı olduğu için, bu kategorideki teknikler sıklıkla nokta işleme olarak adlandırılır. İlgilenilen pikselin komşularının da işleme katılmasıyla oluşan matrise maske denir. Daha büyük komşu alanlar, daha fazla esnekliğe imkân verir. Genel yaklaşım (x, y) noktasında g 'yi belirleyebilmek için, (x, y) 'nin daha önceden tanımlanmış komşu alanında f in değerlerinin bir fonksiyonunu kullanmaktır. Bu formülasyon içindeki başlıca yaklaşımlardan bir tanesi, maskelerin kullanılmasıdır (bunlara ayrıca filtreler, çekirdekler, şablonlar veya pencereler de denilmektedir).



Şekil 2.16 Kontrastın daha iyi hale getirilmesi için gri seviye dönüşüm fonksiyonları

2.4. Uzaysal Düzlemde İyileştirme Teknikleri

Bu tezde öncelikle uzaysal düzlemdeki imge iyileştirme tekniklerinden bahsedilmiştir. Özellikle tıbbi amaçla kullanılan imgelerin iyileştirilmesi hedeflendiği için bütün iyileştirme tekniklerine değinilmemiştir. Zira yapılan çalışma, uzaysal düzlemde yapılan iyileştirme tekniklerinden doğrusal olmayan bir çalışmadır. Çoğunlukla, imgedeki belirli

iyileştirme özellikleri, arzu edilmeyen etkileri de ortaya çıkarmaktadır. Çok önemli olan bir imge bilgisi kaybedilebilir ya da iyileştirilmiş imge orijinal şeklin zayıf bir temsili olabilir. İyileştirme algoritmaları orijinal imgede olmayan bir bilgiyi var edemez, ancak imgedeki bazı görünmeyen unsurları görünür hale getirebilir. Bu bölümde, çoğunlukla medikal imgelerde kullanılan imge iyileştirme algoritmaları oluşturulacaktır.

Çoğunlukla imge iyileştirme ve imge nitelendirmede kullanılan bir şeklin histogramı, her bir gri düzeydeki imgede piksellerin sayısını içeren bir vektör olarak tanımlanır. Histogram, $h(i)$, şu şekilde tanımlanabilir [44].

$$h(x, y) = T[f(x, y)] \quad (2.13)$$

$$h(i) = \sum_{x=0}^{M-1} \sum_{y=0}^{M-1} \delta((f(x, y) - i) \quad i = 0, 1, 2, \dots, P - 1 \quad (2.14)$$

Burada;

$$\delta(w) = \begin{cases} 1 & w = 0 \\ 0 & \text{diğer durum} \end{cases} \quad (2.15)$$

Kullanışlı bir imge iyileştirme operasyonu, aynı zamanda maske olarak bilinen ve lokal operatörlerin kullandığı konvolüsyondur. $w(k, l)$ maskesi, maskenin merkezindeki bir nokta olan $(k, l) = (0, 0)$ 'da dizinin katsayılarını $(2K + 1 \times 2L + 1)$ şeklinde düşünürsek, maske ile birlikte şeklin konvolüsyonu Denklem (2.16)'daki gibi tanımlanır:

$$g(x, y) = w(k, l) * f(x, y) = \sum_{k=-K}^K \sum_{l=-L}^L w(k, l) f(x - k, y - l) \quad (2.16)$$

Burada, $g(m, n)$ konvolüsyonun sonucu ya da imgenin çıkışıdır. Şekli maske ile birlikte konvüle etmek için maske, imge piksellerinin (m, n) merkezine yerleştirilir. Maske katsayıları ve bunlara karşılık gelen imge piksellerinin yeni değerleri tespit edilerek bu yeni değerlerin nihai toplamı (m, n) 'de imge çıkışının piksel değeri olarak kullanılır. Çıkış şeklinin tamamı $g(x, y)$, orijinal imgedeki tüm piksellere aynı işlemin tekrar uygulanması ile elde edilir. Bir konvolüsyonun maskesi, özellikli bir iyileştirme operasyonu ya da şeklin özelliklerinin değişimini etkili kılmak için şekle uygulanabilir. Maske katsayılarının spesifik değerleri arzu edilen farklı iyileştirme türlerine bağlıdır [1].

2.4.1 Piksel Bazında İmge İşlemleri

Bir imgenin diğerine bölünmesi gibi bir işleme değindiğimizde, esasında bölünmenin iki imge arasında birbirine tekabül eden pikseller için olduğunu belirtmek gerekir. Bu nedenle mesela eğer f ve g imge iseler, f imgesini g imgesine bölerek

bulduğumuz yeni oluşturulmuş imgenin ilk unsuru, f içinde g pikseli tarafından bölünen ilk pikseldir; tabi ki burada g içinde hiçbir pikselin sıfır değerine sahip olmadığı varsayılmaktadır. Diğer aritmetik ve mantık işlemleri, olaya dâhil olan imgelere tekabül eden pikseller arasında benzer şekilde tanımlanır [44].

2.4.2 Doğrusal ve Doğrusal Olmayan İşlemler

H girdi ve çıktıları imge olan bir operatör olsun. Eğer herhangi f ve g iki imgeyi ve herhangi a ve b iki ölçek için aşağıdaki eşitliği sağlıyorsa, o zaman H için doğrusal operatör denilebilir.

$$H(af + bg) = aH(f) + bH(g) \quad (2.17)$$

Diğer bir ifadeyle, iki imgenin toplamına uygulanan doğrusal operatörün sonucu (gösterilen sabitlerle çarpılmış olan) operatörü teker teker imgelere uygulamakla, uygun sabitlerle sonuçları çarpıp, ondan sonra çıkan sonuçları toplamakla aynıdır. İki imgenin mutlak değerlerinin farkını hesaplayan bir operatör doğrusal değildir. Denklem (2.17) testinden kalan bir operatör tanım olarak doğrusal değildir. İmaj işleminde doğrusal işlemler olağanüstü öneme haizdir, çünkü bunlar çok iyi anlaşılan teorik ve pratik sonuçlara dayanır. Bazen doğrusal olmayan işlemler daha iyi netice verse de, her zaman tahmin edilebilir değildirler ve çoğunlukla teorik olarak çok iyi anlaşılmış değildir [44].

2.4.3 İmgede Kompanzasyon

Çoğu imge mekanizmaları, şeklin doğrusal olmayan yoğunluk profilinin ortaya çıkmasından kaynaklanan doğrusal olmayan yoğunluk özelliklerine sahiptir. Bu özellikte bu etki kısaca;

$$E(x, y) = C(f(x, y)) \quad (2.18)$$

şeklinde tarif edilebilir [3]. Burada elde edilen yoğunluk şekli $f(m, n)$ dir ve bu etki $e(m, n)$ imge sistemi tarafından gerçekleşen yoğunluk çıkışı temsil eder ve burada $C(.)$ doğrusal olmayan bir imge sistem operatörüdür. İmgenin doğrusal olmayan özelliklerini düzeltmek için tersi bir dönüşüm uygulanmalıdır.

$$g(x, y) = T(e(x, y)) = C^{-1}(C(f(x, y))) \quad (2.19)$$

$$g(x, y) = f(x, y) \quad (2.20)$$

Burada $T(\cdot)$, imge sistem operatörü olan $C^{-1}(\cdot)$ 'ye eşit doğrusal olmayan operatördür ve $g(x,y)$ ise çıkış şeklidir. Doğrusal olmamanın özelliklerinin belirlenmesi pratikte zor olabilir. Bununla beraber doğrusal olan yoğunluk ölçme aygıtının, doğrusal olmamanın gerçek özelliklerini belirlemede, imge sisteminin çıkışının ortaya konulması gerekir.

2.4.4 Dinamik Aralık değiştirilerek Yapılan İmge İyileştirme

İmgenin gri ölçeği çok dar veya geniş olduğunda imgedeki bazı detaylar görünür olmaktan çıkar ve istenen bölgelerde ya siyah bir alan ya da beyaz bir alan olarak görünür. Dinamik aralık değiştirilerek, elde edilen yeni imgede daha detaylı bir imge elde edilebilir. Elde edilen imge verisinin dinamik aralığı, imge sisteminin özelliklerini aştığında ya da tam tersi olduğunda kullanılan bir imge iyileştirme yöntemidir. Bu, gözlemcinin özel bir imgede belirgin olarak dar olan yoğunluk bantlarındaki ilgilendiği imge bilgisi olabilir. Yoğunluk derecelemesi, şekli değiştirerek imgedeki belirgin yoğunluk bantlarına gözlemcinin odaklanmasını sağlar. Öyle ki, bu ilgili yoğunluk bandı, imgenin dinamik aralığını kapsar. Örneğin f_1 ve f_2 ilgili yoğunluk bandını tanımlamada bilinirse, dereceleme dönüştürmesi Denklem (2.21)'deki gibi gösterilir;

$$g = \left\{ \frac{e-f_1}{f_2-f_1} \right\} (f_{max}) \quad (2.21)$$

Burada, e ara şeklini, g çıkış şeklini ve f_{max} maksimum görüntü yoğunluğunu ifade etmektedir. Örneğin 8 bit gri ölçekli bir imgede; $f_1=80$ ve $f_2=140$ ise, bu işlem uygulandığında, 80 ve altındaki renk değerleri tam siyaha çekilir, 140 ve üzerindeki değerler de tam beyaza çekilir. Böylece 80 ve 140 arasında bulunan 60 değer, $f_{max}=256$ seviyelik ölçeğe yayılır [3].


2.4.5 İmgede Histogram Eşitlemesi

Histogram, bir imgedeki piksellerin gri seviyelerinin piksel sayısına göre grafiksel gösterimidir. Buna imge histogramı veya gri-düzey histogramı da denir. İmge histogramı, imgenin her bir noktasındaki piksellerin tespiti ile bu piksellerin sayısının ne olduğunu gösterir. Bu sayede histogram üzerinden imge ile ilgili çeşitli bilgilerin çıkartılması sağlanır. Bazen pikseller çok dar bir alanda daha fazla yoğunluk gösterdiklerinde detaylar görünmeyebilir. Bu durumda histogram eşitlemesi yapılarak piksellerin daha eşit bir


şekilde ölçek üzerinde dağılımı sağlanarak detaylar görünebilir hale getirilir. Gri ton değerleri $[0, L - 1]$ aralığında değişen bir sayısal imgenin histogramı,

$$p(r_k) = n_k / N \quad (k = 0, 1, 2, \dots, L - 1) \quad (2.22)$$

ayrık fonksiyonudur. Burada r_k gri ton değerini, n_k imgede bu ton değerinden piksellerin sayısını, N imgedeki toplam piksel sayısını gösterir [1]. Bu şekilde tanımlanmış $p(r_k)$ fonksiyonu, gri ton değerlerinin imgede bulunma olasılıklarının hesabını verir. Uygulamalarda histogramın tanımı çeşitli şekillerde basitleştirilebilir. Örneğin r_k değerindeki k doğrudan tamsayı olarak alınır. Ayrıca imge histogramı gösteren tablolarda çoğu zaman normalize edilmiş değerler yerine her bir gri ton değerinden piksellerin sayısı gösterilir. Şekil 2.17.'de dar bir aralıktaki örnek bir imge ve histogramı ile Şekil 2.18.'de bu imgeye ait histogram eşitlemesi görülmektedir.



Şekil 2.17 Histogram eşitlemesinden önceki imge ve histogramı



Şekil 2.18 Histogram eşitlemesi yapılmış imge ve histogramı

İmge histogramı imgenin genel görünümü hakkında bir bilgi verir. Bu görünüm, histogramda piksellerin yoğunlaştığı bölgelere bakarak çeşitli şekillerde yorumlanabilir. Eğer pikseller histogramın küçük gri ton sayılı değerlerini gösteren bölgelerinde yoğunlaşıyorsa imgenin genel olarak karanlık olduğu sonucuna varılabilir. Pikseller yüksek gri ton değerlerinde yoğunlaşıyorsa çok aydınlık ve beyazın ağırlıklı olduğu bir imge söz konusudur. Pikseller histogramın orta bölgelerinde dar bir alanda yoğunlaşıyorsa şekil 2.17.'deki gibi imgeye gri ton baskındır.

2.4.6 Lokal Operatör Kullanarak İmge İyileştirme

Lokal operatörler her bir piksel için genellikle komşu piksellerin değerlerine bağlı yeni değerler sağlayarak, sadece bu piksele bağlı olan ve diğerleri de buna yakın alanlarda olan imgeyi iyileştirir. Pek çok lokal operatör maske konvülasyonu ile uygulanan doğrusal uzaysal filtrelerdir. Bazıları doğrusal olmayan operatörlerdir [44].


2.4.7 Gri Seviye Dönüşümleri Yaparak İmge İyileştirme

İmgeyi daha iyi hale getirme tekniklerinden biri de piksellerin gri seviyelerinin dönüşümüdür. Bu yöntem, imgeyi daha iyi hale getirmenin en basit teknikleri arasındadır. İşleme tabi tutulmasından önce ve sonraki piksel değerleri, sırası ile r ve s ile gösterilecektir. Daha önceki bölümde gösterildiği gibi, bu değerler şeklin $s = T(r)$ ifade edilmesi ile ilgilidir ve burada T bir piksel değeri olan s 'ye piksel değeri r 'yi haritalayan dönüşümdür. Burada sayısal değerler ele alındığı için, dönüşüm fonksiyonunun değerleri

tipik olarak tek boyutlu dizide saklanır ve r 'den s 'ye kadar olan haritalamalar tablo aramaları aracılığı ile uygulanır. Bir 8 bitlik ortam için, T değerlerini ihtiva eden bir arama tablosunda 256 giriş bulunması gerekir [48].

2.4.8 İmgenin Tümleyenini Alarak Görüntü İyileştirme

Bir görüntünün bazen tersi alınarak daha bazı bölümlerin daha iyi görünmesi sağlanabilir. Bir resmin negatifini bulmak için, her bir noktanın renginin tümleyeni alınır. Yani ölçek büyüklüğü L ise, rengin değeri L değerinden çıkarılarak her bir noktanın tersi bulunmuş olur. Şekil 2.19'de, sayısal negatif alma işleminin dönüşüm fonksiyon grafiği verilmiştir [49].



Şekil 2.19 Negatif alma işlemi


İmgenin renk ölçeğinin boyutu L ise her nokta için gri düzeyler, $[0, (L-1)]$ aralığında olacaktır. Bu durumda, resmin negatifi şöyle bulunabilir:

$$s = (L - 1) - r \quad (2.23)$$

s : noktanın negatif renk değeri


r : noktanın renk değeri

L : renk ölçeğinin boyutu



Şekil 2.20 İmge iyileştirmede kullanılan bazı basit dönüşüm fonksiyonları

Şekil 2.20’de da görüldüğü gibi giriş ve çıkış gri seviyelerinin fonksiyona bağlı değişimleri imge üzerinde doğrusal ve doğrusal olmayan bazı işlemlerin gerçekleştirilmesini sağlamaktadır. Bu işlemler kontrastın artırılması, imgenin tümleyeninin alınması gibi işlemler olduğu gibi, imgenin saturasyon değerlerindeki değişiklikler de olabilir [49]. Bu şekilde bir imgenin yoğunluk seviyelerini tersine çevirmek, bir fotoğrafın negatifine eş değer sonucu üretmektedir. Bu tip işlem özellikle bir imgenin koyu kesimlerdeki beyaz veya gri detayı daha belirgin hale getirmek için uygundur. Bir örnek Şekil 2.21’de verilmiştir.




Şekil 2.21 a) Orijinal sayısal mamogram b) Eş (2.24)’deki negatif dönüşümü kullanarak elde edilen negatif imge (G.E. Tıbbi sistemleri tarafından temin edilmiştir)

Orijinal imge, küçük bir lezyonu gösteren bir sayısal mamogramdır. Her iki imgede da görsel içerik aynı olmasına rağmen, özellikle bu durum için negatif imgede göğüs dokusunu analiz etmenin ne kadar daha kolay olduğu görülmektedir.

2.4.9 Kontrast Arttırma Dönüşümü ile İmge İyileştirme

En basit doğrusal fonksiyonlardan biri kontrast artırma dönüşümüdür. Düşük kontrastlı imgeler kötü aydınlatma, görüntüleme algılayıcısındaki dinamik aralık eksikliği, veya imge alınması esnasında mercek açıklığının yanlış ayarlanması sonucu olabilir. Kontrast artırmanın arkasındaki fikir, işleme tabi tutulmakta olan imgede, gri seviyelerin dinamik aralığını artırmaktır. Özellikle bu durumlara röntgen çekimlerinde veya MR imgelerinde sıkça rastlanmaktadır. İmgenin kontrastına bağlı değişimi görmek için Şekil 2.22.a'da, kontrast artırmada kullanılan tipik bir dönüşüm incelenebilir. Noktalar (r_1, s_1) ve (r_2, s_2) dönüşüm fonksiyonunun şeklini kontrol etmektedir. Şekil 2.22.b, düşük kontrast ile 8 bitlik bir imge göstermektedir. Şekil 2.22.c, kontrast büyütmesinin sonucunu göstermektedir. Bu, sırası ile imgedeki minimum ve maksimum gri seviyelerin r_{min} ve r_{max} gösterilmesi ile aşağıdaki şekilde ayarlanarak gerçekleştirilmiştir [44].


$$(r_1, s_1) = (r_{min}, 0) \text{ ve } (r_2, s_2) = (r_{max}, L-1).$$



a)



b)



c)

d)

Şekil 2.22 Kontrast arttırmanın imge üzerinde oluşturduğu değişiklikler;

a) Dönüşüm fonksiyonunun şekli, b) Düşük kontrastlı bir imge, c) Kontrastı arttırılmış imge, d) Eşiklenmiş imge

Şekil 2.22.c’de kontrast arttırılarak imgedeki detayların nasıl ön plana çıktığı görülmektedir. Bu durum özellikle MR ve CT de çekilen hatalı çekimlerin daha görünür hale gelmesinde etkili bir yöntemdir.


2.5. Temel İmge Operatörleri

2.5.1 İmge Kaydırma:

Verilen bir imgenin piksellerinin koordinatlarının yatay ve düşey eksenler boyunca belirlenen sabit değerler miktarınca yer değiştirilmesi işlemine imge kaydırma denir. Orijinal imgenin piksel değerleri $I(r, c)$ ile temsil edilirse ötelenmiş imgenin piksel değerleri şu şekilde gösterilir [2].

$$r' = r + r_0 \quad (2.24)$$

$$c' = c + c_0 \quad (2.25)$$




Şekil 2.23 İmge kaydırma;

a)Orijinal imge, b) r_0 kadar sağa, c_0 kadar yukarı kaydırılmış imge

2.5.2 İmge Kesme (Parça çıkarma):

Verilen bir imge matrisinden, imgenin belirli bir bölümünü işaret eden dikdörtgen şeklin koordinatları vasıtasıyla çıkarılması işlemine parça çıkarma denir [2].




Şekil 2.24 İmgeden parça çıkarma;

a)Orijinal imge, b) Parça çıkarma işlemi

2.5.3 İmge Aynalama

İmge aynalama operatörü girişine uygulanan sayısal imgeyi yatay veya dikey eksene göre aynalamak suretiyle çıkış imgesini oluşturan bir görüntü süzgecidir. Bu nedenle yatay operatör (H) ve dikey operatör (V) olmak üzere iki farklı şekilde tanımlanır. Şekil 2.25'te bu operatörlerin çalışma şekli gösterilmektedir [2].



