

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**DENETİMSİZ DERİN ÖĞRENME KULLANILARAK DİJİTAL MEME
TOMOSENTEZİ GÖRÜNTÜLERİNDE GÜRÜLTÜNÜN GİDERİLMESİ**

YÜKSEK LİSANS TEZİ

Osman Alpcan ÖZCAN

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği Programı

EYLÜL 2023

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**DENETİMSİZ DERİN ÖĞRENME KULLANILARAK DİJİTAL MEME
TOMOSENTEZİ GÖRÜNTÜLERİNDE GÜRÜLTÜNÜN GİDERİLMESİ**

YÜKSEK LİSANS TEZİ

**Osman Alpcan ÖZCAN
(504201415)**

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği Programı

Tez Danışmanı: Doç. Dr. İsa YILDIRIM

EYLÜL 2023

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**UNSUPERVISED DENOISING OF DIGITAL BREAST TOMOSYNTHESIS
IMAGES USING DEEP LEARNING**



M.Sc. THESIS

**Osman Alpcan ÖZCAN
(504201415)**

Department of Electronics and Communication Engineering

Biomedical Engineering Programme

Thesis Advisor: Assoc. Prof. Dr. İsa YILDIRIM

SEPTEMBER 2023

İstanbul Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü'nün 504201415 numaralı Yüksek Lisans Öğrencisi Osman Alpcan ÖZCAN, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “DENETİMSİZ DERİN ÖĞRENME KULLANILARAK DİJİTAL MEME TOMOSENTEZİ GÖRÜNTÜLERİNDE GÜRÜLTÜNÜN GİDERİLMESİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı: **Doç. Dr. İsa YILDIRIM**

İstanbul Teknik Üniversitesi

Jüri Üyeleri: **Prof. Dr. Ender Mete EKŞİOĞLU**

İstanbul Teknik Üniversitesi

Dr. Metin ERTAŞ

Türk Hava Yolları

Teslim Tarihi : 18 Eylül 2023
Savunma Tarihi : 25 Eylül 2023





Aileme,



ÖNSÖZ

Bu tez; İstanbul Teknik Üniversitesi, Elektronik ve Haberleşme Mühendisliği Anabilim Dalı, Biyomedikal Mühendisliği Programı kapsamında yüksek lisans derecesi edinmek amacıyla yazılmıştır. Bu çalışma ile dijital meme tomosentezi görüntüleri üzerindeki gürültülerin denetimsiz derin öğrenme ağı ile giderilmesi için yeni bir yöntem önerilmiştir. Denetimsiz derin öğrenme ağlarının medikal görüntülerin gürültülerinin giderilmesi ve iyileştirilmesi üzerine taşıdığı potansiyel ortaya konulmak istenmiştir.

Bu çalışma sırasında her koşulda desteğini hissettiğim değerli danışmanım Doç. Dr. İsa YILDIRIM hocama, görüş ve önerileri ile her zaman bilgi üretimi konusunda desteğini esirgemeyen sayın Dr. Metin ERTAŞ hocama, lisans hayatım boyunca ve yüksek lisans ders ve tez döneminde çalışmalarımızı birlikte yürüttüğümüz, beraber öğrenmenin kıymetini her daim hissettiren kadim dostum Müberra Aydın'a teşekkürü borç bilirim.

EYLÜL 2023

Osman Alpcan ÖZCAN
(Biyomedikal Mühendisi)

İÇİNDEKİLER

ÖNSÖZ	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SEMBOLLER	xv
ÇİZELGE LİSTESİ	xvii
ŞEKİL LİSTESİ	xix
ÖZET	xxi
SUMMARY	xxiii
1.GİRİŞ	1
1.1 Meme Kanseri	1
1.2 Memenin Görüntüleme Yöntemleri	2
1.2.1 Mamografi.....	2
1.2.2 Ultrasonografi	2
1.2.3 Dijital meme tomosentezi	3
1.3 Problem Tanımlaması	3
1.4 Literatür Taraması	4
1.5 Katkı	7
2. YÖNTEM	9
2.1 Matematiksel Yöntemler ile Gürültünün Giderilmesi.....	9
2.2 Denetimsiz Derin Öğrenme Ağı ile Gürültünün Giderilmesi.....	10
3. DENEY	15
3.1 Deneysel Veriler.....	15
3.2 Karşılaştırma Yöntemi	15
3.3 Ağ Mimarisi ve Eğitim Süreçleri	16
3.4 Sonuçlar.....	16
4. TARTIŞMA	27
5. KAPANIŞ	29
KAYNAKÇA	31
ÖZGEÇMİŞ	35