Şekil 2.25 İmge aynalama işlemleri

İmge aynalama operatörünün giriş çıkış ilişkisi şu şekilde tanımlanabilir. $H(.)$ ve $V(.)$ sırasıyla yatay ve dikey imge aynalama operatörlerini temsil etsin. u imge döndürme operatörünün girişine uygulanan bir sayısal imgeye, $u[l,c]$ ise bu imgenin (l,c) koordinatlarında bulunan bir pikselini gösterebilir. Burada l ve c sırasıyla satır ve sütun indislerini temsil etmekte olup, $L \times C$ boyutlarındaki bir giriş imgesi için $1 \leq l \leq L$ ve $1 \leq c \leq C$ 'dir. Benzer şekilde h yatay imge döndürme operatörünün çıkışında elde edilen $h=H(u)$ imgesini ve v dikey imge döndürme operatörünün çıkışında elde edilen $v=V(u)$ imgesini temsil etsin. Bu tanımlar ışığında h ve v imgesi u imgesinin sırasıyla x ve y eksenini boyunca aynalanmış hali olup, h ve v imgelerinin pikselleri u imgesinin piksellerinden aşağıdaki şekilde elde edilmektedir [2].

$$h[l, c] = u[l, C - c + 1] \quad (2.26)$$

$$v[l, c] = u[L - l + 1, c] \quad (2.27)$$

Burada $l=1,2,\dots,L$ ve $c=1,2,\dots,C$ 'dir

Yukarıdan da anlaşılabileceği gibi u imgesinin $L \times C$ piksel boyutlarında olması durumunda çıkışta oluşacak olan v ve h görüntülerinin boyutları yine $L \times C$ olacaktır. Sonuç olarak bu işlemler incelendiğinde ileri yönde ve ters yönde yapılan aynalama işlemlerinin aynı çıktıyı verdiği anlaşılmaktadır.

$$H(u) = H^{-1}(u) \quad (2.28)$$


$$V(u) = V^{-1}(u) \quad (2.29)$$

2.5.4 İmge Döndürme

Verilen bir imgenin piksellerinin koordinatlarının bir açı miktarınca döndürülmesi işlemine imge döndürme denir. Döndürme operatörü, giriş imgesinin (x_1, y_1) piksel pozisyonunu 0 orijini etrafında kullanıcı tarafından belirlenmiş bir açı kadar döndürerek çıkış imgesinde (x_2, y_2) pozisyonunda haritalayan bir geometrik dönüşüm sağlar. İmge sınırlarının dışında olan konumlar ihmal edilir. Döndürme operatörünün, yönlendirme operatörlerinin yer aldığı uygulamalarda önilemci olarak kullanımı faydalı olmasına rağmen, genellikle bir imgenin görsel durumunu düzeltmek için kullanımı daha yaygındır. Döndürme operatörü şu dönüşümü gerçekleştirir:

$$x_2 = \cos(\theta) \cdot (x_1 - x_0) - \sin(\theta) \cdot (y_1 - y_0) + x_0$$

$$y_2 = \sin(\theta) \cdot (x_1 - x_0) + \cos(\theta) \cdot (y_1 - y_0) + y_0$$



Şekil 2.26 İmge döndürme;

a)Orijinal imge, b) 90° döndürülmüş imge

Burada (x_0, y_0) , giriş imgesindeki döndürme merkezinin koordinatları ve θ , döndürme açısıdır. Dönüşüm işlemi, orijinal giriş imgesinin boyutlarıyla tanımlanan imge sınırları içinde uygun olmayan (x_2, y_2) çıkış yerlerini oluşturur. Böyle durumlarda, imge dışında oluşturulan son elemanlar çoğu zaman ihmal edilmektedir. Döndürülen imgeler dışında kalan boş pikseller genellikle siyah piksellerle doldurulur. Döndürme algoritması, dönüşümün uygulanmasından farklı olarak tamsayı olmayan bir (x_2, y_2) koordinatı üretebilir. Her bir tamsayı pozisyonundaki piksel yoğunluğunu üretmek için farklı deneysel yöntemler kullanılabilir. Örneğin buna ilişkin iki kural:

- Her tamsayı piksel pozisyonundaki yoğunluk seviyesini, en yakın tamsayı olmayan (x_2, y_2) komşu değerini kabul etmeye müsaade eder.
- Her tamsayı piksel pozisyonundaki yoğunluk seviyesini, en yakın tamsayı olmayan n değerinin ağırlıklı ortalamasını temel alarak hesaplar. Ağırlık, gösterimin yanındaki piksel örtüşme veya uzaklıkla orantılıdır. Sonraki metot daha iyi sonuçlar verir fakat algoritmanın hesaplanması için gereken süreyi uzatır.

2.5.5 Kenar Çıkarma

İmge analizinde en fazla kullanılan işlemlerden biri kenar tespiti. Kenar tespiti, sıklıkla objelerin sınırlarını tespit etmek ve gri seviye imgelerde objeleri arka plandan ve birbirinden ayırmak amacıyla kullanılmaktadır. Kenar bir imgede kısa mesafede büyük parlaklık değişimi olarak ifade edilmektedir. Bu anlamda kenar, esas olarak imgedeki iki farklı bölgeyi birbirinden ayıran sınırı oluşturan en temel bilgidir. Kenar algılama işlemi, bir imgenin belirgin bölgesel değişikliklerini tespit etme işlemidir.

Kenar çıkarma birçok uygulamada imge boyutunun azaltılmasını sağlar. İmge boyutunu azaltmak, imge depolama ve sorgulama işlemlerinde büyük öneme sahiptir. İmgedeki kenarları bulup siyah beyaz bir imge elde etmek, yapılan aramaların dar bir alanda yapılmasını ve dolayısıyla daha hızlı sonuca ulaşılmasını sağlar [2].

Bir nesne ile arka plan arasındaki geçiş bölgesi sınır olarak adlandırılır. Bunun yanında üst üste gelen iki nesne arasındaki geçiş bölgesi de sınır tanımına girer. Sınırın kenar piksellerinin birleşiminden meydana gelmesi, yani kenarların nesnenin sınırlarını belirlemesi bu işlemin oldukça sık kullanılmasına neden olur.

Kenar tespiti bazı uygulamalarda bölütleme (segmentation) işleminin de ön aşamalarındandır. Bölütleme, bir imge üzerindeki eş özellikli piksel bölgelerinin belirlenmesi işlemi olarak tanımlanabilir. İmge işlemede bölütleme çok önemli ancak bir o kadar da zor bir işlemdir. Çeşitli bölge tanıma işlemleri gerektiren bu işlem, genellikle ilgili olunan kısımları imgenin diğer kısımlarından ayırmak için kullanılır. Pek çok araştırmacı tarafından değişik kenar algılayıcılar geliştirilmiş olup bunların büyük bir kısmı türeve dayalı kenar çıkarma maskeleridir. Bu maskelerin uygulanmasında orijinal görüntü ile ilgili kenar maskesinin konvolüsyonu incelenir. Konvolüsyon genliği, ilgili pikselin kenar genliği ile orantılı bir değer vermektedir [2].

Türeve dayalı popüler kenar çıkarma operatörleri arasında Roberts, Sobel, Prewitt ve Canny sayılabilir. Her bir kenar algılayıcıda, gradyent boyu verilen maskeler yardımı ile hesaplanır. Eğer herhangi bir pikseldeki gradyent boyu belirli bir eşik değerinden yüksek ise, o piksel bir kenar pikseli olarak değerlendirilir. Sadece kenar noktalarına ilişkin bilgi üreten Roberts; hem kenar noktalarına ilişkin bilgi hem de kenarın yönelimi ile ilgili bilgi üreten Sobel ve Prewitt; sabit bir maskenin, sekiz yön için, sekiz farklı durumunu imgeye uygulayan Kirsch ve Robinson; ikinci türeve dayanan Laplacian vb. yöntemler kenar tespitinde sıklıkla kullanılan yöntemlerdir [50]. Kenar çıkarma operatörü olarak işlem kolaylığı ve performansının uygunluğu sebebiyle Sobel operatörü sıklıkla kullanılmaktadır. Bu yüzden aşağıda Sobel operatörü ile ilgili bir miktar detay verilecektir.

2.5.6 Sobel Kenar Çıkarıcı

Sobel operatörü, imgede iki boyutlu yüzeysel gradyent ölçümünü gerçekleştiren 3x3'lük komşulukları kullanan bir operatördür. Kenarlara karşılık gelen yüksek frekanslı bölgeleri vurgular. Bu metot genellikle gri ölçekli imgede bulunan bütün noktadaki yaklaşık mutlak gradyent büyüklüğünü bulmak için kullanılır. Sobel satır ve sütun maskeleri aşağıdaki gibidir [2].

Sobel satır ve sütun maskeleri aşağıdaki gibidir.


Satır maskesi

$$\begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}$$

sütun maskesi

$$\begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$$

Bu maske yatay ve dikey yönlerde kenarın büyüklüğünü bulmak ve ardından bunları tek bir matriste birleştirmek için kullanılır. Sobel kenar çıkarıcı kenar bilgisini araştırırken satır ve sütun kenar çıkarma maskesi imgeye aşağıdaki şekilde uygulanır. Hedef pikselin değeri, maske ile imgenin örtüşen piksellerinin çarpılmasıyla elde edilen 9 adet değer toplanıp mutlak değerinin alınmasıyla hesaplanır. Şekil 2.27’da görüldüğü gibi, maske merkezleri imgedeki her piksel ile örtüşecek şekilde imgedeki her piksel sırasıyla taranarak imgenin kenarları bulunur. Satır maskesi yapısı gereği imgedeki yatay kenarları açığa çıkarırken sütun maskesi imgedeki dikey kenarları açığa çıkarır [51].



Şekil 2.27 Sobel kenar çıkarmasında konvolüsyon işlemi

$x[r,c]$ bir imgenin (r,c) konumundaki parlaklık değeri olsun. Burada r ve c sırasıyla satır ve sütun indisleridir ve $R \times C$ piksel büyüklüğündeki bir imge için $1 \leq r \leq R$ ve $1 \leq c \leq C$ dir. Bu imgenin $x(r,c)$ pikselinin Sobel kenar büyüklüğü $E(r,c)$ şu şekilde hesaplanır:

$$E[r,c] = m^2H + m^2V \quad (2.30)$$

Burada, mH ve mV yatay ve dikey yönlerdeki kenar büyüklüklerini göstermektedir. Bu büyüklükler şu şekilde hesaplanır [52].

$$m_H = \sum_{i=1}^3 \sum_{j=1}^3 x[r-2+i, c-2+j]M[i,j] \quad (2.31)$$

ve

$$m_V = \sum_{i=1}^3 \sum_{j=1}^3 x[r-2+i, c-2+j]M[i, j] \quad (2.32)$$

Maskleme işleminden sonra her bir pikselin yerine ait iki değer oluşur. Birinci değer S_1 , satır maskesinden elde edilen sonuç; ikinci değer S_2 , sütun maskesinden elde edilen sonucu göstermektedir.

$$\text{Kenar büyüklüğü; } \sqrt{s_1^2 + s_2^2} \quad \text{Kenar yönü; } \tan^{-1} \left[\frac{s_1}{s_2} \right]$$

Kenar yönü, kenarın kendisine diktir. Çünkü yön, gri seviyenin değiştiği anlardaki grandyentin yönüne karşılık gelmektedir. Sobel Gradienti kullanılarak elde edilen kenar çıkarma imgesi Şekil 2.28’de görülmektedir.



Şekil 2.28 Sobel Gradienti kullanılarak gerçekleştirilen kenar bulma operasyonu

3. İMGEDE OLUŞAN GÜRÜLTÜLER

Günümüzde sayısal imgelerin kullanımı her geçen gün artmaktadır. Özellikle uydu televizyonu, manyetik rezonans görüntüleme (MR), tanı-teşhis sistemleri (computed axial tomography), coğrafik bilgi sistemleri, ultrasonik görüntüleme ve astronomi alanlarında sıklıkla kullanılmaktadır. Sayısal imgeler kayıt esnasında farklı sebeplerden dolayı gürültüden etkilenirler. Özellikle kaydedilen imge ile kaydedici sistem arasında yer alan ortamın ideal olmaması (rasgele saçılma ve soğurulma) veya kaydedici sistemin ideal olmaması (sensör gürültüsü, sınırlı sistem doğruluğu, sonlu duyarlılık ve kuantalama hataları vs.) ya da iletim esnasında alıcı ile verici arasındaki hatalardan meydana gelir [1]. İmgelerde ortaya çıkabilecek her türlü istenmeyen işaretin genel adı olan gürültü, bozucu işaretler olarak ya da esas işarete etkiyerek işaretin yapısını tamamen veya kısmen tahrip eden rasgele işaretler olarak tanımlanır [2]. İmge üzerinde oluşabilecek bozulmaların birçok nedeni vardır. Yukarıda bahsedilenlerin dışında:

- Ortamın aydınlık seviyesinin düşük olması
- Atmosferik türbülansın kaynaklanan bulanıklaşma
- Çekim esnasında kameranın veya imgelenen nesnenin hareketi,
- Merceklerden kaynaklanan geometrik bozulmalar
- Analog imgelerin sayısal ortama aktarılırken bozulmaya uğraması
- Niceleme etkileri
- Mekanik sistemlerden kaynaklanan girişimler sayılabilir.

3.1. İmgelerde Doğal Yollarla Oluşan Gürültü Çeşitleri

Doğal yollarla ortaya çıkan gürültüler aşağıdaki gibi sınıflandırılmaktadır:

Foton gürültüsü: Işığın doğal ve temel özelliklerinden biridir. Işık beraberinde gürültü de getirir (Gürültü miktarı, sinyalin karekökü kadardır).

Termal gürültü: Foto diyot ışık almazken bile karanlık akımı olarak adlandırılan bir akıma sahiptir ve bu akım sürekli bir gürültü kaynağıdır.

Yonga üzerindeki elektronik gürültü: Sinyalin sensörden okunması sırasında meydana gelen bir gürültü çeşididir.

KTC gürültüsü: Bir FET'in kapı ucuna bağlı kapasitördeki gürültü KTC (K: Boltzman sabiti, T: Sıcaklık, C: Kapasite) gürültüsü olarak adlandırılır ve bu gürültü ihmal edilemeyen bir gürültüdür.

Yükseltici gürültüsü: Okuma gürültüsü olarak da adlandırılır ve çıkış yükseltici tarafından üretilir.

Kuantalama gürültüsü: Kuantalama gürültüsü, genlik kuantalama işleminin doğasından kaynaklanan bir gürültü biçimidir ve analog-dijital dönüştürücülerde meydana gelir.

Darbe Gürültüsü: Darbe gürültüsü her yerde bulunabilen gürültünün özel bir çeşididir. Darbe gürültüsü imgenin kalitesini önemli ölçüde düşürür bu yüzden giderilmesi gerekir.

3.1.1 Darbe Gürültüsü

Darbe gürültüsü, gürültünün özel bir türü olup bunun birçok kaynağı olabilir. Sayısal yayıncılıkta işaret bilgisinin iletiminde karşılaşılan veri kayıpları, asıl işaret üzerinde darbe şeklinde ortaya çıkmaktadır. Çünkü bit boyutunda veriler halinde iletilen bilgi paketçiklerinden herhangi birisi veya bu paketçiklerden bir bölümü bozulacak olur ise, ilgili bilginin sayısal değeri değişir. Bu durumda ortaya çıkan hata, darbe gürültüsü olarak adlandırılmaktadır. Başka bir deyişle imgedeki piksellerin parlaklık değerleri çoğunlukla komşu piksellerin parlaklık değerlerine yakın değerler almaktadır. Eğer bir pikselin parlaklık değeri komşu piksellerin parlaklık değerinden önemli oranda farklılık gösteriyor ise bu piksel gürültü olarak değerlendirilmektedir. İmgede bozulmalara yol açan bu tür gürültülere darbe gürültüsü denilmektedir [2]. Genel olarak literatürde tanıtılan darbe gürültüsü modelleri, darbe gürültüsünün imgeye eş dağılımlı bir şekilde etkilediğini öngören modellerdir [53-56]. Literatürde darbe gürültüsünü matematiksel olarak modellemek için önerilen birçok model bulunmaktadır. Darbe gürültüsü analitik olarak:

$$U_{(i,j)} = \begin{cases} n_{i,j}, & \text{olasılığı } p \\ 0_{i,j}, & \text{olasılığı } (1 - p) \end{cases} \quad (3.1)$$

Burada i ve j piksel lokasyonunu ve p gürültülü pikselin gelme olasılığını ifade eder. Bu durumda gürültüsüz pikselin gelme olasılığı $(1-p)$ olur. Darbe gürültüsünün olasılık karakteristiği Denklem (3.1)'de ifade edilmiştir.

Yukarıdaki ifadede $0_{i,j}$ orijinal imgeyi, $n_{i,j}$ gürültüyü, $U_{(i,j)}$ gürültülü imgeyi ve p ise gürültü yoğunluğunu temsil etmektedir. $n_{i,j}$ değeri iki tür gürültü tipine bağlıdır.

Sabit Değerli Darbe Gürültüsü: Darbe gürültüsünün, orijinal işaretin dinamik aralığı içerisinde minimum veya maksimum değerlere sahip darbeler şeklinde ortaya çıktığı varsayımına dayalı olan modellerdir [57, 58]. 8-bit bir imge için sadece 0 ya da 255 değerini alır. Bu gürültü tipinde gürültülü pikseller maksimum ya da minimum değerler aldığı için resmin üzerinde siyah ya da beyaz nokta olarak görünmektedirler. Bu yüzden tuz, biber gürültüsü olarak da adlandırılırlar. Tuz, biber gürültü modelinde gürültü Denklem(3.2)'de gösterilen iki değerden birini alır.

$$Sabit\ Değerli\ Darbe\ Gürültüsü = \begin{cases} Biber, & n_{i,j} = 0 \\ Tuz, & n_{i,j} = 255 \end{cases} \quad (3.2)$$

Rastgele Değerli Darbe Gürültüsü: 8-bit bir imge için [0-255] aralığında herhangi bir değer alabildiği varsayımına dayalı olan darbe gürültüsü modelidir [59,60]. Bu tür bir gürültü, orijinal işaretin dinamik aralığı içerisinde bulunduğu için gürültü mü yoksa asıl işaret mi olduğunu belirlemek oldukça güçtür.

Sabit değerli darbe gürültüsü gelme olasılığı $p/2$, rastgele değerli darbe gürültüsü piksel gelme olasılığı $p/2$ ve gürültüsüz piksel gelme olasılığı $(1-p)$ ile ifade edilirse, bu ifadeye ait olasılık karakteristiği Denklem (3.3) ile gösterilebilir.

$$U_{(i,j)} \begin{cases} n_{i,j} & (0\ veya\ 255)\ olasılığı\ p/2 \\ n_{i,j} & [0, 255]\ olasılığı\ p/2 \\ 0_{i,j} & olasılığı\ (1-p) \end{cases} \quad (3.3)$$

3.2. İki Aşamalı Uyarlamalı Hızlı Medyan Filtre (DCFAMF)

Geleneksel medyan tabanlı filtreler, darbe gürültüsünü temizlemek için kullanılan etkili doğrusal olmayan filtrelerdir. Darbe gürültüsünü silerken kenarları da iyi bir şekilde korumak için çeşitli filtre şemaları sunulmuştur. Ancak bu filtreler sadece düşük gürültü yoğunluklarında iyi performans gösterebilmektedirler. Ancak yüksek gürültü oranlarında iyileştirilmiş resmin detaylarında bulanıklaşma ve kaybolma meydana gelmekte, bu da resmin kalitesini düşürmektedir. Bu bölümde önerilen filtre, darbe gürültüsünü detaylara zarar vermeden başarılı bir şekilde silerken, aynı zamanda basit yapısı hızlı algoritması ve farklı imgeler için ayar gerektirmeyen bir yapıya sahiptir. Özellikle aşırı derecede darbe gürültüsüne maruz kalmış resmin detayları başarılı bir şekilde korunabilmiştir.

Biyomedikal imgelerin gürültü bileşenlerinden arındırılması ise, hastalıklara teşhis koymada sağladığı kolaylık ve bu teşhislerin doğruluğunu artırması nedeniyle günümüzde

biyomedikal sistemlerde mutlaka kullanılan ve aranılan bir özellik olmuştur [61]. Çünkü yaşamsal öneme sahip biyomedikal bir imgede bazı detayların kaybolması hem tanı ve teşhiste güçlük, hem de hata yapılmasına sebep olabilmektedir [62]. Bu yüzden gürültü giderici filtrelerin bir yandan darbe gürültüsünü gidermesi, diğer yandan imgenin sahip olduğu detayları koruması gerektiğinden, imge verisinden gürültünün etkin bir şekilde giderilmesi oldukça zor bir işlemdir. Geleneksel gürültü yok etme tekniklerinin asıl imgenin sahip olduğu detayları bulanıklaştırma ve bilgi kaybına neden olma gibi istenmeyen yönleri mevcuttur.

Bu bölümde güçlü gürültü belirleme algoritmasına hibrit olarak eklenmiş uyarlamalı medyan filtre kombinasyonundan oluşmuş hızlı bir filtre sunulmaktadır. Bu kısımdan itibaren önerilen filtrenin ismi İki Aşamalı Uyarlamalı Hızlı Medyan Filtre (DCFAMF) olarak kullanılacaktır. DCFAMF hızlı, basit, aynı zamanda geleneksel filtrelerden daha iyi sonuçlar vermektedir. Filtrenin aşırı derecede darbe gürültüsünü etkili biçimde silerken imgenin detaylarını da etkili biçimde koruduğu görülmüştür. DCFAMF tüm değişik sistemlerde kullanılabilirken, herhangi bir ayar değişimi söz konusu değildir.

3.3. Rastgele Değerli Darbe Gürültüsü Belirleme Süreci

Rastgele değerli gürültü bulaşmış bir imgedeki gürültülü pikseli belirlemek, sabit değerli bir gürültüyü belirlemeye göre çok daha zordur. Çünkü gürültülü piksel değerinin komşu piksel değerinden farkı çok büyük olabildiği gibi çok küçük değerlerde de olabilir. Bu yüzden geleneksel medyan tabanlı filtreler, özellikle rastgele değerli yüksek gürültü oranlarında iyi performans göstermezler. Bir pikselin gürültü olup olmadığını belirlemek için birçok filtre kullanılmaktadır. Ana yaklaşım algoritmanın sadeliği ve başarısıdır.

	j-1	j	j+1
i-1	a ₁	a ₂	a ₃
i	a ₄	A_{scan}	a ₅
i+1	a ₆	a ₇	a ₈

Şekil 3.1 İncelenen piksel yoğunluğu ve 3×3 penceredeki koordinatları

Rastgele değerdeki gürültüyü belirleme süreci iki aşamadan meydana gelmektedir. Birinci aşama; iterasyonun başlangıcında, Şekil 3,1'deki pencereleme yapılmış olan

merkezi piksel A_{scan} 'nin sağında ve solunda bulunan en yakın iki değeri olan a_4 ve a_5 piksellerinin farkı alınır. Bulunan bu fark değeri, $|A_{scan} - a_4|$ veya $|A_{scan} - a_5|$ değerlerinden büyük olmamalıdır. Aynı şekilde merkezi piksel A_{scan} 'nin üstünde ve altında bulunan en yakın iki değeri olan a_2 ve a_7 piksellerinin farkı alınır. Bulunan bu fark değeri, $|A_{scan} - a_2|$ veya $|A_{scan} - a_7|$ değerlerinden büyük olmamalıdır.

$$\begin{aligned} F1 &= |a_4 - a_5| & F11 &= |a_2 - a_7| \\ F2 &= |A_{scan} - a_4| & F22 &= |A_{scan} - a_2| \\ F3 &= |A_{scan} - a_5| & F33 &= |A_{scan} - a_7| \end{aligned}$$

$$A_{scan} = \begin{cases} \text{Gürültülü Piksel,} & (F2 \text{ veya } F3 > F1) \text{ veya } (F22 \text{ veya } F33 > F11) \\ \text{Gürültüsüz Piksel,} & \text{Diğer Durumlar.} \end{cases}$$

İkinci aşama; gürültü yoğunluğu fazla olan imgelerde bazen, bazı gürültülü piksel değerleri birinci aşamada belirlenemeyebilirler. Böyle durumlarda merkezi pikselin çapraz değerleri arasındaki farkın da karşılaştırılması gerekir. İkinci aşamada bu işlem gerçekleştirilir.

$$\begin{aligned} Fa &= |a_3 - a_6| & Faa &= |a_1 - a_8| \\ Fb &= |A_{scan} - a_3| & Fbb &= |A_{scan} - a_1| \\ Fc &= |A_{scan} - a_6| & Fcc &= |A_{scan} - a_8| \end{aligned}$$

$$A_{scan} = \begin{cases} \text{Gürültülü Piksel,} & (Fb \text{ veya } Fc > Fa) \text{ veya } (Fbb \text{ veya } Fcc > Faa) \\ \text{Gürültüsüz Piksel,} & \text{Diğer Durumlar.} \end{cases}$$

Gürültü kararı verilen piksel işaretlenerek sonraki pikselde bu gürültülü pikseller restorasyon aşamasında kullanılmayacaklardır. İki aşama sonunda da gürültü kararı verilirse, A_{scan} etrafında pencereleme oluşturulup restorasyon aşamasına geçilir.

3.4. Geliştirilmiş İki Aşamalı Uyarlamalı Hızlı Medyan Filtresi Kullanılarak Tıbbi İmgelerdeki Darbe Gürültüsünün Bastırılması

Filtrelerin başarısı restorasyon aşamasından ziyade, gürültü belirleme algoritmalarının başarısına bağlıdır. Bu aşamada daha önceden gürültü olarak işaretlenmiş piksel etrafında en küçük pencereleme olan 3x3 pencereleme oluşturularak restorasyon aşamasına geçilir. İmgelerde pencereleme işlemi uygulanırken, düşük gürültü yoğunluklarında küçük pencereleme, büyük gürültü yoğunluklarında ise genellikle büyük pencerelemeye tabi tutulur. DCFAMF'nin işleyişi aşağıdaki gibidir.

1.Aşama: İncelenen piksel kırmızı kutu ile işaretlenen pikseldir. Bu piksel değeri detektör tarafından daha önce işaretlenmediği için (Gürültülü pikseller “*” işareti ile işaretlenmiştir), piksel üzerinde herhangi bir işlem yapılmaz. Çünkü incelenen piksel detektöre göre resmin orijinal bir parçasıdır. Bu işlem hem algoritmanın hızını artırmakta hem de imge kalitesine büyük katkıda bulunmaktadır.

	j			156	165	167	165	170	171	171
	163	164	180	182	175	172	170			
	*	175	188	205	0	178	*			
i	255	255	*	*	165	*	*			
	167	0	182	*	*	*	*			
	172	180	0	*	*	*	*			
	175	0	255	200	*	*	*			

2.Aşama: a) Eğer merkezi piksel, gürültü olarak işaretlenmişse aşağıdaki pencereleme işlemine tabi tutulur.

$$i(* * \boxed{160 \ 175 \ 185} * * * *)$$

Geleneksel filtreler restorasyon aşamasında tüm pikselleri kullanırken önerilen bu algoritma, bozuk piksel yerine gelebilecek değeri sadece bozulmamış piksellerden seçmektedir. Buradaki seçim, $U(i, j) = 175$

	j			156	165	167	165	170	171	171
	163	164	180	182	175	172	170			
	*	175	185	*	0	178	*			
i	255	*	*	*	165	*	*			
	167	*	160	*	*	*	*			
	172	180	0	205	150	*	*			
	175	0	255	200	*	*	0			

b) Eğer gürültülü piksel etrafındaki tüm komşu pikseller detektör tarafından gürültü olarak işaretlenmişse, pencereleme boyutu olarak bir üst seviye olan 5x5 tercih edilir.

	j			156	165	167	165	170	171	171
	163	164	*	182	175	172	170			
	*	175	188	205	0	178	*			
i	255	255	*	*	*	*	*			
	167	0	182	*	*	*	*			
	172	180	0	*	*	*	*			
	175	0	*	200	*	204	*			

$$i(* * \boxed{* * *} * * * *)$$

3. Aşama: Pencere boyutunun 5x5 yapılmasına rağmen, pencerelenen tüm pikseller hala gürültülü ise pencere boyutu 7x7'ye çıkarılır. 7x7 pencerelemesinde tüm pikseller hala gürültülü ise, bu durumda pencere boyutu daha fazla arttırılmaz. Çünkü pencere boyutu arttıkça detaylar kaybolmakta ve netlik de azalmaktadır.

$$i \begin{pmatrix} & & & j & & & \\ 156 & 165 & 167 & 165 & 170 & 171 & 171 \\ 163 & 164 & * & 182 & 175 & 172 & 170 \\ * & 175 & 188 & 205 & 0 & 178 & * \\ 255 & 255 & * & * & * & * & * \\ 167 & 0 & 182 & * & * & * & * \\ 172 & 180 & 0 & * & * & * & * \\ 175 & 0 & * & 200 & * & 204 & * \end{pmatrix}$$

4.Aşama: Son aşama pencere büyüklüğünü daha fazla arttırmak yerine, bir önceki işlemde tahmin edilen komşu pikselin değeri atanır. Son piksele kadar iterasyon bu şekilde devam eder. Özellikle bu aşama, imge kalitesinde bozulmaya sebep olmamakta ve pencere boyutu daha fazla arttırılmadığı için algoritmanın hızını büyük oranda arttırmaktadır.

3.4.1 Simülasyon Sonuçları

Bu kısımda son zamanlarda darbe gürültüsünü yok etmek için popüler olarak kullanılan filtreler ile bu tezde önerilen filtreler karşılaştırılmıştır. Deneysel sonuçların tümü MATLAB programı yardımıyla elde edilmiştir. Deneylerdeki test imgesi için literatürde popüler olarak kullanılan beyin MR [63] imgesi kullanılmıştır. Karşılaştırma için bozulmuş imgeler hem geleneksel hem de modern yöntemler vasıtasıyla iyileştirilmiş, iyileştirilmiş imge ile orijinal imge arasındaki restorasyon kalitesini belirlemede literatürde iyi bilinen ve sıklıkla kullanılan Tepe Sinyali-Gürültü Oranı (PSNR) ve Hataların Kareleri Toplamının Ortalaması (MSE) [64] kriterleri kullanılmıştır.


$$PSNR = 10 \log_{10} \frac{255^2}{MSE} \quad (3.4)$$

$$MSE = \frac{\sum_{i=1}^N \sum_{j=1}^M ((r_{i,j} - x_{i,j}))}{M \times N} \quad (3.5)$$

Burada $M \times N$ imgenin boyutu, r orijinal imge ve x iyileştirilmiş imgeyi ifade etmektedir.

DCFAMF'nin görsel performansını kanıtlamak için Beyin MR imgesine %40 gürültü eklendikten sonraki iyileştirme sonuçları Şekil 3.2'te görülmektedir. Tablo 3.1'de

ise DCFAMF ile çeşitli filtrelerin, PSNR ve MSE değerleri sayısal olarak karşılaştırılmıştır.




Şekil 3.2 Bazı filtrelerin iyileştirme sonuçları;


a) Orijinal imge, b) Gürültülü imge, c) IDBA çıkışı, d) BDND çıkışı, e) CWMF çıkışı, f) AMF çıkışı, g) SMFAMF çıkışı, h) SNFF çıkışı, i) DCFAMF çıkışı

Tablo 3.1 MR imgesinin farklı gürültü yoğunluklarında çeşitli filtrelerin PSNR ve MSE değerleri ile karşılaştırılması

Filtreler		10%	%20	%30	%40	%50	%60	%70	%80	%90
DCFAMF (Önerilen)	PSNR	41,71	38,77	36,92	35,14	33,52	32,25	30,45	28,48	26,82
	MSE	4,39	8,63	13,22	19,91	28,91	38,73	58,62	92,27	135,23
IDBA	PSNR	39,66	36,85	34,53	32,65	31,05	29,32	29,39	28,01	25,91
	MSE	7,03	13,43	22,91	35,32	51,06	76,05	74,83	102,82	166,76
BDND	PSNR	23,64	20,41	18,55	17,06	15,78	13,68	12,45	11,25	10,48
	MSE	281,24	591,67	907,99	1279,62	1718,23	2786,64	3698,97	4876,19	5822,1
CWMF	PSNR	32,42	29,61	27,18	23,81	20,43	17,07	13,96	11,15	8,72
	MSE	37,25	71,1	124	270	588	1276	2612	4989	8731
AMF	PSNR	39,52	34,86	32,38	30,24	28,46	26,83	25,02	23,29	20,62
	MSE	7,26	21,24	37,59	61,53	92,70	134,92	204,68	304,85	563,74
SMFAMF	PSNR	32,86	28,41	25,35	23,01	20,42	18,1	14,86	11,72	8,96
	MSE	33,66	93,77	189,71	325,15	590,31	1007,12	2123,64	4376,03	8261,9
SNFF	PSNR	30,89	29,3	24,45	22,12	20,1	18,36	16,81	15,23	14,22
	MSE	52,98	76,40	233,39	399,10	635,45	948,59	1355,44	1950,21	2460,8
Ortalama	PSNR	34,39	31,17	28,48	26,29	24,25	22,23	20,42	18,45	16,53
	MSE	60,54	125,18	218,47	341,58	529,37	895,53	1446,98	2384,59	3734,56



a)




b)


Şekil 3.3 Farklı filtrelerin çıkışının grafiksel gösterimi;

a) PSNR (dB), b) MSE


Şekil 3.4’de Beyin MR imgesinin 10% ile 90% arasında özellikle yüksek gürültü oranlarındaki görsel test sonuçları görülmektedir.




%10 Gürültü




Restore edilmiş imge




%20 Gürültü




Restore edilmiş imge




%30 Gürültü




Restore edilmiş imge




%40 Gürültü




Restore edilmiş imge




%50 Gürültü




Restore edilmiş imge




%60 Gürültü




Restore edilmiş imge




%70 Gürültü




Restore edilmiş imge




%80 Gürültü



Restore edilmiş imge



%90 Gürültü




Restore edilmiş imge


Şekil 3.4 Beyin MR imgesinin %10-%90 arasındaki gürültü yoğunluğundaki görsel performansı

3.4.2 Histogram Dağılımı


Şekil 3.5.a'da imgenin gürültüsüz halinin histogram dağılımı görülmektedir. Şekil 3.5.b'de gürültü eklenmiş imgeye bakıldığında, yüksek oranda (0 ve 255) değerinin olduğu görülmektedir. İmge restore edildikten sonra darbe gürültüsünün kaybolduğu ilk şekil ile benzerliğinden de anlaşılmaktadır.



a)



b)



c)

Şekil 3.5 Histogram dağılımı;

a) Orijinal imgenin histogramı, b) Gürültü eklendikten sonraki histogramı, c) İyileştirilmiş resmin histogramı

Tablo 3.1'deki sayısal sonuçlar ile birlikte Şekil 3.2, Şekil 3.3 ve Şekil 3.4'teki görsel sonuçları incelendiğinde, Önerilen filtrenin aşırı derecede bozulmuş imgeleri başarılı bir şekilde onardığı görülmektedir. Filtrenin başarısındaki önemli sebeplerden biride gürültü belirleme algoritmasının başarısından ileri gelmektedir. Bu gürültü belirleme algoritması bu filtrenin dışında başka filtrelerde de kullanılabilecek yapıdadır.

4. YAPAY SINIR AĞLARI İLE İMGENİN İŞLENMESİ

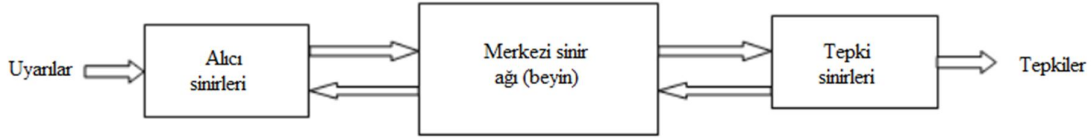
Bu bölümde aşırı bozulmuş imgeleri iyileştirmek için uyarlamalı bir yapay sinir ağı modeli geliştirilmiştir. Uyarlamalı Yapay Sinir Ağı (ANNM) olarak adlandırılan filtrenin temelinde yapay sinir ağları vardır. Önerilen algoritma yeni ve etkili bir darbe gürültü yok edicidir. Farklı gürültü yoğunluklarında eğitilmiş olan ağlar, gürültünün yoğunluğuna göre devreye girerek, gürültülü piksel yerine gelebilecek en uygun komşu pikseli tahmin etmektedir. Önerilen algoritma, sayısal imgelerdeki darbe gürültüsünü etkili biçimde yok ederken aynı zamanda detayları da korumaktadır. Deneysel sonuçlar, önerilen algoritmanın aynı tarz geleneksel filtrelerden daha iyi sonuçlar elde ettiğini göstermiştir. İlk olarak yapay sinir ağlarının özellikleri ve genel olarak kullanım alanlarından bahsedildikten sonra filtrenin tasarım ve uyarlamalı hale getirilmesi anlatılmıştır.

4.1. Yapay Sinir Ağları

Yapay sinir ağları (YSA), insanlar tarafından gerçekleştirilmiş olayları öğrenebilen (gerçek beyin fonksiyonlarının ürünü olan örnekleri), çevreden gelen olaylara karşı nasıl tepkiler üreteceğini belirleyebilen bilgisayar sistemleridir. Bu sistemler günümüzde daha da geliştirilerek artmaktadır. YSA, olayların örneklerine bakmakta, onlardan ilgili olay hakkında genellemeler yapmakta, bilgiler toplamakta ve daha sonra hiç görmediği örnekler ile karşılaşınca öğrendiği bilgileri kullanarak o örnekler hakkında karar verebilmektedir. YSA; insan beyninden esinlenerek, öğrenme sürecinin matematiksel olarak modellenmesi uğraşı sonucu ortaya çıkmıştır.

Bu nedenledir ki, bu konu üzerindeki çalışmalar ilk olarak beyni oluşturan biyolojik üniteler olan nöronların modellenmesi ve bilgisayar sistemlerinde uygulanması ile başlamış, daha sonraları bilgisayar sistemlerinin gelişimine de paralel olarak birçok alanda kullanılır hale gelmiştir. YSA, basit biyolojik sinir sisteminin çalışma şeklini simüle etmek için tasarlanan programlardır. Simüle edilen sinir hücreleri (nöronlar) içerirler ve bu nöronlar çeşitli şekillerde birbirlerine bağlanarak ağı oluştururlar. Bu ağlar öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler. Diğer bir ifadeyle, YSA'lar, normalde bir insanın düşünme ve gözlemlemeye yönelik doğal yeteneklerini gerektiren problemlere çözüm üretmektedir. Bir insanın, düşünme ve

gözlemlene yeteneklerini gerektiren problemlere yönelik çözümler üretebilmesinin temel sebebi ise insan beyninin ve dolayısıyla insanın sahip olduğu yaşayarak veya deneyerek öğrenme yeteneğidir. Biyolojik sistemlerde öğrenme, nöronlar arasındaki sinaptik bağlantıların ayarlanması ile olur. Şekil 4.1’de bu sisteme ait blok diyagram görülmektedir. İnsanlar doğumlarından itibaren yaşayarak öğrenme süreci içerisine girerler. Bu süreç içinde beyin sürekli bir gelişme göstermektedir. Yaşayıp tecrübe ettikçe sinaptik bağlantılar ayarlanır ve hatta yeni bağlantılar oluşur. Bu sayede öğrenme gerçekleşir. Bu durum YSA için de geçerlidir. Öğrenme, eğitime yoluyla örnekler kullanarak olur; başka bir deyişle, gerçekleşme girdi/çıkı verilerinin işlenmesiyle, yani eğitime algoritmasının bu verileri kullanarak bağlantı ağırlıklarını bir yakınsama sağlanana kadar, tekrar tekrar ayarlamasıyla olur.



Şekil 4.1 Biyolojik sinir sisteminin blok diyagramı

YSA'lar, ağırlıklandırılmış şekilde birbirlerine bağlanmış birçok işlem elemanlarından (nöronlar) oluşan matematiksel sistemlerdir. Bir işlem elemanı, aslında sık sık transfer fonksiyonu olarak anılan bir denklemdir. Bu işlem elemanı, diğer nöronlardan sinyalleri alır; bunları birleştirir, dönüştürür ve sayısal bir sonuç ortaya çıkartır. Genelde, işlem elemanları kabaca gerçek nöronlara karşılık gelirler ve bir ağ içinde birbirlerine bağlanırlar; bu yapı da sinir ağlarını oluşturmaktadır. Sinirsel hesaplamanın merkezinde dağıtılmış, uyarlamalı ve doğrusal olmayan işlem kavramları vardır. YSA'lar, geleneksel işlemcilerden farklı şekilde işlem yapmaktadırlar. Geleneksel işlemcilerde, tek bir merkezi işlem elemanı her hareketi sırasıyla gerçekleştirir. YSA'lar ise her biri büyük bir problemin bir parçası ile ilgilenen, çok sayıda basit işlem elemanlarından oluşmaktadır. En basit şekilde, bir işlem elemanı, bir girdiyi bir ağırlık kümesi ile ağırlıklandırır, doğrusal olmayan bir şekilde dönüşümünü sağlar ve bir çıktı değeri oluşturur. İlk bakışta, işlem elemanlarının çalışma şekli yanıltıcı şekilde basittir. Sinirsel hesaplamanın gücü, toplam işlem yükünü paylaşan işlem elemanlarının birbirleri arasındaki yoğun bağlantı yapısından gelmektedir [65].

Çoğu YSA'da, benzer karakteristiğe sahip nöronlar tabakalar halinde yapılandırılırlar ve transfer fonksiyonları eş zamanlı olarak çalıştırılırlar. Hemen hemen

tüm ağılar, veri alan nöronlara ve çıktı üreten nöronlara sahiptirler. YSA'nın ana ögesi olan matematiksel fonksiyon, ağıın mimarisi tarafından şekillendirilir. Daha açık bir şekilde ifade etmek gerekirse, Biyolojik sinir sisteminin blok diyagramı fonksiyonun temel yapısını, ağırlıkların büyüklüğü ve işlem elemanlarının işlem şekli belirler. YSA'ların davranışları, yani giriş verisinin çıkış verisiyle nasıl ilişkilendirdikleri, ilk olarak nöronların transfer fonksiyonlarından, nasıl birbirlerine bağlandıklarından ve bu bağlantıların ağırlıklarından etkilenir.

YSA'da iki önemli aşama vardır, bunlardan birincisi öğrenme, ikincisi ise test aşamasıdır. Ağıın doğru ağırlık değerlerine ulaşması örneklerin temsil ettiği olay hakkında genellemeler yapabilme yeteneğine kavuşması demektir. Bu genelleştirme özelliğine kavuşması işlemine ağıın öğrenmesi denir [65].

Ağıın eğitimi tamamlandıktan sonra öğrenip öğrenmediğini (performansını) ölçmek için yapılan denemelere ise ağıın test edilmesi denmektedir. Test etmek için ağıın öğrenme sırasında görmediği örnekler kullanılır. Test etme sırasında ağıın ağırlık değerleri değiştirilmez. Test örnekleri ağıa verilir. Ağı eğitimi sırasında belirlenen bağlantı ağırlıklarını kullanarak görmediği bu örnekleri için çıktılar üretir. Elde edilen çıktıların doğruluk değerleri ağıın öğrenmesi hakkında bilgiler verir. Sonuçlar ne kadar iyi olursa eğitimin performansı da o kadar iyi demektir.

4.1.1 Yapay Sinir Ağlarının Genel Özellikleri

YSA'lar, uygulanan ağı modeline göre değişik karakteristik özellikler göstermelerine karşın temel birkaç ortak özelliğe sahiptirler. YSA'lar makine öğrenmesi gerçekleştirirler. YSA'nın temel işlevi bilgisayarların öğrenmesini sağlamaktır. Olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışırlar. Programları çalışma stili bilinen programlama yöntemlerine benzememektedir. Geleneksel programlama ve yapay zekâ yöntemlerinin uygulandığı bilgi işleme yöntemlerinden tamamen farklı bir bilgi işleme yöntemi vardır.

YSA'da bilgi, ağıın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır. Diğer programlarda olduğu gibi veriler bir veri tabanında veya programın içinde gömülü değildir. Bilgiler ağıın üzerinde saklı olup ortaya çıkartılması ve yorumlanması zordur. YSA'nın olayları öğrenebilmesi için o olay ile ilgili örneklerin belirlenmesi gerekmektedir. Örnekleri kullanarak ilgili olay hakkında genelleme

yapabilecek yeteneğe kavuşturulurlar (uyarlamalı öğrenme). Örneklerin oluşturulması ve toplanması YSA biliminde özel bir öneme sahiptir [65].