KISALTMALAR

2D	: İki Boyutlu
3D	: Üç Boyutlu
AlexNet	: Krizhevsky ve arkadaşları tarafından tasarlanan yapay sinir ağı
BM3D	: Blok Eşlemeli Üç Boyutlu Filtreleme(Block Matching 3Dimensions)
BOI	: Görüntü Arka Planı (Background Of Image)
BSC-DBT	: Meme Kanser Görüntüleme- Dijital Meme Tomosentezi
CGAN	: Koşullu Üretken Çekişmeli Ağlar
CNN	: Evrişimli Sinir Ağı (Convolutional Neural Network)
CNR	: Kontrast Gürültü Oranı (Contrast Noise Ratio)
CPU	: Merkez İşlem Birimi (Central Process Unit)
DBT	: Dijital Meme Tomosentezi (Digital Breast Tomosynthesis)
DCNN	: Derin Evrişimli Sinir Ağı (Deep Convolutional Neural Network)
ECDNet	: Tian ve arkadaşları tarafından tasarlanan yapay sinir ağı
FFDNet	: Zhang ve arkadaşları tarafından tasarlanan yapay sinir ağı
GPU	: Grafik İşlem Birimi (Graphic Process Unit)
Ne2Ne	: Huang ve arkadaşları tarafından tasarlanan yapay sinir ağı
Noise2Noise	: Lethinen ve arkadaşları tarafından tasarlanan yapay sinir ağı
Noise2Self	: Batson ve arkadaşları tarafından tasarlanan yapay sinir ağı
Noise2Void	: Krull ve arkadaşları tarafından tasarlanan yapay sinir ağı
NLM	: Yerel Olmayan Ortalama (Non-Local Mean)
PSNR	: Tepe Sinyal Gürültü Oranı (Peak Signal Noise Ration)
ROI	: İlgilenilen Bölge (Region Of Interest)
ReLU	: Nair ve arkadaşları tarafından tasarlanan yapay sinir ağı
RGB	: Renkli Görüntü – Kırmızı Yeşil Mavi (Red-Green-Blue)
SSIM	: Yapısal Benzerlik İndeksi (Structural Similarity Index)
TV	: Toplam Değişim (Total Variation)



SEMBOLLER

σ	: Standart Sapma
λ	: Ortalama Piksel Deęeri
$G(x, y)$: Görüntü
$I(x, y)$: Orijinal Görüntü
$\eta(x, y)$: Gürültü
$P(i, j)$: Bölüklenmiş Piksel Adresi
γ	: Düzenleştirme Parametresi
\mathcal{L}	: Kayıp Fonksiyonu
\mathcal{L}_{reg}	: Kayıp Fonksiyonu Regresyon Bölümü
\mathcal{L}_{rec}	: Kayıp Fonksiyonu Yeniden Yapılandırma Bölümü



ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1: Her iki veri seti ile yapılan eğitim sonucu matematiksel yöntem ile yapay sinir ağının gürültü parametrelerine göre temizleme yeteneğinin metrikler üzerinden karşılaştırma çizelgesi.	17
Çizelge 3.2: Her iki veri seti ile yapılan eğitim sonucu matematiksel yöntem ile yapay sinir ağının gürültü parametrelerine göre temizleme yeteneğinin CNR değeri üzerinden karşılaştırma çizelgesi.	17
Çizelge 3.3: Her iki veri seti ile eğitim sonucu matematiksel yöntem ile yapay sinir ağının gaussian gürültüsünü temizleme yeteneğinin metrikler üzerinden karşılaştırma tablosu.	22
Çizelge 3.4: Her iki veri seti ile eğitim sonucu matematiksel yöntem ile yapay sinir ağının Poisson gürültüsünü temizleme yeteneğinin metrikler üzerinden karşılaştırma tablosu.	22