YSA'nın güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekmektedir. Her ağ eğitmek için elde bulunan örnekler iki ayrı sete bölünürler. Birincisi ağ eğitmek için eğitim seti diğeri ise ağın performansını sınamak için test seti kullanılır. Her ağ önce eğitim seti ile eğitilir. Ağ bütün örneklerle doğru cevaplar vermeye başlayınca eğitim işi tamamlanmış kabul edilir. Daha sonra ağın hiç görmediği test setindeki örnekler ağa gösterilerek ağın verdiği cevaplara bakılır. Eğer ağ hiç görmediği örneklerle kabul edilebilir bir doğrulukta cevap veriyor ise o zaman ağın performansı iyi kabul edilir ve ağ kullanıma alınarak gerekirse çevrimiçi kullanılır. Ağ kendisine gösterilen örneklerden genellemeler yaparak görmediği örnekler hakkında bilgiler üretebilirler. Algılamaya yönelik olaylarda kullanılabilirler. Ağlar daha çok algılamaya yönelik bilgileri işlemede kullanılırlar. Bu konuda başarılı oldukları yapılan uygulamalarda görülmektedir. Bilgiye dayalı çözümlerde uzman sistemler kullanılmaktadır.

Şekil (örüntü) ilişkilendirme ve sınıflandırma yapabilirler. Verilen örneklerin sınıflandırılması ve belirli sınıflara ayrıştırılarak daha sonra gelen bir örneğin hangi sınıfa gireceğine karar vermesi hedeflenmektedir.

Örüntü tamamlama gerçekleştirebilirler. Bazı durumlarda ağa eksik bilgileri içeren bir örüntü (pattern), veya bir şekil verilir. Ağın bu eksik bilgileri bulması istenir. Örneğin yırtık bir resmin kime ait olduğunu belirlemesi ve tam resmi vermesi gibi bir sorumluluk ağdan istenebilmektedir.

Kendi kendini organize etme ve öğrenebilme yetenekleri vardır. YSA'nın örnekler ile kendisine gösterilen yeni durumlara adapte olması ve sürekli yeni olayları öğrenebilmesi mümkündür.

Eksik bilgi ile çalışabilmektedirler. YSA'lar kendileri eğitildikten sonra eksik bilgiler ile çalışabilir ve gelen yeni örneklerde eksik bilgi olmasına rağmen sonuç üretebilirler. Eksik bilgiler ile de çalışmaya devam ederler. Eğer ağın performansı düşmez ise eksik olan bilginin önemli olmadığı anlaşılır.

Hata toleransına sahiptirler. YSA'ların eksik bilgilerle çalışabilme yetenekleri hatalara karşı toleranslı olmalarını sağlamaktadır. Ağın bazı hücrelerinin bozulması ve çalışamaz duruma düşmesi halinde ağ çalışmaya devam eder. Ağın bozuk olan hücrelerinin sorumluluklarının önemine göre ağın performansında düşmeler görülebilir.

Belirsiz, tam olmayan bilgileri işleyebilmektedirler. YSA'nın belirsiz bilgileri işleyebilme yetenekleri vardır. Olayları öğrendikten sonra belirsizlikler altında ağlar öğrendikleri olaylar ile ilgili ilişkileri kurarak kararlar verebilirler.

Dereceli bozulma gösterirler. YSA'nın hatalara karşı toleranslı olmaları bozulmalarının da dereceli (göreceli) olmasına neden olmaktadır. Bir ağ zaman içerisinde yavaş yavaş ve zarif bir şekilde bozulur. Bu eksik olan bilgiden veya hücrelerin bozulmasından kaynaklanır. Ağlar, herhangi bir problem ortaya çıktığında hemen anında bozulmazlar [65].

Dağıtık belleğe sahiptirler. YSA'da bilgi ağa yayılmış durumdadır. Hücrelerin birbirleri ile bağlantılarının değerleri ağın bilgisini gösterir. Tek bir bağlantının bir anlamı yoktur. Daha önce belirtildiği gibi ağın bilgilerinin açıklanamamasının sebeplerinden birisi de budur. Bu ağlarda, ağın tamamı öğrendiği olayın bütünü karakterize etmektedir.

Sadece nümerik bilgiler ile çalışabilmektedirler. YSA sadece nümerik bilgiler ile çalışırlar. Sembolik ifadeler ile gösterilen bilgilerin nümerik gösterime çevrilmeleri gerekmektedir.

Burada açıklanan özellikler dikkatlice incelenirse, aslında YSA'nın bilgisayar bilimine oldukça avantajlı katkılarının olduğu görülebilir. Geleneksel bilgisayar yazılım teknolojisi ile çözülemeyen birçok problemin YSA ile çözülebileceği görülebilir.

4.1.2 Yapay Sinir Ağlarının Kullanıldığı Alanlar


YSA başlıca; sınıflandırma, modelleme ve tahmin uygulamaları olmak üzere, pek çok alanda kullanılmaktadır. Başarılı uygulamalar incelendiğinde, YSA'ların çok boyutlu, gürültülü, karmaşık, kesin olmayan, eksik, kusurlu, hata olasılığı yüksek sensör verilerinin olması ve problemi çözmek için matematiksel modelin ve algoritmaların bulunmadığı, sadece örneklerin var olduğu durumlarda yaygın olarak kullanıldıkları görülmektedir. Bu amaçla geliştirilmiş ağlar genellikle şu fonksiyonları gerçekleştirmektedirler;

- Muhtemel fonksiyon kestirimleri
- Sınıflandırma
- İlişkilendirme veya örüntü eşleştirme
- Zaman serileri analizleri
- Sinyal filtreleme
- Veri sıkıştırma

- Örüntü tanıma
- Doğrusal olmayan sinyal işleme
- Doğrusal olmayan sistem modelleme
- Optimizasyon
- Kontrol [66].

4.1.3 Çok Katmanlı Algılayıcı (MLP) Yapısı

Tezde kullanılan YSA, Şekil 4.2'deki MLP tipi ağ yapısındadır. MLP yapısı birçok birimin oluşturduğu bir kümedir. Bu algılayıcı birimler bir araya gelerek ağdaki katmanları oluşturur. Bu katmanlar da bir araya gelerek ağı oluşturur. MLP'de üç temel katman vardır. Bunlar giriş katmanı, gizli katman ve çıkış katmanıdır. Giriş ve çıkış katmanı dışındaki tüm katmanlar gizli katman olarak adlandırılır.



Şekil 4.2 Çok katmanlı yapay sinir ağ mimarisi


Giriş Katmanı: Dış dünyadan gelen girdileri alarak ara katmana gönderir. Bu katmanda bilgi işleme olmaz. Gelen her bilgi geldiği gibi bir sonraki katmana gider. Her işlem elemanın sadece bir tane girdisi ve bir tane çıktısı vardır. Yani, girdi katmanındaki her işlem elemanı bir sonraki katmanda bulunan işlem elemanlarının hepsine bağlanır.

Gizli Katman: Ara katmanlar, girdi katmanından gelen bilgileri işleyerek bir sonraki katmana gönderir. Çok katmanlı bir ağda birden fazla ara katman ve her katmanda birden fazla işlem elemanı bulunabilir.

Çıkış Katmanı: Ara katmandan gelen bilgileri işler ve ağa girdi katmanından verilen girdilere karşılık ağın ürettiği çıkışları belirleyerek dış dünyaya gönderir. Bir çıktı katmanında birden fazla işlem elemanı olabilir. Her işlem elemanı bir önceki katmanda bulunan bütün işlem elemanlarına bağlıdır. Her işlem elemanının bir çıktısı vardır.

4.1.4 Aktivasyon Fonksiyonu


Transfer fonksiyonu olarak da geçen aktivasyon fonksiyonu, birleştirme fonksiyonundan elde edilen net girdiyi bir işlemden geçirerek hücre çıktısını belirleyen ve genellikle doğrusal olmayan bir fonksiyondur. Hücre modellerinde, hücrenin gerçekleştireceği işleve göre çeşitli tipte aktivasyon fonksiyonları kullanılabilir. Aktivasyon fonksiyonları sabit parametrelili ya da uyarlanabilir parametrelili seçilebilir. En uygun aktivasyon fonksiyonu tasarımcının denemeleri sonucunda belli olur. Aktivasyon fonksiyonunun seçimi büyük ölçüde YSA'nın verilerine ve ağın neyi öğrenmesinin istendiğine bağlıdır. Aktivasyon fonksiyonları içinde en çok kullanılanı sigmoid ve hiperbolik tanjant fonksiyonlarıdır. Örneğin, ağın bir modelin ortalama davranışını öğrenmesi isteniyorsa sigmoid fonksiyon, ortalamadan sapmanın öğrenilmesi isteniyorsa hiperbolik tanjant fonksiyonu kullanılması önerilmektedir. Aktivasyon fonksiyonları bir YSA'da nöronun çıkış genliğini istenilen değerler arasında sınırlar. Bu değerler genellikle $[0,1]$ veya $[-1,1]$ arasındadır. YSA'da kullanılacak aktivasyon fonksiyonlarının türevi alınabilir olması ve süreklilik arz etmesi gereklidir. Şekil 4.3'te çok katmanlı bir algılayıcıda aktivasyon fonksiyonunun yeri görülmektedir. Doğrusal veya doğrusal olmayan transfer fonksiyonlarının kullanılması, YSA'ların karmaşık ve çok farklı problemlere uygulanmasını sağlamıştır. Bu çalışmada aktivasyon fonksiyonu olarak doğrusal aktivasyon fonksiyonu kullanılmıştır.



Şekil 4.3 Çok katmanlı yapay sinir ağı nöron yapısı ve aktivasyon fonksiyonun yeri

4.1.5 Doğrusal Aktivasyon Fonksiyon

Doğrusal bir problemi çözmek amacıyla kullanılan doğrusal hücre ve YSA' da, ya da genellikle katmanlı YSA' nın çıkış katmanında kullanılan doğrusal fonksiyon, hücrenin net girdisini doğrudan hücre çıkışı olarak verir. Doğrusal aktivasyon fonksiyonu matematiksel olarak $y=Av$ şeklinde tanımlanabilir. "A" sabit bir katsayıdır. YSA'ların çıkış katmanında kullanılan doğrusal fonksiyon Şekil 4.4'te verilmiştir.



Şekil 4.4 Doğrusal Aktivasyon fonksiyonu

4.1.6 Ara Katman Sayısı ve Proses Elemanlarının Sayısının Belirlenmesi

MLP modelinde herhangi bir problem için kaç tane ara katman ve her ara katmanda kaç tane işlem elemanı kullanılması gerektiğini belirten bir yöntem şu ana kadar bulunmuş değildir. Tasarımcılar kendi tecrübelerine dayanarak bunları belirler. Bazı durumlarda

başlangıçta bir ağ oluşturulup zaman içinde büyütülerek veya küçültülerek istenen ağa ulaşılır. Aşağıda bu durum açıklanmıştır.


MLP ağlarında problemin çözümü için gerekli en iyi topolojiyi belirlemek mümkün olmadığından deneme yanılma yöntemi kullanılmakta bazen eksik sayıda bazen de fazla sayıda işlem elemanı kullanılmaktadır. Gereken sayıda işlem elemanı belirlemek için iki yoldan birisi denenmektedir.

Bunlar; küçük bir ağdan başlayıp büyük bir ağa doğru eğitim esnasında sürekli işlem eleman sayısını artırmak veya büyük bir ağdan başlayıp küçük bir ağa doğru eğitim sırasında sürekli ağı küçültmek ve işlem elemanlarını teker teker ağdan çıkartmaktır. Buna ağın budanması denmektedir.

4.2. Yapay Sinir Ağından Filtre Oluşturulması

Son birkaç yıl içinde imge onarımı konusunda YSA ve bulanık mantık gibi doğrusal olmayan teknikler gittikçe artan bir önem kazanmaktadır. Yapılan araştırma ve incelemeler neticesinde YSA'nın, imge işlemede oldukça başarılı olduğu görülmüştür. Hücresel ağlar paralel mimarileri sayesinde çok hızlı veri işleyebilmektedir. Komşuluk ilişkileri nedeni ile birbirlerini etkileyebilme kabiliyetine sahip olmaları da ayrı bir avantaj sağlamaktadır. İmge gibi birbiri ile anlamlı komşuluk ilişkisi olan yapılar YSA için çok uygundur. Son bir kaç yılda, imgedeki gürültüyü giderme amacıyla bulanık sinir ağı tekniklerinin kullanımı hızla gelişen bir ilgi alanı olmuştur. YSA gürültü azaltma problemlerinde sıklıkla kullanılmaktadır [67-72]. YSA'nın en temel amacı, kendisine gösterilen bir girdi setine karşılık gelebilecek bir çıktı seti belirlemektir. Bunu yapabilmesi için ağ, ilgili olayın örnekleri ile eğitilerek (öğrenme) genelleme yapabilecek yeteneğe kavuşturulur. Bu genelleme ile benzer olaylara karşılık gelen çıktı setleri belirlenir. Bizim amacımız geliştirilen yöntem ile hızlı, doğru ve minimum parametre ile sonradan herhangi bir ayarlamaya ihtiyaç duymadan görevleri yerine getirebilmesidir.

Bu tez çalışmasında, iki aşamalı bir yöntem sunulmaktadır. İlk aşamada gürültü yoğunluğu tespiti yapılacak, ikinci aşama da ise daha önceden farklı gürültü yoğunluklarında eğitilmiş olan ağ devreye konarak bozuk piksel en uygun komşu piksel ile değiştirilecektir. Şekil 4.5'te önerilen filtrenin genel şeması görülmektedir.



Şekil 4.5 Önerilen filtrenin genel şeması

Deneysel sonuçlar incelendiğinde, önerilen algoritmanın darbe gürültüsü etkili biçimde silerken, detaylarını da etkili biçimde koruduğu gözlemlenmiştir. Ayrıca hem görsel değerlendirme hem de popüler imge değerlendirme kriterleri olan PSNR ve MSE bize aynı kategorideki geleneksel filtrelerden daha etkili olduğunu sayısal olarak göstermiştir.


4.2.1 Yapay Sinir Ağı'nın Eğitilmesi

Bu çalışmada kullanılan YSA eğitiminin temel adımları şu şekilde özetlenebilir: YSA'nın geliştirilmesi sürecinde her biri bir aşama olan, ağı mimarisine ve işlevlerine uygun ilişkin şu kararların verilmesi gerekir [65].

- Ağ mimarisinin seçilmesi ve yapı özelliklerinin belirlenmesi (katman sayısı, gizli katman sayısı giriş katmandaki nöron sayısı, çıkış katmandaki nöron sayısı gibi),
- Nörondaki fonksiyonların karakteristik özelliklerinin belirlenmesi,
- Öğrenme algoritmasının seçilmesi ve parametrelerinin belirlenmesi,
- Eğitim ve test verisinin oluşturulması.
- Farklı gürültü yoğunluklarında ağlar eğitilmesi
- Hatalı pikselin gürültü yoğunluğuna göre pencerelenip bir sütun vektörü biçimine çevrilerek giriş katmanından eğitilmiş sinir ağına uygulanması.


4.2.2 Uyarlamalı Yapay Sinir Ağ Mimarisi

Uyarlamalı Yapay Sinir Ağı (ANNM) Geriye Yayınım algoritmaları ile eğitilmiştir. Tasarlanan ANNM bir giriş katmanı ve bir çıkış katmanından oluşan çok katmanlı, ileri beslemeli bir ağıdır. Şekil 4.6'da görüldüğü gibi iki katmanlı ileri beslemeli ağ, purelin nöronlarından oluşmuş bir giriş katmanı ve yine purelin nöronlarından oluşmuş bir çıkış katmanına sahiptir. Girişte dokuz çıkışta ise bir tek nöron bulunmaktadır. Aktivasyon fonksiyonu olarak da doğrusal aktivasyon fonksiyonu kullanılmıştır.




Şekil 4.6 Ağın eğitimi

Çalışmada farklı tip öğrenme kuralları ağı eğitmek için denenmiş olup, en iyi sonuç Levenberg-Marquardt (LM) öğrenme kuralı kullanılarak elde edilmiştir. Bu bölümde öncelikle üç farklı gürültü yoğunluğunda, üç farklı ağ eğitilmiştir. Bu ağların değişik gürültü yoğunlarındaki performansı Şekil 4.7’de incelendiği zaman düşük gürültü yoğunluğunda eğitilmiş olan YSA, yüksek gürültülü imgelerde iyi performans sergilemezken aynı şekilde yüksek gürültü yoğunluğunda eğitilmiş ağ ise düşük gürültüde başarı oranı düşmektedir. Bir uyarlamalı medyan filtrede gürültü miktarı arttığı zaman nasıl pencereleme boyutu artırılıyorsa, bu algortmada da gürültü miktarı değiştiğinde, o anki gürültü yoğunluğuna yakın değerde eğitilmiş olan ağ devreye girerek bozuk olan piksele en uygun tahmini değeri atamaktadır.




Şekil 4.7 Farklı gürültü yoğunluklarında eğitilmiş ağların birbirine göre karşılaştırılması

Şekil 4.7’de görüldüğü gibi gürültü yoğunluğunun %30 a kadar olan bölümünde Network-1 daha iyi sonuçları vermekte iken, gürültü %30-75 arasında ise Network-2 iyi sonuçlar vermektedir. Gürültü %80 den daha fazla ise bu sefer Network-3 iyi sonuçlar vermektedir. Algoritma ise bu tespitten yola çıkılarak hazırlanmıştır. Şekil 4.8’de ANNM’in akış diyagramı görülmektedir.



Şekil 4.8 ANNM’in akış şeması

Akış diyagramı incelendiğinde, incelenen pikselin gürültü olduğuna karar verilirse ilk olarak piksel etrafında 3x3 pencereleme yapılır. Eğer gürültü yoğunluğu fazla değilse daha önce bu yoğunlukta eğitilmiş olan Network-1, devreye alınır. Şekil 4.9’da Network-1’e ait mimari yapı görülmektedir. Mimari yapısında, bu ağı 9 girişi bir çıkışı bulunmaktadır. Pencere matrisi ($X_1, X_2, \dots, X_9$) bir sütun matrise dönüştürülüp ağa giriş olarak uygulanır ve bozuk piksel yerine konacak olan yeni değer tahmin edilir. Eğer gürültü yoğunluğu yüksek ise pencereleme 5x5 boyutuna yükseltilir. Bu sefer daha önce orta yoğunlukta gürültüde eğitilmiş olan Network-2 devreye alınır. Bu ağı 25 girişi bir çıkışı bulunmaktadır. Eğer gürültü yoğunluğu yine de fazla ise pencere boyutu artırılıp 7x7 boyutunda pencereleme ye tabi tutulur. Bu yoğunlukta eğitilmiş olan Network-3 devreye alınır, bu ağı ise 49 girişi, bir çıkışı bulunmaktadır. İterasyon bu şekilde devam eder.



Şekil 4.9 Network-1'in mimarisi


4.3. Deneysel Sonuçlar ve Simülasyon Analizi

Önerilen metot olan ANNM önceki bölümde açıklanmıştı. Bu kısımda son zamanlarda darbe gürültüsü yok etmek için popüler olan filtreler ile bizim önerdiğimiz metot karşılaştırıldı. Ağın eğitilmesi ve eğitilen ağırlarla oluşturulmuş algoritmaların tümü MATLAB üzerinde uygulandı. Deneylerdeki test imgesi olarak göğüs radyografı ve damar radyografı [73] imgeleri kullanıldı. Karşılaştırma için bozulmuş imgeler hem geleneksel hem de modern metotlar vasıtasıyla iyileştirildi. İyileştirilmiş imge ile orijinal imge arasındaki restorasyon kalitesini belirlemede literatürde iyi bilinen ve sıklıkla kullanılan popüler metotlar olan PSNR ve MSE kriterleri ile değerlendirildi.


Tablo 4.1 incelendiğinde önerilen algoritmanın diğer metotlara göre önemli ölçüde iyileştirme sağladığı açıkça görülmektedir. Yine dikkat edilecek olursa hemen hemen tüm kusurlu pikseller onarılırken resmin detayları da korunmuştur. Algoritma özellikle %10 ile %90 arasında değişen yüksek gürültü oranlarındaki test sonuçları ile sınanmıştır.

Tablo 4.1 ‘Göğüs radyografi’ test imgesinin iyileştirme sonuçlarının PSNR (db) ve MSE karşılaştırılması

Filtreler		10%	20%	30%	40%	50%	60%	70%	80%	90%
(A.N.N.M)	PSNR	42.7	39.5	37.4	35.9	33.82	31.75	30.25	28.23	26.2
	MSE	3.48	7.26	11.7	16.5	26.98	43.46	61.39	97.74	154.9
O.C.S	PSNR	29.6	29.2	28.6	27.7	26.76	25.5	24.03	21.55	18.31
	MSE	71.3	77.8	89.3	108	137.1	183.2	257	455	959.5
I.D.B.A	PSNR	39.66	36.85	34.53	32.65	31.05	29.32	28.01	25.9	22.6
	MSE	7.03	13.43	22.91	35.32	76.047	102.82	167.14	410	897
T.L.I.D.E	PSNR	34.4	29.5	23.8	20.9	16.63	14.42	11.21	8.91	7.72
	MSE	23.5	72.9	266	517	1412	2350	4921	8357	10992
A.M.F	PSNR	39.5	34.8	32.3	30.2	28.46	26.83	25.02	23.29	20.6
	MSE	7.26	21.2	37.5	61.5	92.70	134.9	204.6	304.8	563.7
C.W.M.F	PSNR	32.4	29.6	27.1	23.8	20.43	17.07	13.96	11.15	8.72
	MSE	37.2	71.1	124	270	588.9	1276	2612	4989	8731



a)



b)

Şekil 4.10 Farklı filtrelerin grafiksel performansı;



a) PSNR (dB), b) MSE

%60 Gürültü


% 90 Gürültü




a) Orijinal imge




b) Gürültülü imge




c) OCS




d) IDBA




e) TLIDE



f) AMF



g) CWMF



h) DBA




i) ANNM

Şekil 4.11 Göğüs radyografi imgesinin farklı filtrelerin imge iyileştirme sonuçları sırasıyla %60 ve %90;


a) Orijinal imge, b) bozulmuş imge, c) OCS çıkışı, d) IDBA çıkışı, e) TLIDE çıkışı, f) AMF çıkışı, g) CWMF çıkışı, h) DBA çıkışı, i) ANNM çıkışı

%60 Gürültü


% 90 Gürültü




a) Orijinal imge




b) Gürültülü imge




c) OCS




d) IDBA




e) TLIDE




f) AMF



g) CWMF



h) DBA



i) ANNM

Şekil 4.12 Damar radyografi imgesinin farklı filtrelerin imge iyileştirme sonuçları sırasıyla %60 ve %90;

a) Orijinal imge, b) bozulmuş imge, c) OCS çıkışı, d) IDBA çıkışı, e) TLIDE çıkışı, f) AMF çıkışı, g) CWMF çıkışı, h) DBA çıkışı, i) ANNM çıkışı

Şekil 4.11’de göğüs radyografi, Şekil 4.12’de damar radyografi imgelerine ait sırasıyla %60 ve %90 gürültü oranlarındaki, farklı filtrelere ait iyileştirme sonuçları görülmektedir. Hem Tablo 4.1’deki sayısal değerler hem de Şekil 4.10.a ve Şekil 4.10.b’deki grafiklerden ANNM’in başarısı görülmektedir.

YSA kullanılarak gerçekleştirilen darbe gürültü giderici filtre, literatürdekilerin aksine sadece bir gürültü yoğunluğunda eğitilmemektedirler. Gerçekte gürültü yoğunluğu hiçbir zaman bilinemediği için kullanılan ağlar; Network-1 %30 gürültü yoğunluğunda, Network-2 %60 gürültü yoğunluğunda, Network-3 ise %80 gürültü yoğunluğunda eğitilerek uyarlamalı hale getirilmiştir. Bu sayede ağ bir kere eğitildikten sonra herhangi bir parametreye ihtiyaç duymadan tüm imgelerde başarılı bir şekilde kullanılabilmektedir.

5. OLASILIK VE BAYES YAKLAŞIMI

5.1. Olasılık ve Belirsizlik

Olasılık teorisi belirsizliğin matematiksel olarak modellenmesi ile ilgilenir. Evrende gerçekleşen bütün olayların “GİZLİ” bir değişkenin fonksiyonları olduğunu düşünürsek, bu değişken ve fonksiyonların bilinmesi/tanımlanabilmesi halinde “belirsizlikler” ortadan kalkar. Gerçekte bu değişkenlerin ve fonksiyonların “KESİN” olarak bilinmesi pratikte mümkün değildir. Bunun için “OLASILIK TEORİSİ” “TEKRARLANAN” olayların ortalama davranışlarına odaklanır. “TEKRARLANAN” olaylar için gözlemler yapıldığında ve özellikle gözlemlerin sayısı artırıldığında belli ortalamaların sabit değerlere yaklaştığı ve bu ortalama değerlerin daha sonraki olayların katılmasıyla dahi değişmeme eğiliminde olduğu gözlemlenmiştir. Tekrarlanan olaylara örnek olarak; elektron yayını, telefon aramaları, radar algılaması, kalite kontrolü, sistem çökmesi, yazı-tura atılması vb. olayları verebiliriz. Özetle anlatmak gerekirse, bu teorinin amacı olayların ortalama davranışlarını olayların olasılıkları cinsinden tanımlamak ve kestirmektir [75].

Olasılık, bir belirsizlik ölçütü, belirsizliği göstermek ve işlemek için oluşturulmuş bir metottur. Bu belirsizliklerle her zaman karşılaşılabilir ve belirsizliğin temelinde, ilgili olduğu alana ait bütün değişkenleri bilmek mümkün değildir. Bunun yanında gözlemlenebilen değişkenler, ait oldukları alan deterministik olsa da, rastgele davranırlar. Bu yüzden ilgili alanın tüm değişkenlerini ve bu değişkenlerin aralarındaki ilişkileri belirlemek zaman ve maliyet açısından çoğu zaman pratik olarak mümkün olmayabilir. Fakat bütün bu zorluklara rağmen insanoğlu belirsizlik altında karar alabildiğini fark etmiş ve bu becerisini geliştirdiği sistemlere aktarmak istemiştir. Bu beceri, sistemlere aktarılırken çıkan en önemli problemlerden ilki belirsizlik içerisindeki ilişkilerin nasıl temsil edileceğidir. Bu durum ve ilişkilerin temsili için olasılık kuramı kullanılabilir. Bu yöntemde gerçekler bir veya daha fazla değeri olabilen rastlantısal değişkenlerle gösterilirler. Rastlantısal değişkenler ikili değerler (gürültü var-yok), çoklu değerler (düşük gürültü-normal-yüksek) veya sürekli değerler (örnekleme) alabilirler. Sonra bu rastlantısal değişkenler işleme konulup, konuya ait bilgi olasılıksal olarak elde edilir [75].

5.1.1 Olasılığın Mühendislikteki Uygulamaları

Olasılık, mühendislik bilimlerinde birçok uygulama alanına sahiptir. Elektrik-Elektronik Mühendisliği uygulama alanına giren bazı uygulamaları [75]:

- Elektrik devrelerde ısı gürültü,
- Zayıf radar ve radyo sinyallerinin algılanması,
- Enformasyon teorisi,
- Haberleşme sistem tasarımı,
- Sistemlerin güvenilirliği,
- Sistem/cihaz hata/başarısızlık oranları ve olasılıkları,
- Ağ trafiği,
- Haberleşme ağları gibi birçok uygulama alanına sahiptir.

5.2. Bayes Yaklaşımı ve Bayes Ağları

5.2.1 Temel Bilgiler

Bayes yaklaşımının esaslarını üç temel adımda toplayabiliriz:

1. Bilinmeyen parametreler hakkında varsa bazı önsel bilgiler içeren olasılık modeli belirlemek.
2. Bu olasılık modelinin gözlenen veri üzerine koşullandırılmasıyla bilinmeyen parametreler hakkındaki bilginin geliştirilmesi.
3. Modellerin veriye uyumunun ve varsayımların sonuçlara duyarlılığının hesaplanması. [74].

Temel Bayes yaklaşımında gereken anahtar kabuller vardır. Birincisi: bilinmeyen parametreler için belli bir parametrik formun oluşturulmasıdır. İkincisi: bilinmeyen parametreler, sabit olma yerine dağılımsal özelliklere sahip olduğu için daha önceki bilgilere dayalı olan bu parametrelerin bir başlangıç koşulsuz dağılımının belirlenmesinin uygun olacağı kabul edilir. Veri değerlerinin değiştirilebilir olduğu kabul edilir. Model sonuçları, veri değerlerinin tekrar sıralanmasıyla değiştirilemez. Bu özellik, verinin bağımsız ve özdeş dağılımlı olduğunu ifade eden standart varsayımdan daha geneldir. Aynı dağılımdan çekilen bağımsız ve aynı değerler için ortak ortalama bir varyansa sahiptir. Değişebilir veri üretim sürecinin her veri için aynı şekilde bilinmeyen model parametrelerine koşullu olduğunu söylememize izin verir. Olasılığı tanımlamak kolay

olmalıdır. Gerçekte bir olasılık fonksiyonunun özelliklerini matematik olarak tanımlamak kolaydır:

1. Sıfır ve bir ile sınırlıdır
 2. Toplamı ya da integrali 1'e eşittir
 3. Ayırık olayların olasılıklarının integrali veya toplamı bu olayların birleşimlerinin olasılıklarına eşittir [76].
- Gerçek problem olasılık ifadelerinin gerçek anlamını tanımlamada yatar. Bu zorluk Bayes yaklaşımı ve diğer yaklaşımlar arasındaki geleneksel anlaşmazlığın temel noktasıdır. Olasılığın klasik istatistiksel yorumu; bir kitledeki gözlenen bir oranın veya deterministik olmayan bir sonucun uzun dönem davranışdır. Bu görüş Laplace (1814)'a dayanmaktadır. Laplace, olasılığı gözlenen denemelerdeki başarılı olayların sayısı olarak tanımlamaktadır. Deneyin yeteri kadar tekrarlanması esasına dayanır. Olasılığın bir başka yönü, subjektiflik olarak isimlendirilir ve inanç derecesi terimi ile özdeşleştirilir. Bu terim ilk olarak aynı duruma bakan iki kişinin gelecek durumlar hakkında farklı olasılık ifadeleri belirtebileceğidir. Subjektif olasılık olarak isimlendirilen bu kavramın gelişimi Bernardo ve Smith (1994) ile geliştirilmiştir. Bu subjektif olasılık, Bayes yaklaşımında önsel bilgi ile formülize edilir.

Önsel bilgi; elimizde bir veri olmadan ya da henüz veriyi gözlemlemeden parametre hakkında araştırmacının deneyimi, hissiyatı ve teorik fikirlerini içerir. Ayrıca daha önceki çalışmalardan, deneylerden ve ilgili kişilerin görüşlerinden elde edilir. Bu önsel bilgiler, gözlem değerleri ile ifade edilen olabilirlik fonksiyonu kullanımıyla sonsal bilgiye dönüştürülür. Sonsal bilgi ve ona karşılık gelen sonsal olasılık, veriyi gözlemledikten sonra ona tahmin edilmesi istenen parametre hakkındaki olasılık değeridir [74].

5.2.2 Bayes Teoremi

Bayes teoremi olasılık kuramı içinde incelenen önemli bir konudur. Bu teorem bir rastlantısal değişken için olasılık dağılımı içinde koşullu olasılıklar ile marjinal olasılıklar arasındaki ilişkiyi gösterir [77]. Günlük yaşantıda karşılaşılan düşüncelerin, sezgilerin bilimsel amaçlara yönelik kullanılmasında Bayes yaklaşımı ortaya çıkmaktadır [78].

Naïve Bayes, hedef değişkenle bağımsız değişkenler arasındaki ilişkiyi analiz eden tahminci ve tanımlayıcı bir sınıflama algoritmasıdır. Olasılık teorisi içinde incelenen bir olay olarak B olayına koşullu bir A olayı (yani B olayının bilindiği halde A olayı) için olasılık değeri, A olayına koşullu olarak B olayı (yani A olayı bilindiği haldeki B olayı)

için olasılık değerinden farklıdır. Ancak bu iki birbirine ters koşulluluk arasında çok belirli bir ilişki vardır ve bu ilişkiye ilk açıklayan istatistikçi İngiliz Thomas Bayes (1702–1761) adına atfen Bayes Teoremi denilmektedir [79]. Bayes yaklaşımının temeli olan Bayes teoremi ve toplam olasılık formülü, 18. yüzyılın son yarısında Thomas Bayes tarafından geliştirilen koşullu olasılıkların hesaplanması, 1763 yılında Thomas Bayes tarafından ortaya konulan Bayes teoremi, bu yaklaşımın temelini oluşturmaktadır. Jeffreys, de Finette, Savage ve Lindley gibi birçok araştırmacı Bayesci analizin gelişimine katkıda bulunmuşlardır [80]. Bir olayın olasılığı, o olaya ilişkin ön bilgi ile denemeden elde edilen sonuçların yani verinin birleştirilmesi ile oluşmaktadır. Birleştirme işlemi, Bayes teoremine dayanmaktadır.

Günümüzde bilimsel öğrenme ve karar vermede, Bayes yaklaşımı önemli bir ilgi odağı olmuştur ve özellikle son yarım yüzyılda, Bayes yaklaşımı temelli bilimsel çalışmaların sayısında büyük bir artış görülmektedir. Bu yaklaşım istatistikte, ekonometri çalışmalarında ve pek çok alanda uygulanmaktadır. Öznitelikler arasındaki bazı ilişkiler ve bağımlılıklar gösterilememiş olsa da Bayes karar verme kuralının birçok sınıflandırma probleminde oldukça başarılı sonuçlar verdiği görülmüştür [81]. Naïve Bayes, modelin öğrenilmesi esnasında, her çıktının öğrenme kümesinde kaç kere meydana geldiğini hesaplar. Bulunan bu değer, öncelikli olasılık olarak adlandırılmıştır. Örneğin; bir banka kredi kartı başvurularını “iyi” ve “kötü” risk sınıflarında gruplandırmak istemektedir. İyi risk çıktısı toplam 5 vaka içinde 2 kere meydana geldiyse iyi risk için öncelikli olasılık 0,4’tür. Bu durum, “Kredi kartı için başvuran biri hakkında hiçbir şey bilinmiyorsa, bu kişi 0,4 olasılıkla iyi risk grubundadır” olarak yorumlanır. Naïve Bayes aynı zamanda her bağımsız değişken/bağımlı değişken kombinasyonunun meydana gelme sıklığını bulur. Bu sıklıklar öncelikli olasılıklarla birleştirilmek suretiyle tahminde kullanılır [77].

5.2.3 Bayes Yaklaşımın Matematiksel İfadesi

Klasik yaklaşım, elde edilmiş veriler yardımı ile hakkında bilgi sahibi olunması istenen olaylara ait sonuçlar çıkarılmasıdır. Bayes teoremi önsel bilgiler toplandıktan sonra parametreler hakkında önsel bilgilerin yardımıyla yorum yapılmasını sağlayan, sayısal çıkarımdan sözel yoruma geçişte yardımcı bir teoremdir [20].

Samuel Butler, “Hayat, yetersiz önsellerden yeterli sonuçlar çıkarma sanatıdır.” sözüyle kitleye ilişkin parametrelere ait çıkarsamalara yeni bir boyut getirmiştir. Thomas Bayes, bu mantıkla benzer biçimde, nedenlerden sonuçlara doğru olan mantık izleyişini,

sonuçlardan nedenlere doğru değiştirmiştir [82]. Bayes teoreminin tanımında A parametre vektörünü, B gözlemleri temsil etmektedir. Buna göre Bayes teoremi Denklem (5.1)'de gösterildiği gibidir. Naïve Bayes yaklaşımı, genellikle sonrasal olasılıkları hesaplamakta kullanılan ve iki rastgele olayın koşullu ve marjinal olasılıklarını ilişkilendiren bir teoremdir. Maksimum olabilirlik ilkesi üzerine kurulu bir teoremdir. Bu durumda Bayes Teoremi, konulan olasılıkların doğruluk oranını hesaplamak için kullanılabilir.

A ve B rastgele olaylar olsun;

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (5.1)$$

$P(A)$: A olayının bağımsız olasılığı

$P(B)$: B olayının bağımsız olasılığı

$P(B|A)$: A olayının olduğu bilindiğinde B olayının olasılığı (Likelihood, Şartlı olasılık)

$P(A|B)$: B olayının olduğu bilindiğinde A olayının olasılığı (Posterior, Artçıl olasılık)

Naïve Bayes kuralına dayanarak $P(A|B)$ 'yi maksimum yapan durumlar hesaplanabilir

" E " A olayının bütün durumlarının kümesi

$$A_{MAX} = \operatorname{argmax}_{A \in E} P(A|B) \quad (5.2)$$

$$= \operatorname{argmax}_{A \in E} \frac{P(B|A)P(A)}{P(B)} \quad (5.3)$$

$$= \operatorname{argmax}_{A \in E} P(B|A)P(A) \quad (5.4)$$

Burada $P(B)$ sabit olarak göz ardı edilebilir. Sınıflandırıcının görevi yeni bir örnek için doğru sınıfı tahmin etmek olacaktır. Sınıflandırma problemi öncül (a priori) olasılıklar kullanılarak şu şekilde formüle edilebilir:

$P(v|X)$ Örnek durum için olasılık

$X = (a_1, \dots, a_k)$ v sınıfının örnekleri

$P(\text{sınıf}|\text{tahmin edilen sonuç}|\text{parametre1, parametre2, parametre3,}\dots)$

X örneğine $P(v|X)$ olasılığını maksimum yapan sınıf etiketi atanır.

Bayes Teoremi:

$$P(v|X) = P(X|v)P(v)/P(X) \quad (5.5)$$

$P(x)$ = bütün sınıflar için sabittir

$P(v)$ = sınıfın bütün örneklerle karşı görel frekansı

$P(v|X)$ maksimum = $P(X|v) P(v)$ maksimum

$$(a_1, \dots, a_k | v) = P(a_1 | v) \dots P(a_k | v)$$

Eğer i. özellik kesikli değerde ise $P(a_i | v)$, v sınıfında i. özellik olarak a_i değerine sahip örneklerin göreceli frekansı olarak tahmin edilir [77].

Eğer i. özellik sürekli ise;

1. Kesikli hale getirilebilir

2. Veya $P(a_i | v)$ Gauss (Normal) dağılımına sahip olduğu varsayılarak tahmin edilir, sadece ortalama varyans gereklidir. İki durumda da hesaplanabilir. Bayes teoremi ikiden fazla değişkeni olan problemlerin çözümünde de kullanılabilir [84].

$$P(A|B, C) = \frac{P(A)P(B|A)P(C|A,B)}{P(B)P(C|B)} \quad (5.6)$$

Bu işlem koşullu olasılığın tanımı ve Bayes teoremi kullanarak bir kaç adımla genişletilebilirse Denklem (5.7) elde edilir [15].

$$P(A|B, C) = \frac{P(A,B,C)}{P(B,C)} = \frac{P(A,B,C)}{P(B)P(C|B)} = \frac{P(C|A,B)P(A,B)}{P(B)P(C|B)} = \frac{P(A)P(B|A)P(C|A,B)}{P(B)P(C|B)} \quad (5.7)$$

Bayes Ağları ile ilgili örnek;

X: Sınıfı bilinmeyen örnek küme.

X: örnek küme nitelikleri $\{x_1, x_2, \dots, x_n\}$

Veri kümesinde m adet sınıf var kabul edilirse $C_1, C_2, \dots, C_m$ X'in herhangi bir C sınıfına ait olma olasılığı

$$P(C_i | X) = \frac{P(X|C_i)P(C_i)}{P(X)}$$

Tablo 5.1 Örnek küme nitelikleri

Örnek	Eğitim	Yaş	Cinsiyet	Kabul
1	orta	yaşlı	erkek	evet
2	ilk	genç	erkek	hayır
3	yüksek	orta	kadın	hayır
4	orta	orta	erkek	evet
5	ilk	orta	erkek	evet
6	yüksek	yaşlı	kadın	evet
7	orta	genç	kadın	hayır
8	ilk	orta	kadın	evet

Aşağıdaki örnek için kabul nedir?

X_1 : eğitim=yüksek, X_2 : yaş=orta, X_3 : cinsiyet=erkek

Tablo 5.2 Örnekte kullanılan veri kümesine ait olasılıklar

		Kabul			
		5 evet		3 hayır	
Nitelikler	Değer	Sayı	Olasılık	Sayı	Olasılık
Eğitim	ilk	1	1/5	2	2/3
	orta	3	3/5	0	0
	yüksek	1	1/5	1	1/3
Yaş	genç	0	0	2	2/3
	orta	3	3/5	1	1/3
	yaşlı	2	2/5	0	0
Cinsiyet	erkek	3	3/5	1	1/3
	kadın	2	2/5	2	2/3

Tablo 5.1 ve Tablo 5.2'deki değerler kullanılarak aşağıdaki hesaplama yapılır.