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1: BM3D Basitleştirilmiş gruplama görseli [10].....	10
Şekil 2.2: Ağ yapısı.	13
Şekil 3.1: BSC-DBT data seti ile eğitilmiş denetimsiz gürültü giderici sinir ağının (Ne2Ne) etkisinin görsel üzerinde karşılaştırılması.	18
Şekil 3.2: 2D Phantom veri seti ile BM3D matematiksel yöntemin gürültü giderme etkisinin görsel üzerinde karşılaştırılması.	20
Şekil 3.3: BSC-DBT veri seti ile BM3D matematiksel yöntem ile denetimsiz sinir ağının (Ne2Ne) gürültü giderme etkisinin görsel üzerinde karşılaştırılması.	21
Şekil 3.4: 2D Phantom veri seti ile BM3D matematiksel yöntem ile denetimsiz sinir ağının (Ne2Ne) gürültü giderme etkisinin görsel üzerinde karşılaştırılması.	21
Şekil 3.5: Her iki veri seti ile eğitim sonucu matematiksel yöntem ile yapay sinir ağının gaussian gürültüsünü temizleme yeteneğinin metrikler üzerinden karşılaştırma grafiği.	24
Şekil 3.6: Her iki veri seti ile eğitim sonucu matematiksel yöntem ile yapay sinir ağının poisson gürültüsünü temizleme yeteneğinin metrikler üzerinden karşılaştırma grafiği.	24



DENETİMSİZ DERİN ÖĞRENME KULLANILARAK DİJİTAL MEME TOMOSENTEZİ GÖRÜNTÜLERİNDE GÜRÜLTÜNÜN GİDERİLMESİ

ÖZET

Meme kanseri, kadınlarda en yaygın kanser türüdür ve genellikle süt bezi dokusu hücrelerinin kontrolsüz ve aşırı çoğalması sonucu ortaya çıkar. Erken aşamada teşhis edilmezse ölümcül hale gelebilir. Erken aşama teşhisinde en çok tercih edilen görüntüleme yöntemi olan mamografi, 2 boyutlu (2D) bir görüntüleme yöntemidir. 2D yöntemler doğaları gereği bir projeksiyondan görüntü oluştururlar ve bu, dokuların üst üste binmesi nedeniyle yanlış pozitif ve yanlış negatif oranlarının artmasına yol açar; bu oranın artması da ölüm oranlarını artırır.

Bu durumu önlemek için 3D görüntüleme yöntemleri önerilmiş ve kullanımları artmıştır. Dijital meme tomosentezi (DBT), 3 boyutlu (3D) bir görüntüleme yöntemi olarak tercih edilir. DBT, sınırlı açılarda alınan projeksiyonlarla birlikte 3D bir görüntü oluşturur ve düşük radyasyon dozlarıyla çalışır. 2D görüntüleme de oluşan dokuların üst üste binmesi sorunu aşılmış ve böylece dokular daha ayırt edilebilir hale gelmiş ve radyologların erken teşhis oranları artmıştır. Ancak, DBT görüntülerinde sınırlı açı ve düşük radyasyon dozu nedeniyle her projeksiyonun gürültü içereceği ve gürültünün rekonstrüksiyon görüntüsünde artmış şekilde görüneceği kaçınılmazdır. Gürültü giderimi için birçok matematiksel yöntem önerilmiş ve belirli bir ölçüde başarılı oldukları gözlemlenmiştir, ancak hala tatmin edici bir performans sağlama konusunda eksiklikleri vardır.

Yapay zekâ ve derin öğrenme ağlarının gelişimi ve yaygınlaşmasıyla birlikte, tıbbi görüntü işleme alanında kullanımı da artmıştır. Bu bağlamda, derin öğrenme ağları, tıbbi görüntülerde bir gürültü giderici olarak mekânsal düzenleyicilere alternatif olarak önerilmiştir. Bu çalışmada, bir denetimsiz gürültü giderici sinir ağı, DBT görüntüleri üzerinden gürültüleri ortadan kaldırmak için geliştirilmiştir. Önerilen yöntemin performansını analiz etmek için iki farklı veri seti kullanılmıştır. İlk veri seti kanser görüntü arşivinden BSC-DBT (Meme Kanseri Taraması- Dijital Meme Tomosentezi) veri setidir. Bu veri seti, normal, aksiyon alınması gereken, biyopsi ile kanıtlanmış iyi huylu ve biyopsi ile kanıtlanmış kanser olarak etiketlenmiş 5060 hasta içermektedir. Görüntüler dilimler halinde 2 boyutlu olarak kullanılmıştır. Her kategoriden eşit ve toplam verilerin %70 eğitim verisi, %15 validasyon verisi ve %15 test verisi olacak şekilde belirlenmiştir. Bu veri setine ek olarak DBT-2D Phantom veri seti kullanılmıştır. Toplamda 2148 veri ve yine görüntüler iki boyutlu dilim görüntüsü olacak şekilde veri setinin %70'i eğitim verisi %15'i validasyon verisi ve %15 test verisi olarak organize edilmiştir. Düşük doz ve dar açı kaynaklı en belirgin gürültü şekilleri Gaussian ve Poisson gürültüleri olması sebebiyle gürültü giderici hedefi bu iki gürültü olarak belirlenmiş ve eğitim parametreleri bu gürültülerin giderilmesi üzerine belirlenerek eğitim tamamlanmıştır.