İki olasılık vardır;

C_1 : Kabul=evet, C_2 : Kabul=hayır

$P(X|c_1)P(c_1)$ c_1 : kabul = evet

$P(X\{x_1, x_2, \dots, x_n\} | \text{kabul=Evet})$ olasılığı

$P(X_1|C_1) = P(\text{eğitim=yüksek} | \text{kabul=evet}) = 1/5$

$P(X_2|C_1) = P(\text{yaş=orta} | \text{kabul=evet}) = 3/5$

$P(X_3|C_1) = P(\text{cinsiyet=erkek} | \text{kabul=evet}) = 3/5$

$P(X|C_1) = P(X|\text{kabul=evet}) = 1/5 * 3/5 * 3/5 = 9/125$

$P(C_1) = P(\text{kabul=evet}) = 5/8$

$P(X|C_1)P(C_1) = P(X|\text{kabul=evet}) * P(\text{kabul=evet})$

$P(X|C_1)P(C_1) = 9/125 * 5/8 = 0.045$

$P(X|C_2)P(C_2)$ C_2 : kabul = hayır

$P(X_1|C_2) = P(\text{eğitim=yüksek} | \text{kabul=hayır}) = 1/3$

$P(X_2|C_2) = P(\text{yaş=orta} | \text{kabul=hayır}) = 1/3$

$P(X_3|C_2) = P(\text{cinsiyet=erkek} | \text{kabul=hayır}) = 1/3$

$P(X|C_2) = P(X|\text{kabul=hayır}) = 1/3 * 1/3 * 1/3 = 1/27$

$$P(C_2) = P(\text{kabul=hayır}) = 3/8$$

$$P(X|C_2)P(C_2) = P(X | \text{kabul=hayır}) * P(\text{kabul=hayır})$$

$$P(X|C_2)P(C_2) = 1/27 * 3/8 = 0.014$$

Sonuç: $0,045 > 0,014$ sonuç **EVET**

Bayes sınıflandırıcıda sıfır sorunu: Örnekte erkek için kabul=hayır olanlar “0” olsa idi $P(X_3|C_2) = P(\text{cinsiyet=erkek} | \text{kabul=hayır}) = 0$ olacaktı. Bu durumda:

$P(X|C_2) = P(X|\text{kabul=hayır}) = 1/3 * 1/3 * 0 = 0$ olacaktır. Yani diğer olasılıkların etkisi sıfır “0” olacaktır. Bu durum anlamlı değildir. Bunun önüne geçmek için k sabiti eklenir. k, 0 ile 1 arasında bir değerdir. Genellikle 1 tercih edilir $(n+kp) / (d+k)$ Burada p, herhangi bir niteliğin iki muhtemel değeri var ise

$p = 1/2 = 0.5$ alınır. Bu durumda, $k=1$ ve $p=0.5$ kabul edilerek

$$P(X|C_2) = P(X|\text{kabul=hayır})$$

$$P(X|C_2) = 1/3 \times 1/3 \times (0+0.5)/(3+1)$$

$$P(X|C_2) = 0.791 \text{ olacaktır.}$$

5.3. Önsel ve Sonsal Dağılımlar

Belirsizlik insan hayatında daima var olan bir unsurdur. Bu belirsizlik bilgi eksikliğine, unutulmuş geçmişe veya henüz meydana gelmemiş durumlara bağlı olabilir. Günlük yaşamda sürekli olarak kullanılan düşünceler, sezgiler bilimsel amaçlar için kullanılabilir. Bu tür oluşumların bilimsel olarak kullanılmasında Bayes yaklaşımı sayesinde kullanılabilir bir hale gelmiştir [84].

Bir olasılıksal sınıflandırma olan Navie Bayes sınıflandırmanın temel fikri, bir olayın sınıfının olasılığını tahmin etmek için verilen bir örneğin sınıfının koşullu olasılıklarını kullanmaktır. Belge sınıflandırma gibi bazı öğrenme problemlerinde yaygın olarak kullanılan pratik yaklaşımdır. Bu yaklaşımın “Naïve” kısmı içindeki kelime bağımsızlığı varsayımından kaynaklanmaktadır. Çünkü kelime kombinasyonlarının olasılıklarını tahminci olarak kullanmaz. Bu yüzden Karar Ağacı gibi algoritmaların üstel karmaşıklığından öte verimli bir yaklaşımdır ve performansı YSA ve Karar Ağacı ile karşılaştırılabilir [83].

Naïve Bayes’de artımlı olarak tabir edilen çevrimiçi bir öğrenme durumu vardır; her bir talim örneği artımlı olarak bir hipotezin doğru olma olasılığını arttırır veya azaltır. Öncül bilgi, gözlemlenen verilerle birleştirilebilir [77].

5.3.1 Önsel Bilgi

Önsel bilgi, bilinmeyen parametre hakkında ön bilgidir. Mevcut veriden hariç uzmanın parametre ile ilgili önceki deneyimini, hissiyatını ve teorik fikirlerini içerir. Bunun dışında daha önce yapılmış çalışmalardan, deneylerden ve uzman görüşlerinden elde edilir [15, 4]. Bayesci çıkarım için önsel bilginin doğru seçilmesi büyük önem taşır. Seçilecek önsel dağılım veriler elde edilmeden önce bilinmeyen parametreler hakkındaki tüm bilgileri en iyi şekilde tanımlamalıdır [84].

5.3.2 Sonsal Bilgi

Sonsal bilgi veri gözlemlendikten sonra çıkarım yapılması istenen parametre hakkındaki olasılık değeridir. Sonsal bilgi, Bayesci çıkarımda bilinmeyen bütün parametreler hakkında bilginin güncel durumunu ortaya koyar. Sonsal bilgi, önsel bilgi ile olabilirlik fonksiyonu kullanılarak elde edilir [78].

5.3.3 Önsel Dağılımın Seçimi

Bayesci modeller oluşturulurken öncelikli olarak yapılacak işlemlerden biri önsel dağılımın belirlenmesidir. Birçok problemde, olasılık fonksiyonu ile ilgili herhangi bir gözlem yapılmadan önce, deney yapan bir kişi, önceki bilgilerini gözden geçirip bir olasılık dağılımı oluşturarak, değişkenin kitle içerisinde nerede bulunabileceğini tahmin edebilir. Başka bir deyişle, herhangi bir deneysel veri elde edilmeden önce, deneyi yapan kişinin geçmiş tecrübeleri ve bilgi birikimi onun, değişkenin kitlenin diğer bölgelerine oranla, belli bazı bölgelerinde bulunmasının daha yüksek olasılıklı olduğuna inanmasına yol açacaktır. Bu olasılıktan elde edilen dağılım önsel dağılımdır [78].

Önsel dağılımın belirlenmesi dikkatli biçimde gerçekleştirilmelidir. Uygun olmayan bir önsel dağılımın seçilmesi yanlış çıkarımlara neden olabilir. Veri elde edilmeden önce elde herhangi bir bilgi yoksa uygun önselin nasıl seçileceği ile ilgili literatürde birçok çalışma yapılmıştır. Ama genellikle önsel olarak bilgi vermeyen dağılımlar kullanılıp,

çıkartım aşamasında veriden öğrenerek önsel bilgi elde edilebilir. Yani bir önceki adımdaki sonsal dağılım, bir sonraki adımda önsel dağılım olarak kullanılabilir. Fakat bu durum bazen sonuca yakınsamayı geciktirebilir veya yanlış önsel seçimi kötü çıkarımlarla sonuçlanabilir [84]. Önsel dağılım olarak bilgi veren önsel seçildiğinde çoğu zaman konu ile ilgili daha önce yapılmış olan çalışmaların sonuçlarını kullanmak yararlı olabilir. Bu durumda önsel bilgi, önceki çalışmaların meta analizinin yapılması ile elde edilebilir. Fakat çoğu durumda var olan bilgilerin önsel ile ifade edilmesi zor olabileceği için bilgi vermeyen önsellerin kullanması gerekli olabilir. Parametre belirlenmiş bir aralıkta olmak zorunda ise çıkarımlar bu aralıktan üretilmelidir. Örneğin, derecelmeler toplamıyla gerçekleştirilen Likert tipi bir anketten alınan 0,1,...,100 şeklinde değerlerin, ortalamasının 0 ve 100 arasında olmak zorunda olduğu söylenebilir. Böyle bir durumda sınırlar bir önsel bilgidir. Sonucu daha geniş bir aralıkta aramak mantıksız olacaktır. Ayrıca sınırlı aralık için yapılan çıkarımın hatası diğerine göre daha düşük olacaktır [84].

Bayesci çıkarıma yapılan eleştirilerden biri yanlış veya yanlış oluşturulmuş bir önselin çıkarıma olan etkileridir. Bu yüzden, objektif önseller seçilmelidir. Objektif önseller veriden daha az bilgi içeren önsellerdir. Önselin etkisi örneklem büyüdükçe azaldığı için yanlış önsel sorununun sadece küçük örneklem çıkarımları için tehlikeli olduğu belirlenmiştir. Önsel dağılım seçiminde herhangi belirgin bir kural bulunmamaktadır. Çoğunlukla hangi önsel dağılımın daha uygun olacağını kestirmek zordur. Bu durumda, önsel dağılımın çıkarımları ne kadar etkilediği incelenmelidir [78].

5.4. Bayes Yaklaşımı ile Klasik Yaklaşım Arasındaki Farklılıklar

İstatistik konusunda temel olarak iki farklı felsefi yaklaşım olan Klasik (Frekansçı, Berkeley istatistiği) ve Bayes yaklaşımının belirginleştiği görülmektedir. Bu iki yaklaşım başlangıç aksiyomlarının yorumlanmasında, pek çok konu ve kavramın ele alınışında birbirine alternatif olmuştur. Bayes yaklaşımı gelişme süreci göz önünde bulundurulduğunda, kendi disiplini olan alternatif bir yaklaşım olduğu için pek çok istatistiksel kavram bu yaklaşımda farklı yorumlanmakta ve ele alınmaktadır [86].

Klasik yaklaşım tümdengelim yöntemi, Bayes yaklaşımı tümevarım yöntemiyle paralellik gösterir. Ayrıca pek net olamamakla birlikte klasik yaklaşım nedensellik ilkesinin deterministik yorumuna yakın iken, Bayes yaklaşımı olasılıklı yorumuna yakındır. Bayes yaklaşımında herhangi bir olayın olasılığı hesaplanırken, deneme yapılan paranın veya zarın hilesiz olması gibi, başlangıç varsayımlarına ihtiyaç duyulmamaktadır.

Çünkü pratikte her zaman geçerli olamayacak böyle varsayımlar olmadan, bu konuda gerekli olan alt yapı ön bilgi ile sağlanmaktadır [86]. Bayes yaklaşımı ile klasik yaklaşım arasındaki en önemli fark, parametre kavramına olan yaklaşımlarındadır. Klasik yaklaşımda, parametrenin sabit olduğu kabul edilip analizler doğrudan veriden elde edilen bilgi olan olabilirlik fonksiyonu ile yapılırken, Bayes yaklaşımında parametre, rastlantı değişkeni olarak kabul edilir ve sonsal bilgi bir önsel dağılım kullanılarak elde edilir. Klasik istatistiği savunanlar bu ön bilgiyi, gözlenmediği ve kişiden kişiye değişkenlik gösterebileceğinden dolayı kabul etmemektedirler. Ancak istatistiğin verimli olarak kullanımında önsel düşünce de önemli bir rol oynamaktadır. Klasik istatistikçilerin göstermiş oldukları itirazlara rağmen Bayesci olmayan bir bilim adamı olan Freedman'ın "verilerden çıkarsamalar yapılacağı zaman, en muhafazakâr istatistikçi bile, bazı varsayımları ve önsel bilgileri kullanmak zorunda kalacaktır" şeklinde bir açıklamada bulunması, ek bilginin gerekliliğini vurgulamıştır. Bu sayede Bayesci yöntemler klasik yöntemlere göre daha doğru çıkarımlarda bulunur [78].

5.5. Bayes Yaklaşımının Avantajları ve Dezavantajları

Bayes yaklaşımında en çok önsel dağılımın oluşturulması ve sonsal dağılımın elde edilmesi aşamasında zorluklarla karşılaşılır. Önsel dağılımların elde edilmesi aşamasında zorluklar, parametre hakkındaki kesin olmayan önsel bilgilerin önsel dağılıma dönüştürülmesi işleminde ortaya çıkar. Çok değişkenli modeller söz konusu olduğunda, özellikle parametreler arasında önsel ilişkiler varsa, bilgi içeren önsel dağılımların belirlenmesi zorlaşır ve elde edilen önsel dağılımlar karmaşılaşır. Parametreler arasında karmaşık önsel dağılımlar söz konusu olduğunda, sonsal dağılımların elde edilmesi de zor olabilir [78].

Bayes yaklaşımının üstünlüğü klasik istatistikte çözüm bulunamayan problemlere çözüm bulunabilmesinden kaynaklanmaktadır. Örneğin, klasik istatistikte tam olarak çözüm bulunamayan problemlerden biri olan Behrens-Fisher problemi için Bayes yaklaşımı ile bir çözüm sağlanabilmektedir [78]. Bayes yaklaşımı, süreç hakkındaki bilgilerin optimal kullanımına izin verir. Çıkarım yapmak için örneklem büyüklüğü bir kısıt değildir. Büyük örneklemelerle çalışmak istatistiksel süreç kontrolünde önemli bir maliyettir. Fakat Bayesci istatistik, kullanılan süreçlerde maliyet kısıtı gözetilerek toplam denetleme maliyeti minimize edilebilir. Sonuç olarak Bayes yaklaşımı klasik istatistik temelli tahminlerde görülen sıkıntılı durumlarda birçok avantaja sahiptir [78].

5.5.1 Birleşik Olasılık Dağılımı

Birleşik olasılık dağılımında her değişken ağdaki bilgi ile hesaplanabilir. Bir değişken, diğer değişken değerlerinin birleşiminin olasılığı olarak gösterilebilir.

$$(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i | P_a(x_i)) \quad (5.8)$$

Böylelikle birleşik olasılık dağılımındaki her değişkenin Koşullu Olasılık Tablolarındaki (KOT) değerlerin çarpımı ile temsil edilebilir. Birleşik olasılık dağılımına dayanan bu hesaplama ile ağdaki değişkenlere ait tüm sorgular cevaplanabilir [78].

5.5.2 Bayes Ağlarının Oluşturulması

Birleşik olasılık dağılımı temsili Bayes ağlarının oluşturulmasında kullanılır. Öncelikle birleşik olasılık dağılımı koşullu olasılık cinsinden $P(x_1, \dots, x_n) = P(x_n | x_1, \dots, x_{n-1})P(x_1, \dots, x_{n-1})$ şeklinde açılır. Bu işlem formüldeki her birleşik olasılık, koşullu olasılıkla temsil edilene kadar devam ettirilir ve böylece bir zincir kuralı oluşur [1].

$$\begin{aligned} P(x_1, \dots, x_n) &= P(x_n | x_1, \dots, x_{n-1})P(x_{n-1} | x_1, \dots, x_{n-2}) \dots P(x_2 | x_1)P(x_1) \\ &= \prod_{i=1}^n P(x_i | x_1, \dots, x_{i-1}) \end{aligned} \quad (5.9)$$

Bu formül her düğüm ile ataları arasında koşullu bağımsızlığı yani ağın ata-ebeveyn-çocuk ilişkileriyle nasıl oluşturulacağını gösterir. Doğru bir ağ oluşturabilmek için her düğüm ve ataları yukarıdaki eşitliğe uygun olmalıdır. Kısaca X_i düğümünün ebeveynleri, X_i üzerinde etkisi olan $X_1 \dots X_{n-1}$ aralığındaki tüm düğümleri içermelidir.

Bayes ağları düğümler arasındaki bu etkileri birleşik olasılıklardan yararlanarak koşullu olasılığa çevirir ve bu şekilde ağ oluşturulur. Bu sayede ağ genellikle doğrusal karmaşıklıkta büyür. Eğer ağda n adet düğüm ve bunların etkilendiği k adet düğüm varsa, düğümlere ait KOT'larında 2^k adet veri tutulur. Ağ n adet düğümden oluştuğu için tüm ağ $n * 2^k$ ile ifade edilebilir. Ancak ele alınan alandaki tüm değişkenler birbirlerinden etkilenirse ağ yapısı tam bağlı bir hal oluşturur ve karmaşıklık üstel olarak artar. Böyle bir durumda ağı tasarlayıp çıkarım yapmak her zaman mümkün olmayabilir. Düğümlerin gelişigüzel ağa yerleştirilmesi de ağ içerisindeki bağ sayısını dolayısıyla da KOT'sunda tutulacak değerleri arttıracaktır. Bu durum hesaplanması zor olasılıklar doğurabilir. Kötü bir yapıdan kaçınmak için modeli oluşturulacak alan iyice incelenmeli, değişkenler

arasındaki neden-sonuç-etki ilişkileri çıkarılmalıdır. Bundan sonra yapılacak eklemeler; kök-ata-ebeveyn-çocuk-yaprak sırasında yapılmalıdır [78].

5.5.3 Bayes Ağ Modellerinde Öğrenme

Bir modelin bağımlılık yapısı ve koşullu olasılık fonksiyonları uzman görüşü ile sağlanabilir. Birçok uygulamada, bu bilgi elde edilemeyebilir. Buna ek olarak, farklı uzman kişiler farklı uzman görüşleri verebilir. Bu gibi durumlar ele alınan problemde bilgi karmaşası oluşturur. Bu nedenle, modelin bağımlılık yapısı ve koşullu olasılık fonksiyonları veriden tahmin edilir. Bu süreç öğrenme olarak adlandırılır. Amaç, mevcut veri tabanı kullanılarak, en iyi modeli elde etmektir. Öğrenmenin iki farklı çeşidi vardır. Grafikte yer alan bağlantıları belirleyen bağımlılık yapısını öğrenme yapısı öğrenmeyi, koşullu olasılık fonksiyonlarının parametrik yapısını öğrenme ise parametre öğrenmeyi ifade eder [87].

5.6. Uygulama Alanları

Verilerin değerlendirilme ve birleştirilme biçimi, Bayes yaklaşımını kullanan uygulama alanlarını çoğaltmaktadır. Özellikle banka ve genetik gibi sektörlerde, mevcut verilerle yapılan analizlerin, geçmişteki verilerle desteklenerek bir takım sonuçlara varılması elde edilen sonuçların güvenilirliği açısından daha uygun olmaktadır. Bayes yaklaşımı nitel ve nicel bilgileri istatistiksel temellere dayandırarak birleştirebildiği için, uygun bir çözüm sunabilmektedir. İmgelerden sonuç çıkartan uygulamalarda, borsa gelecek değer tahmin uygulamalarında, otomatik öğrenme sistemlerinde Bayes tipi olasılık kavramları kullanılabilmektedir. Ayrıca bu teorem genetik danışmanlar tarafından, soy ağacı bilgileri ile klinik verilerin kombine edilmesinde ve taşıyıcılık risklerinin hesaplanmasında kullanılmıştır. Bilgisayar destekli tanısal yaklaşımda kullanımı giderek artmaktadır [78].

5.7. Naïve Bayes Sınıflandırıcı

Naïve Bayes sınıflandırıcı kuvvetli bağımsız varsayımlarla Bayes teoremi temeline dayanan olasılıklı bir sınıflayıcıdır. Naïve Bayes sınıflandırması, belirli örneklerin özelliklerinin birbirlerinden şartlı bağımsız oldukları varsayımı üzerine dayanır. Saf Bayes olarak da isimlendirilebilen bu sınıflandırıcıların çalışma mantığı şu şekildedir. Eğer elde

ayıklanıp sınıflara atanmış bir miktar belge var ise, bu bilgiyi yeni gelen belgelerin sınıflandırılması için kullanabilecek yarı otomatik bir sistem kurulabilir. Sınıflandırıcı terimlerin belge içinde dağılımını hesaplayarak, yeni gelen belgeler için sınıf tahmininde bulunabilir.

Yalın tasarımına ve görünüşte basitleştirilmiş varsayımlarına rağmen Naïve Bayes sınıflandırıcılar gerçek dünya problemlerinde etkin bir şekilde kullanılabilir ve beklenilenden daha iyi sonuçlar vermektedir [78]. Örneklerin özelliklerinin birbirlerinden şartlı bağımsız oldukları varsayımı, özelliklerin birbirleriyle güçlü bir şekilde bağımlı olduğu gerçek dünya problemlerine çok uygun olmasa da, problemi basitleştirerek çok boyutluluğun etkisini azaltmaya yardımcı olmaktadır. Eğitim ve değerlendirme işlemlerinin çok hızlı olması ve gerçek dünya problemlerinde şaşırtıcı derecede iyi sonuçlar vermesi avantajlarıdır. Çok karmaşık sınıflandırma problemlerini çözmede yetersiz kalabilmesi ise dezavantajıdır [78].

5.7.1 Naïve Bayes Olasılık Modeli

Naïve Bayes sınıflandırıcısı, birçok sınıflandırma probleminde başarısı kanıtlanmış, popüler bir makine öğrenmesi tekniğidir [81]. Naïve Bayes sınıflandırıcısı, çok iyi bilinen, pratik, olasılığa dayanan, birçok uygulamada kullanılan bir sınıflayıcıdır. Chakrabarti ve arkadaşları bir külliyattaki metinlerin hiyerarşik olarak organize edilmesi için Naive Bayes'i kullanmışlardır. Frietag ve McCallum, dokümanlardan bilgi çıkarabilmek için, ağın her düğümündeki kelime dağılımını hesaplamak amacıyla Naïve Bayes benzeri bir model kullanmıştır. Dumais ve arkadaşları doküman sınıflama işlemini otomatize etmek amacıyla Naïve Bayes ve diğer metin sınıflayıcıları kullanmışlardır. Naïve Bayes' in oldukça sık kullanılmasının bir başka nedeni kolay anlaşılabilir bir yöntem olmasıdır. Bazı alanlarda Naïve Bayes, performans olarak YSA ve karar ağacı öğrenmelerine karşı tercih edilebilir. Peng ve arkadaşları, Bayes teoremini kullanarak dokümanlardan elde ettikleri karakter bazlı n-gram'larla yazar tanıma uygulaması gerçekleştirmişlerdir. Domingos ve Pazzani, Naïve Bayes' in hangi durumlarda sınıflandırma için en uygun olduğunu ve hangi durumlarda olasılık tayinlerinin (assessment) yanlış olduğunu araştırmışlardır. Domingos ve Pazzani bu noktayı netleştirip, Naïve Bayes'in sınıflandırma için en uygun olduğu basit durumları göstermişlerdir. Naïve Bayes hedefe ulaşmak için en uygun imkânları seçmeye yönelik bir model oluşturur [88].

Yeni örnekler üzerindeki sınıflandırma, Bayes kuralı kullanılarak, örneğe en çok benzeyen sınıf seçilerek yapılır. Naïve Bayes sınıflandırıcısı örneklerin tüm özelliklerinin, sınıfın şartlarını veren özellikler açısından birbirinden bağımsız olduğunu kabul eder. Buna “Naïve Bayes Bağımsızlık Varsayımı” denir. Bu varsayım birçok gerçek problemde geçersiz olsa da, Naïve Bayes çoğu zaman çok iyi sınıflandırma performansı gösterir ve bu sebeple diğer Bayes sınıflandırıcılardan hesaplama zamanı olarak çok daha hızlı çalışır. Bağımsızlık varsayımı ve her özellik için, parametreler ayrı olarak öğrenilir ve bu durum genelde özellik sayısı çok olduğunda öğrenmeyi büyük ölçüde kolaylaştırır. Naïve Bayes sınıflandırıcısı, her x örneğinin bir özellik vektörüyle ifade edildiği ve hedef fonksiyon $f(x)$ ’in V sınırlı değer kümesinden herhangi bir değer alabildiği öğrenme işlerine uygulanır. Hedef fonksiyon için bir eğitim seti hazırlanır $\langle a_1, a_2, \dots, a_n \rangle$ şeklindeki özellik vektörüyle ifade edilen, yeni bir örnek alınır ve eğiticiden bu örneğin hedef değerini yani ait olduğu sınıfı tahmin etmesi istenir. Yeni gelen örneğin sınıfının belirlenmesi, Bayes yaklaşımına göre, örneği anlatan $\langle a_1, a_2, \dots, a_n \rangle$ özellik değerlerine göre en uygun hedef değerinin, $vMAP$ (maximum a posteriori hypothesis), atanmasıdır [88].

$$V_{MAP} = \underset{v_j \in V}{\operatorname{argmax}} P(v_j | a_1, a_2, \dots, a_n) \quad (5.10)$$

Bayes teoremi kullanılarak (5.10)’deki Denklem şöyle yazılabilir:

$$V_{MAP} = \underset{v_j \in V}{\operatorname{argmax}} \frac{P(a_1, a_2, \dots, a_n | v_j) P(v_j)}{P(a_1, a_2, \dots, a_n)} \quad (5.11)$$

$$V_{MAP} = \underset{v_j \in V}{\operatorname{argmax}} P(a_1, a_2, \dots, a_n | v_j) P(v_j) \quad (5.12)$$


Eğitim verisine dayanarak (5.10)’deki iki terim hesaplanır. Her $P(v_j)$ değeri, eğitim verisinde geçen, her hedef değer v_j ’nin frekansı sayılarak kolaylıkla hesaplanabilmektedir. Bu terimlerin sayısının olası örnekler çarpı olası hedef değerleri sayısına eşit olması probleme neden olabilir. Bu nedenle, gerçekçi hesaplar elde etmek için her örneğin, örnek uzayında defalarca görülmesi gerekmektedir. Naïve Bayes sınıflandırıcısı, özellik değerlerinin, hedef değerden bağımsız olması kabulüne dayanır. Bir başka deyişle, $(a_1, a_2, \dots, a_n)$ Bağlamının olasılığı, her bir özelliğin olasılıklarının ürünüdür [88].

$$P(a_1, a_2, \dots, a_n | v_j) = \prod_i^n P(a_i | v_j) \quad (5.13)$$

Bu Denklemi (5.12) de yerine koyarsak Naïve Bayes sınıflandırma yaklaşımını elde etmiş oluruz.

$$V_{NB} = \underset{v_j \in V}{\operatorname{argmax}} P(v_j) \prod_i^n P(a_i|v_j) \quad (5.14)$$

V_{NB} , Naïve Bayes sınıflandırıcısının çıktısını, yani sınıfı gösterir. Bir Naïve Bayes sınıflandırıcısında, eğitim verisinden hesaplanması gereken farklı $P(a_i|v_j)$ terimlerinin sayısı, farklı özellik değerleri çarpı farklı hedef değerleri sayısı kadardır. Kısaca, Naïve Bayes öğrenme metodu, çeşitli $P(v_j)$ ve $P(a_i|v_j)$ terimlerinin eğitim verisi üzerindeki frekanslarına dayanarak hesaplandığı bir öğrenme aşamasıdır. Bu hesaplanma bütünü, öğrenme hipoteziyle ilişkilidir. Bu hipotez, daha sonra (5.14)'teki Denklem uygulanarak her yeni örneğin sınıflandırılması için kullanılır [88].




Şekil 5.1 Sınıflandırma görevinin görselleştirilmesi

Şekil 5.1'de yukarıda anlatılan sınıflandırma işleminin görselleştirilmesi görülmektedir.

5.8. Naïve Bayes Sınıflandırıcısının Filtre Olarak Kullanılması

İmge içerisindeki gürültülü pikseller detektör tarafından tespit edildikten sonra ikinci aşama olan restorasyon aşamasına geçilir. Restorasyon işlemi sadece gürültülü piksellere uygulanır. Restore edilecek piksel değerlerini belirlemek için Bayes sınıflandırıcı kullanılacaktır. Öncelikle sınıflandırıcının kullanacağı bir öğrenme setine ihtiyaç vardır.



Şekil 5.2 Eğitim setlerini oluşturmak için resmin parçalara ayrılması;
a)Bozulmuş imge, b) parçalara ayrılmış imge

Bunun için; Şekil 5.2.a'deki bozulmuş olan imge Şekil 5.2.b'de görüldüğü gibi parçalara ayrılır. Bu parçalardan gürültü bulaşmamış 9 ayrı veri havuzu oluşturulur. Tablo 5.3'de şekil 5.2 teki parça-1 parçasının gürültü bulaşmamış bölümlerinden oluşturulmuş önsel (gürültü bulaşmamış) bilgiler bulunmaktadır. Resmin kaç parçaya ayrılacağı ve her parçadan eğitim seti için kaç örnek alınacağı tasarımcıya aittir. İmgelerin fazla parçalara ayrılması ve bu parçalardan da eğitim seti için fazla değer alınması, filtrenin hassasiyetini artırırken, hesaplama zamanını ise ciddi bir şekilde arttırmaktadır. Tablo-5.3'deki eğitim seti hazırlanırken;

$$x = \{a_1, a_2, \dots, a_n\}, a = \{1, 2, 3, \dots, 254\}, n = \{1, 2, 3, \dots, 8\}, V_j = \{1, 2, 3, \dots, 254\}' \text{ dir.}$$

Tablo 5.3 Parça-1'deki öğrenme setine ait bir örnek

Tahmin edici sütunlar (özellikler)									
	a_1	a_2	a_3	a_4	a_5	a_6	a_7	a_8	V_j
x_1	131	132	136	136	137	138	140	147	137
x_2	132	137	138	140	142	144	147	147	142
x_3	140	142	144	147	147	149	149	151	147
.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.
.	150	152	153	154	155	155	155	157	155
.	166	167	168	170	172	172	172	173	172
.	167	168	168	170	170	170	170	172	170
.	167	168	168	168	169	169	170	170	169
x_m	168	168	169	169	170	170	171	172	170

Tablo 5.4 Tablo 5.3 kullanılarak Eğitim seti-1'in yoğunluk değerlerinin oluşturulması

Yoğunluk değeri	147	151	155	156	157	158	159	163	165	167	170	172	173
Eğitim setindeki tekrarlanma sayısı	2	1	4	1	7	3	5	2	1	2	4	3	5

Hesaplama yapılacak değer aralığı (gürültülü pikselin gerçek değeri), 0 ile 255 arasında oluşabilecek 256 değerden herhangi bir değerdir. Fakat bu 256 değer için hesaplama yapmak işlem süresini uzatacağı için, hatalı piksel yerine geçebilecek olan değer, komşuluk ilişkisi içinde kendisine en yakın olan piksel olacağından sadece komşusu olan 8 adet piksel değerinin olasılıkları hesaplanır. Bu sekiz değer dışındaki $(256-8)=248$ yoğunluk değerinin olasılığı eşit olup, komşu piksellere göre düşük olasılıklıdır. Bu sayede komşu olmayan, çok küçük olasılıklara sahip yüzlerce ihtimal hiç hesaplanmaz. Sadece yüksek olasılığa sahip komşu pikseller hesaplanıp, hatalı pikselin yerine gelmesi gereken değer atanır. Örneğin Tablo-1'deki eğitim setini kullanarak bozulmuş bir pikselin yerine atanacak değeri bulmaya çalışalım. Bozulmuş bu pikselin komşuları, detektör tarafından elde edilmiş olan $x = \{188, 155, *, 157, 157, 159, 170, *\}$ vektörü değerlerinden oluşmuş olsun. Şekil 5.3'te küçük kare içerisinde restore edilecek olan gürültü piksel, büyük kare içerisinde ise gürültülü pikselin komşuları görülmektedir.

				j			
	156	165	167	165	170	*	171
	163	164	*	182	175	172	170
	*	175	188	155	*	157	*
i	255	*	*	157	*	159	*
	167	155	156	159	170	*	*
	*	180	*	159	170	*	*
	175	*	*	200	*	204	*

Şekil 5.3 Bozulmuş Beyin MR'ına ait rastgele bir kesit görülmektedir

Gürültülü pikseller “*” sembolü ile gösterilmektedir. $a_2 = *$ ve $a_8 = *$ Gürültülü piksellerdir, $a_1 = 155$, $a_3 = 157$, $a_4 = 157$, $a_5 = 159$, $a_6 = 159$, $a_7 = 170$ komşu piksellerdir. Detektör tarafından gürültü olarak işaretlenen piksel olasılık hesaplamasına

dahil edilmez. Örneğin (a_2, a_8) değerleri hesaplanmayacaktır. Denklem (5.14) kullanılarak $a_1 = 155$ pikselinin bozuk piksel yerine gelme olasılığı hesaplanır.

$$\begin{aligned}
& (V_j = a_1 = 155) \\
& = P(V_j) \\
& * [P(a_1 = 155|V_j) * P(a_3 = 157|V_j) * P(a_4 = 157|V_j) \\
& * P(a_5 = 159|V_j) * P(a_6 = 159|V_j) * P(a_7 = 170|V_j)] \\
& P(V_j = a_1 = 155) = \frac{4}{40} \left[\frac{0.01}{4} * \frac{1}{4} * \frac{1}{4} * \frac{0.01}{4} * \frac{0.01}{4} * \frac{0.01}{4} \right] = 2.5e-013
\end{aligned}$$

$a_1, a_3, a_4, a_5, a_6, a_7$ pikselleri aynı yöntemle hesaplanıp Tablo 5.5'te gösterilmiştir.

Tablo 5.5 x vektör elemanlarının hesaplanmış olasılık değerleri

Pikseller	a_1	a_3	a_4	a_5	a_6	a_7
Olasılık değerleri	2.5e-13	1.8e-9	1.8e-9	8.0e-18	8.0e-18	2.5e-15

Tablo 5.5'teki olasılık değerleri arasından en yüksek olasılığa sahip olan piksel aşağıdaki gibi belirlenir.

$$\begin{aligned}
& argmax_{v_j \in \{0 \dots 255\}} \left\{ P(V_j) \prod_i^n P(a_i|v_j) \right\} = \max\{2.5e-13, 1.8e-9, 8.0e-18, 2.5e-15\} \\
& = P(V_j = a_3 = 157)
\end{aligned}$$

Hesaplama sonucu hatalı piksel yerine 157 değeri gelmelidir. Hangi parçada olma durumuna göre o parça için eğitilmiş veri madeninde hesaplama yapılır. Hesaplama sonucunda en yüksek ihtimale sahip piksel, bozuk olan piksel yerine yerleştirilir. İterasyon bu şekilde devam eder.

5.9. Deneyisel Sonuçlar ve Simülasyon Analizi


Önerilen metot olan Naïve Bayes sınıflandırıcı filtre (NBCF) önceki bölümde açıklanmıştı. Bu kısımda ise son zamanlarda darbe gürültüsü yok etmek için popüler olarak kullanılan filtreler ile bizim önerdiğimiz metot karşılaştırıldı. Deneyisel sonuçların tümü

MATLAB üzerinde uygulandı. Deneylerdeki test imgesi için literatürde popüler olan Lena ve Beyin MR imgeleri kullanıldı. Karşılaştırma için bozulmuş imgeler hem geleneksel hem de modern metotlar vasıtasıyla iyileştirildi.

İyileştirilmiş imge ile orijinal imge arasındaki restorasyon kalitesini belirlemede literatürde iyi bilinen sıklıkla kullanılan popüler metotlar olan PSNR ve MSE kriterleri ile değerlendirme yapıldı.

Tablo 5.6 Beyin MR test imgesinin iyileştirme sonuçlarının PSNR (db) ve MSE karşılaştırılması

Filtreler		%10	%20	%30	%40	%50	%60	%70	%80	%90	%95
NBCF	PSNR	41.23	39.08	37.1	35.19	33.43	32.21	30.4	28.63	25.99	23.89
	MSE	4.90	8.04	12.68	19.68	29.52	39.09	59.30	89.14	163.71	265.51
IDBA	PSNR	37.5	34.48	30.72	29.12	27.26	25.45	23.5	22.64	19.3	16.65
	MSE	11.56	23.18	55.09	79.63	122.20	185.39	290.46	354.1	764.0	1406.3
CWMF	PSNR	28.92	23.75	21.21	17.33	15.81	12.76	11.04	9.36	5.75	4.71
	MSE	83.38	274.21	492.13	1202.5	1706.4	3444.1	5117.8	7534.9	17301	21983
AMF	PSNR	39.52	34.86	32.38	30.24	28.46	26.83	25.02	23.29	20.62	18.75
	MSE	7.26	21.24	37.59	61.53	92.70	134.92	204.68	304.85	563.74	867.12
DBSMF	PSNR	36.56	33.23	30.84	28.1	25.65	23.53	17.41	15.12	12.68	8.83
	MSE	14.36	30.91	53.59	100.71	177.04	288.46	1180.5	2000.2	3508.2	8513.0
SNFF	PSNR	30.91	28.23	26.24	24.35	21.73	19.36	16.74	15.36	14.59	12.87
	MSE	52.73	97.74	154.55	238.83	436.60	753.49	1377.5	1892.7	2259.9	3358.0
TLIDE	PSNR	33.56	29.55	23.88	21.25	17.45	14.21	10.89	8.57	6.94	5.01
	MSE	28.65	72.12	266.12	487.62	1169.7	2466.5	5297.6	9038.2	13155	20515
DBA	PSNR	36.8	33.57	28.95	27.3	24.85	23.6	21.94	18.07	17.75	16.42
	MSE	13.59	28.58	82.81	121.08	212.85	283.84	415.99	1014.1	1091.6	1482.8
NFT	PSNR	38.8	36.65	33.4	31.2	29.3	27.06	23.42	20.08	18.74	16.47
	MSE	8.57	14.06	29.72	49.33	76.40	127.96	295.9	638.4	869.1	1465.8




Şekil 5.4 %40 gürültü eklenmiş Beyin MR imgesinin farklı filtreler ile imge iyileştirme sonuçları;
a) Orijinal imge b)Bozulmuş imge, c) DBA filtre çıkışı, d) NFT filtre çıkışı, e) IDBA filtre çıkışı, f) CWMF filtre çıkışı g) AMF filtre çıkışı, h) DBSMF filtre çıkışı, i) SNFF filtre çıkışı, j) TLIDE filtre çıkışı, k) NBCF çıkışı


Şekil 5.4'teki beyin MR test imgesinin %40 gürültü sonrasında farklı filtrelerle ait iyileştirme sonuçları görülmektedir. Görsel performansı dikkate alındığında Tablo 5.6'daki değerleri doğrular nitelikte olduğu görülmektedir.

Tablo 5.7 Lena.bmp test imgesinin iyileştirme sonuçlarının PSNR (db) ve MSE karşılaştırılması


Filtreler		%10	%20	%30	%40	%50	%60	%70	%80	%90	%95
NBCF	PSNR	42.84	39.72	37.38	36.13	34.42	33.28	32.1	31.3	29.75	26.15
	MSE	3.38	6.94	11.89	15.85	23.5	30.55	40.09	48.2	68.88	157.7
IDBA	PSNR	39.66	36.85	34.53	32.65	31.05	29.32	28.01	25.9	22.6	18.6
	MSE	7.03	13.43	22.91	35.32	51.06	76.05	102.8	167.1	410	897
CWMF	PSNR	32.42	29.61	27.18	23.81	20.43	17.07	13.96	11.15	8.72	6.87
	MSE	37.25	71.13	124.5	270.5	589	1277	2613	4990	8731	13368
AMF	PSNR	39.52	34.86	32.38	30.24	28.46	26.83	25.02	23.29	20.62	18.75
	MSE	7.26	21.24	37.59	61.53	92.7	134.9	204.7	304.9	563.7	867.1
DBSMF	PSNR	38.42	34.28	30.47	27.38	24.92	22.05	18	14.12	10.03	7.36
	MSE	9.36	24.27	58.36	118.9	209.5	405.6	849.3	2518	6458	11942
SNFF	PSNR	30.89	29.3	24.45	22.12	20.1	18.36	16.81	15.23	14.22	13.12
	MSE	52.98	76.4	233.4	399.1	635.5	948.6	1355	1950	2461	3170
TLIDE	PSNR	34.42	29.5	23.87	20.99	16.63	14.42	11.21	8.91	7.72	6.02
	MSE	23.5	72.96	266.7	517.7	1413	2350	4921	8358	10992	12914
DBA	PSNR	39.8	36.59	34.29	32.25	30.38	28.45	26.36	23.79	20.13	19.17
	MSE	6.81	14.26	24.21	38.73	59.58	92.91	150.3	271.7	631.1	787.1
NFT	PSNR	39.3	35.66	32.7	30.01	27.73	25.5	23.73	21.01	17.69	15.29
	MSE	7.64	17.66	34.92	64.88	109.7	183.3	275.5	515.3	1107	1923




Şekil 5.5 Lena bmp. İmgesine ait farklı filtreler için PSNR (dB) değerleri



Şekil 5.6 Lena bmp. İmgesine ait farklı filtreler için PSNR (dB) değerleri




Şekil 5.7 Lena bmp. İmgesine ait farklı filtreler için MSE değerleri



Şekil 5.8 Lena bmp. İmgesine ait farklı filtreler için MSE değerleri

Tablo 5.7, Şekil 5.5, Şekil 5.6, Şekil 5.7 ve Şekil 5.8'deki grafikler incelendiğinde önerilen algoritmanın diğer metotlara göre önemli ölçüde iyileştirme sağladığı açıkça görülmektedir. Algoritma, özellikle yüksek gürültü oranlarındaki test sonuçları ile sınıanmıştır. Gürültü yoğunluk aralığı % 10 ile % 95 arasında seçilmiş olup artış miktarı ise %10 olarak uygulanmıştır.



Şekil 5.9 %60 Gürültü eklenmiş Lena imgesinin farklı filtreler ile imge iyileştirme sonuçları;

a) Orjinal imge b)Bozulmuş imge, c) DBA filtre çıkışı, d) NFT filtre çıkışı, e) IDBA filtre çıkışı, f) CWMF filtre çıkışı g) AMF filtre çıkışı, h) DBSMF filtre çıkışı, i) SNFF filtre çıkışı, j) TLIDE filtre çıkışı, k) NBCF çıkışı

Son olarak Şekil 5.9’da %60 gibi yüksek oranda darbe gürültüsüne maruz kalmış Lena test imgesinin çeşitli filtreler tarafından iyileştirme sonuçları görülmektedir. Şekil 5.9.k’da imge incelendiğinde sayısal verilen dışında resmin görsel olarak da diğer imgelere göre özellikle kenar ve detaylarının daha iyi korunduğu ve hemen hemen tüm bozuk piksellerin onarıldığı görülmektedir. NBCF filtresi diğer filtreler ile karşılaştırıldığında mükemmel görsel sonuçlar elde edilmiştir. Darbe gürültüsünü yok etmek açısından bu sonuçlar oldukça önemlidir.

6. SONUÇLAR VE ÖNERİLER

6.1. Sonuçlar

Bu tez çalışmasının üçüncü bölümünde sunulan DCFAMF metodu aşırı derecede bozulmuş imgeleri etkili bir şekilde restore etmiştir. Bu algoritma basit yapılı olmasının yanında, tüm gürültü düzeylerinde başarılı ve hızlı bir şekilde uygulanabilmiştir. Algoritmanın darbe gürültüsünü bastırırken imgenin detaylarını da koruduğu Şekil 3.2 ve Şekil 3.4'teki görsel performanslarında da açıkça görülmektedir. Algoritmanın hızlı olması sebebiyle gerçek zamanlı uygulamalarda kullanılması uygundur. Ayrıca algoritmanın imgeyi iyileştirmeye başlamadan önce herhangi bir ön hazırlığa ya da parametre değişimine gerek duymaması da filtrenin önemli bir avantajıdır.

Bölüm 4'te ise literatürde daha önce de çalışılmış olan yapay sinir ağları ile gürültü giderme metodu geliştirilerek, farklı eğitim algoritmalarında denenip en ideali olan elde edildikten sonra uyarlamalı hale getirilmiştir. Çünkü YSA tabanlı filtreler sadece eğitildikleri gürültü oranlarında etkili olabilmektedirler. Önerilen filtrede ağ bir kez eğitildikten sonra tüm imge çeşitlerine ve gürültü oranlarına başarılı bir şekilde uygulanabilmektedir. Uyarlamalı hale getirilen ağlar öncesine ve sonrasına eklenen yeni algoritmalar ile de hem daha etkili hem de daha hızlı bir hale getirilmiştir. Bir avantajı da aynı tür filtrelerle kıyaslandığında, seçilen uygun ağ parametreleri sayesinde de daha az iterasyonla ağların eğitimi tamamlanmıştır.

Bölüm 5'te sayısal bir imgedeki darbe gürültüsünü tespit etmek kadar, tespit edilen gürültünün temizlenmesi de önemlidir. Bozulmuş piksel etrafındaki komşu piksellerin medyan değerini almak yerine, Naïve Bayes sınıflandırıcı yöntemi kullanarak belirlenmiştir. Bu bölümde ilk önce, detektör tarafından bozulmamış piksellerden, bir öğrenme seti oluşturulmakta ve bu öğrenme seti kullanılarak sınıflandırma işlemi yapılmaktadır. Naïve Bayes sınıflandırıcı filtre olarak ilk defa bu tezde sunulmuş olup, son zamanlarda darbe gürültüsünü yok etmek için sunulan filtrelere iyi bir alternatiftir.

NBCF filtre ile hem düşük hem de yüksek gürültü oranlarında, mükemmel sayısal ve görsel sonuçlar elde edilmiştir. Filtre gürültüyü temizlerken, özellikle kenar bölgelerinin detaylarını da çok iyi şekilde korumuştur. Filtre hiçbir parametre değişikliği yapılmaksızın tüm imgelere başarılı bir şekilde uygulanabilmektedir. Aynı zamanda yöntemin basitliği ve

başarısının yanında bir de dezavantajı bulunmaktadır. Öncelikle imge parçalara ayrılmakta ve bu parçalardan alınan bozulmamış piksellerden bir öğrenme seti oluşturulmaktadır. Bu durum işlem süresini arttırmaktadır.

Sunulan her üç yönteminde genişletilmiş benzetim ve deneysel sonuçlar, önerilen filtrelerin yüksek PSNR çıkış performansı ve düşük MSE değerleriyle literatürde iyi bilinen metotlar kadar gürültüyü bastırdığı ve resmin detaylarını da mükemmel bir şekilde koruduğu görülmüştür.

6.2. Öneriler

Darbe gürültüsünü yok etmek amacıyla, farklı makine öğrenme tekniklerinin birleştirilerek daha etkin algoritmalar geliştirilebilir.

Daha etkin ve hızlı gürültü belirleme metotları geliştirilerek, restorasyon aşaması kolaylaştırılabilir.

Markov Zinciri ve yapay sinir ağları kombinasyonu darbe gürültüsünü etkili biçimde yok edilmesi gerçekleştirilebilir.

Darbe gürültüsünü oluşturan tüm dış etkenlere ait matematiksel bir model geliştirilebilir.

Sunulan yöntemler literatürdeki mevcut filtreler ile birleştirilerek daha iyi sonuçlar elde edilebilir.

Sunulan yöntemler kenar sezme, sınır belirleme, imge bölütleme gibi alanlarda diğer imge işleme uygulamalarına uyarlanabilir.

KAYNAKLAR

- [1] **R. C. Gonzales and R. E. Woods.**, 2002. Digital Image Processing, 2nd ed. Reading, MA: Addison-Wesley, New York.
- [2] **Yüksel Y.**, 2012. Görüntülerdeki Sayısal Dürtü Gürültüsünün Tip-2 Bulanık Mantık Teknikleriyle İyileştirilmesi, *Doktora Tezi*, Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Kayseri.
- [3] **Guo D., Qu X., Du X., Wu K., and Chen X.**, 2014 , Salt and Pepper Noise Removal with Noise Detection and a Patch-Based Sparse Representation, *Advances in Multimedia*, 2014, 14 pages
- [4] **Ibrahim H., Kong N. S. P., and Ng T. F.**, 2008, Simple adaptive median filter for the removal of impulse noise from highly corrupted images, *IEEE Transactions on Consumer Electronics*, **54**, 1920-1927.
- [5] **Chen S., Shi W., and Zhang W.**, 2013, An Efficient Universal Noise Removal Algorithm Combining Spatial Gradient and Impulse Statistic, *Mathematical Problems in Engineering*, 2013, 12 pages.
- [6] **Latifoğlu F.**, 2013, A Novel Approach To Speckle Noise Filtering Based On Artificial Bee Colony Algorithm: An Ultrasound Image Application, *Computer Methods And Programs in Biomedicine*, **111**, 561-569.
- [7] **Ko S.J. and Lee Y.H.**, 1991, Center weighted median filters and their applications to image enhancement, *IEEE Trans. on Circuits and Systems*, **38**, 984-993.
- [8] **Yin L., Yang R., Gabbouj M., Neuvo Y.**, 1996, Weighted median filters: A tutorial, *IEEE Trans. on Circuits and Systems II*, **43**, 157-192.
- [9] **Yıldırım M. T.**, 2007. 2. Tip Bulanık Sistemler ile Sayısal Görüntülerden Dürtü Gürültüsünün Giderilmesi, *Doktora Tezi*, Erciyes Üniversitesi Fen Bilimler Enstitüsü, Kayseri.
- [10] **Wang, Z., Zhang, D.**, 1999, Progressive switching median filter for the removal of Impulse noise from highly corrupted images, *IEEE Transactions on Circuits and Systems II: Analog and Digital Signal Processing*, **46**, 78-80.
- [11] **Chen, T., Wu, H.R.**, 2001, Adaptive impulse detection using center-weighted median filters, *IEEE Signal Processing Letters*, **8**, 1-3.
- [12] **Pok, G., Liu, J.C., Nair, A.S.**, 2003, Selective removal of impulse noise based on homogeneity level information, *IEEE Transactions on Image Processing*, **12**, 85-92.
- [13] **Dong Y., and Xu S.**, 2007, A New Directional Weighted Median Filter for Removal of Random-Valued Impulse Noise, *IEEE Signal Processing Letters*, **14**, 193-196.
- [14] **Xu J., Wang L., Shi Z.**, 2014, A switching weighted vector median filter based on edge detection, *Signal Processing*, **98**, 359-369.
- [15] **Thota S., Rao M.V.G., Kumar P.R.**, 2011, FPGA Implementation of Adaptive Median Filter for the Removal of Impulse Noise, *International Journal of Electronics & Communication Technology*, IJECT 2, 20-24.

- [16] Akkoul S., Ledee R., Leconge R., and Harba R., 2010, A new adaptive switching median filter, *IEEE Signal Process. Letters*, **17**, 587–590.
- [17] Zhang S., and Karim M. A., 2002, A new impulse detector for switching median filters, *IEEE Signal Process. Letters*, **9**, 360–363.
- [18] Ng P.-E., and Ma K.-K., 2006, A switching median filter with boundary discriminative noise detection for extremely corrupted images, *IEEE Trans. Image Process.*, **15**, 1506–1516.
- [19] K. S. Srinivasan and D. Ebenezer, 2007, A new fast and efficient decision based algorithm for removal of high-density impulse noises, *IEEE Signal Process Letters*, **14**, 189-192.
- [20] Madhu N.S., Revathy K., Tatavarti R., 2008. Removal of salt-and- pepper noise in images: A new decision-based algorithm, In:Proceedings of IAENG International Conference on Imaging Engineering ICIE 2008, *IAENG International Multiconference of Engineers and Computer Scientists*, IMECS, 611-616.
- [21] Nair M.S., Raju G., 2012.A new fuzzy-based decision algorithm for high-density impulse noise removal, *Signal, Image and Video Processing*, **6**, 579-595.
- [22] M.E. Yüksel., 2004, A simple neuro-fuzzy impulse detector for efficient blur reduction of impulse noise removal operators for digital images, *IEEE Trans. Fuzzy Syst.*, **12**, 854-865.
- [23] Toprak A., Güler I., 2006, Suppression of Impulse Noise in Medical Images with the Use of Fuzzy Adaptive Median Filter, *J. Medical Systems*, **30**, 465-471.
- [24] Yu H., Zhao L., and Wang H., 2008, An Efficient Procedure for Removing Random-Valued Impulse Noise in Images, *IEEE Signal Processing Letters*, **15**, 922-925.
- [25] Kayhan S. K., 2014, An effective 2-stage method for removing impulse noise in images, *Journal of Visual Communication and Image Representation*, **25**, 478-486.
- [26] Duan F., Zhang Y.J., 2010, A Highly Effective Impulse Noise Detection Algorithm for Switching Median Filters, *IEEE Signal Processing Letters*, **17**, 647-650.
- [27] Lebrun M., Buades A., Morel J. M., 2013, Implementation of the “Non-Local Bayes” (NL-Bayes) Image Denoising Algorithm, *Image Processing On Line*, 1–42.
- [28] Turkmen I., 2013, A new method to remove random-valued impulse noise in images, *AEU - International Journal of Electronics and Communications*, **67**, 771-779.
- [29] Toprak A., Güler İ., 2008, Angiograph image restoration with the use of rule base fuzzy 2D Kalman filter, *Expert Systems with Applications*, **35**, 1752-176.
- [30] Jafar I.F., AlNa'mneh R.A. , Darabkh K.A., 2013, Efficient Improvements on the BDND Filtering Algorithm for the Removal of High-Density Impulse Noise, *IEEE Trans Image Process.*, **22**, 1223-1232
- [31] Besdok E., Civicioglu P. and Alci M., 2004, Impulsive noise suppression from highly corrupted images by using resilient neural networks, *Lecture Notes in Artificial Intelligence*, **3070**, 670-675
- [32] Cai N., Cheng J. and Yang J., 2005, Applying a wavelet neural network to impulse noise removal, *Proc. ICNN&B'05 International Conference on Neural Networks and Brain*, **2**, 781-783.

- [33] **Van De Ville D., Nachtegaal M., Van der Weken D., Kerre E. E., Philips W. And Lemahieu I.**, 2003, Noise reduction by fuzzy image filtering, *IEEE Trans. on Fuzzy Systems*, **11**, 429-436
- [34] **Morillas S., Gregori V., Peris-Fajarne G. and Latorre P.**, 2005, A fast impulsive noise color image filter using fuzzy metrics, *Real-Time Imaging*, **11**, 417-428.
- [35] **Russo F.**, 2000, Noise removal from image data using recursive neurofuzzy filters, *IEEE Trans. on Instrumentation Measurement*, **49**, 307-314.
- [36] **Yuksel, M.E., Bastürk, A., Besdok, E.**, 2004, Detail-preserving restoration of Impulse noise corrupted images by a switching median filter guided by a simple neuro-fuzzy network, *EURASIP Journal on Applied Signal Processing*, **16**, 2451-2461.
- [37] **Windyga P. S.**, 2001, Fast impulsive noise removal, *IEEE Trans. on Image Proc.*, **10**, 173-179.
- [38] **Smolka B., Plataniotis K.N., Chydzinski A., Szczepanski M., Venetsanopoulos A.N. and Wojciechowski K.**, 2002, Self-adaptive algorithm of impulsive noise reduction in color images, *Pattern Recognition*, **35**, 1771-1784.
- [39] **Rahman S.M.M. and Hasan M.K.**, 2003, Wavelet-domain iterative center weighted median filter for image denoising, *Signal Processing*, **83**, 1001-1012.
- [40] **Russo F.**, 2004, Impulse noise cancellation in image data using a two-output nonlinear filter, *Measurement*, **36**, 205-213.
- [41] **Xu H., Zhu G., Peng H. and Wang D.**, 2004, Adaptive fuzzy switching filter for images corrupted by impulse noise, *Pattern Recognition Letters*, **25**, 1657-1663.
- [42] **Alajlan N., Kamela M., Jernigan E.**, 2004, Detail preserving impulsive noise removal, *SignalProcessing: Image Communication*, **19**, 993-1003.
- [43] **Chen T. and Wu H.R.**, 2001, Space variant median filters for the restoration of Impulse noise corrupted images, *IEEE Trans. on Circuits and Systems-II*, **48**, 784-789.
- [44] **Toprak A.**, 2006. Bulanık Adaptif Medyan Filtresi Kullanarak Tıbbi Görüntülerdeki Darbe Gürültüsünün Bastırılması, *Doktora Tezi*, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara
- [45] **Cayırılı M.**, 2006. Yanma Olayının Modellenmesi ve Görüntü İşleme Yoluyla Yanma Performansının Optimizasyonu, *Yüksek Lisans Tezi*, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Isparta
- [46] Internet: Dr. Brian Mac Name online <http://www.comp.dit.ie/bmacnamee/LectureNotes/GraphicsAndImageProcessing/ImageProcessing5SpatialFiltering2>.
- [47] **Anil K. Jain.**, 1989, Fundamentals of Digital Image Processing. Prentice Hall.
- [48] **Bankman, Issac.**, 2000, Handbook of Medical Imaging: Processing and Analysis Management Hardcover, Academic Press.
- [49] **Demir Ö.**, 2006. Matlab Gereçleri ile Görüntü İşleme Uygulamaları, *Yüksek Lisans Tezi*, Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- [50] **Umbugh, S. E.**, 1998, Computer vision and image processing, Prentice Hall Inc., London.

- [51] **Soytürk M.A.**, 2005. Sayısal Kenar Çıkarma ve Yapay Sinir Ağları Yardımıyla Araç Tanıma, *Yüksek Lisans Tezi*, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü.
- [52] **Yüksel, Y., Alçı, M., Yüksel, M.E.**, 2009, Output Enhancement of Impulse Noise Filters by Edge Detection and Neuro-Fuzzy Processing, *New Advances in Intelligent Decision Technologies, Studies in Computational Intelligence*, **199**, 329-339.
- [53] **Abreu, E., Lightstone, M., Mitra, S.K., Arakawa, K.**, 1996, A new efficient approach for the removal of impulse noise from highly corrupted images, *IEEE Transactions on Image Processing*, **5**, 1012–1025.
- [54] **Han, W.Y., Lin, J.C.**, 1997, Minimum–maximum exclusive mean (MMEM) filter to remove impulse noise from highly corrupted images, *IEEE Electronics Letters*, **33**, 124–125.
- [55] **Yüksel, M.E., Baştürk, A.**, 2005, A simple generalized neuro–fuzzy operator for efficient removal of impulse noise from highly corrupted digital images, *AEÜ International Journal of Electronics and Communications*, **59**, 1–7.
- [56] **Pok, G., Liu, J.C., Nair, A.S.**, 2003, Selective removal of impulse noise based on homogeneity level information, *IEEE Transactions on Image Processing*, **12**, 85–92.
- [57] **Russo, F., Ramponi, G.**, 1996, A fuzzy filter for images corrupted by impulse noise, *IEEE Signal Processing Letters*, **6**, 168–170.
- [58] **Umbaugh, S.E.**, 1998, Computer vision and image processing, Prentice Hall Inc., London.
- [59] **Chen, T., Wu, H.R.**, 2001, Space variant median filters for the restoration of impulse noise corrupted images, *IEEE Transactions on Circuits and Systems II: Analog and Digital Signal Processing*, **48**, 784–789.
- [60] **X. Lan, Z. Zuo.**, 2014, Random-valued impulse noise removal by the adaptive switching median detectors and detail-preserving regularization, *Optik - International Journal for Light and Electron Optics*, **125**, 1101-1105.
- [61] **A. Toprak, İ. Güler.**, 2007, Impulse noise reduction in medical images with the use of switch mode fuzzy adaptive median filter, *Digital Signal Processing*, **17**, 711-723.
- [62] **Toprak A.**, 2007, Quantum noise suppression in X-ray images using fuzzy 2-D Wiener filter, *Journal of Medical Systems*, **31**, 351-355
- [63] The USC-SIPI image database, University of Southern California [Online].
- [64] **A. Bovik.**, 2000. Handbook of Image and Video Processing, Academic Press, New York
- [65] **Öztemel E.**, 2003. Yapay Sinir Ağları. Papatya Yayıncılık, İstanbul.
- [66] **Çavuslu, Ali.**, 2006, FPGA ile yapay sinir ağı eğitiminin donanımsal gerçekleştirilmesi, *Lisans Tezi*, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli.
- [67] **C. Deng, H. M. Liu, Z. H. Wang.**, 2010, Applying an improved neural network to impulse noise removal, *Wavelet Analysis and Pattern Recognition (ICWAPR), International Conference on*, 207-210.
- [68] **Yoshimura H., Shimizu T., Matumura T., Kimoto M., & Isu N.**, 2007, Adaptive Noise Reduction Filter for Speech Using Cascaded Sandglass-Type Neural Network,

- In Proceedings of the IEEE International Conference on Robotics and Automation, Italy, 10-14.*
- [69] **Zhang X. P., 2001**, Thresholding Neural Network for Adaptive Noise reduction, *IEEE Transactions on Neural Networks*, **12**, 567-584.
 - [70] **Apalkov I.V., Zvonarev P.S., Khryashchev V.V., 2005**, Neural network adaptive switching median filter for image denoising, *Proceedings of EUROCON*, 22-24.
 - [71] **G. Kaliraj, S. Baskar, 2010**, An efficient approach for the removal of impulse noise from the corrupted image using neural network based impulse detector, *Image and Vision Computing*, **28**, 458-466.
 - [72] **Türkmen İ., 2012**, Removing random-valued impulse noise in images using a neural network detector, *Turkish Journal of Electrical Engineering & Computer Sciences*, **22**, 637-649.
 - [73] The USC-SIPI image database, University of Southern California.
 - [74] **Murat N., 2007**. Model Seçiminde Bayes Yaklaşımlarının Kullanılması, *Yüksek Lisans Tezi*, Ondokuz Mayıs Üniversitesi Fen bilimleri Enstitüsü, Samsun.
 - [75] **Stark H., and Woods J. W., 1994**, Probability, Random Processes, and Estimation Theory for Engineers. Prentice Hall, New Jersey.
 - [76] **KOLMOGOROV, A. N., 1950**. Foundations of the theory of probability, New York.
 - [77] **Yumak B., 2011**. Elektronik Postaların Ayırıştırılmasında Naïve Bayes ve Bulanık Mantık Yöntemlerinin Karşılaştırılması, *Yüksek Lisans Tezi*, Gazi Üniversitesi Fen bilimleri Enstitüsü, Ankara.
 - [78] **Kılıç. B. S., 2011**. Bayes ağları kullanarak medikal transtorasik ekokardiyografi verilerinin işlenmesi ve teşhis yazılımı geliştirilmesi, *Yüksek Lisans Tezi*, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü, Denizli.
 - [79] **Xiang, Y., Pant, B., Eisen, A., Beddoes, M.P. and Poole D., 1991**: PAINULIM: A Neuromuscular Diagnostic Aid Using Multiply Sectioned Bayesian Networks, *Proc. of the ISMM International Conference on Mini and Microcomputers in Medicine and Healthcare*, 64-69.
 - [80] **Yılmaz, R., 2002**. Jeffreys'in önseli kullanılarak geliştirilmiş lineer modellerde Bayes analizi ve bir uygulama, *Yüksek Lisans Tezi*, Ondokuz Mayıs Üniversitesi, Samsun.
 - [81] **Domingos P., Pazzani M., 1997**, On the Optimality of the Simple Bayesian Classifier under Zero-One Loss, *Machine Learning*, **29**, 103-130.
 - [82] **Gürsakal N., 1992** , Bayesci İstatistik, Uludag Üniversitesi Basımevi, Bursa.
 - [83] **Zdziarski, Jonathan, A., 2005**, Ending Spam: Bayesian Content Filtering and the Art of Statistical Language Classification, *No Starch Pres Inc.*, 10.
 - [84] **Can, A., 2008**, Bayesçi Kestirim Teknikleri İle Hedef Takibi, *Doktora Tezi*, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
 - [85] **Çevik, M., 2009**. Doğrusal Olmayan Bayesçi Regresyon ve Yüksek Frekanslı Ses Sistemlerinde Bir Uygulama, *Doktora Tezi*, , Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

- [86] **Ekici, O.**, 2005. Bayesyen Regresyon ve WinBUGS İle Bir Uygulama, *Yüksek Lisans Tezi*, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- [87] **Olmuş, H.**, 2007. Bayes Ağlar ve Markov Ağları Kullanan Kümeleme Yönteminin İncelenmesi ve Bir Uygulama, *Doktora Tezi*, Gazi Üniversitesi Fen Bilimleri Enstitüsü,
- [88] **Türkoğlu F.**, 2006. Melez Yaklaşımlarla Türkçe Dokümanlarda Yazar Tanıma, *Yüksek Lisans Tezi*, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

ÖZGEÇMİŞ

Yazar 1977 Yılında Diyarbakır'ın Bismil İlçesinde doğdu. 1988 yılında Bismil Atatürk İlkokulundan, 1991 yılında Bismil Ortaokulundan, 1994 Bismil Lisesinden mezun oldu.

1994 yılında girdiği Dicle Üniversitesi, Mühendislik-Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliğini bölümünden 1998 yılında mezun oldu. 1998-1999 tarihleri arasında TEDAŞ'a ait orta gerilim bakım-onarım ve yeni tesis yapımı üzerine bir yıl çalıştı. 1999 yılında Dicle Üniversitesi Şırnak Meslek Yüksekokulunda okutman olarak göreve başladı aynı yerde 2007 yılına kadar çalıştı. 2006-2008 Yılları arasında Dicle Üniversitesi, Fen bilimleri enstitüsü, Elektrik- Elektronik Mühendisliği anabilim dalında yüksek lisansını tamamladı. 2009 yılında Fırat Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Telekomünikasyon Anabilim Dalında doktora eğitimine başladı. 2007 yılında Batman Üniversitesi Meslek Yüksekokulu Elektrik Programında Öğretim Görevlisi olarak göreve başladı. Halen aynı göreve devam etmektedir. Evli ve üç çocuk babasıdır.

Elektronik Posta: cafer.budak@batman.edu.tr