Önerilen modelin başarısını deęerlendirmek için CNR (kontrast-gürültü oranı), PSNR (zirve sinyal gürültü oranı) ve SSIM (yapısal benzerlik indeksi) metrikleri kullanılmıştır. Çalışma sırasında matematiksel yöntemler ile önerilen modelin başarısı metrikler üzerinde kıyaslanmış ve çalışmanın sonucunda önerilen denetimsiz gürültü giderici ağ ile belirlenen metriklerdeki iyileşmenin daha üstün olduğu gözlemlenmiştir. Görüntülerdeki niteliksel iyileşme, önerilen modelinin oldukça umut verici olduğunu göstermektedir.



UNSUPERVISED DENOISING OF DIGITAL BREAST TOMOSYNTHESIS IMAGES USING DEEP LEARNING

SUMMARY

Breast Cancer is the most common type of cancer in women, usually caused by the uncontrolled and excessive proliferation of glandular tissue cells. It becomes fatal if not diagnosed at an early stage. Before the age of 40, doctors recommend regular manual examinations. After the 40s, imaging methods are added at regular intervals for these examinations. Mammography, a 2-dimensional (2D) imaging method, is the most preferred imaging modality in early-stage diagnosis. By their nature, 2D methods create an image on a projection, and this increases the rate of false positive and false negative rates due to overlapping of tissues. This increased rate often means delayed or incorrect treatment and consequently increases mortality rates.

Ultrasonography has been proposed to prevent this situation. Ultrasonography is used as an additional imaging method to distinguish dense and overlapping tissues on mammography. This means an increase in cost and workload. For this reason, 3D imaging modalities have been proposed and their use has increased in order to perform imaging more effectively, in a shorter time and at a lower cost. Digital breast tomosynthesis (DBT) is preferred as a 3-dimensional (3D) imaging method. DBT creates a 3D image with a limited number of projections at wide angles and low radiation doses. The problem of overlapping of the tissues formed in 2D imaging has been overcome, thus the dense tissues have become more distinguishable and the early detection rates of radiologists have been increased. However, in DBT images, due to the limited number of projections and low radiation dose, it is inevitable that each projection will contain noise and that the noise will appear amplified in the reconstructed image. Although many mathematical methods have been proposed for noise removal and have been observed to be successful to some extent, they still lack of providing satisfactory performance.

With the development and popularization of artificial intelligence and deep learning networks, its use in the field of medical image processing has also increased. In this context, deep learning networks have been proposed as an alternative to mathematical regularizers as a denoiser in medical images. Deep learning networks perform their operations by establishing connections between the given task and the ground truths targeted during learning activities. For this reason, they need ground truths. However, ground truths are difficult parameters to obtain in many real-world problems. To overcome this difficulty, unsupervised network models have been proposed. There are different approaches as learning models for unsupervised network models. One of them aims to learn by benchmarking over different variations of a given task. Another one is the blind spot network structure. This structure aims to generate artificial variations based on a single input and to form the target with the data it diversifies. There are certain limitations for both approaches. The first one is that it is difficult to

capture the same scene with different parameters, such as medical imaging and motion imaging, while the difficulty for the other method is the low success rate. Therefore, in order to provide a solution based on the first approach, this study aims to obtain an unsupervised denoising neural network that aims to remove noise from DBT images based on a network that has proven itself in removing noise from real-world images.

As a solution to the need to recapture a scene with different parameters, the proposed method aims to obtain image pairs through sub-sampling sets from the scene and use these pairs as training input. Thus, noise removal can be performed on a single noisy image. Two different datasets are used to analyse the performance of the proposed method. The first dataset is the BSC-DBT (Breast Cancer Screening - Digital Breast Tomosynthesis) dataset from the cancer image archive. This dataset contains 5060 patients labelled as normal, action required, biopsy proven benign and biopsy proven cancer. Images were used in slices in 2D. To be equal from each category and total data was determined to be 70% training data, 15% validation data and 15% test data. In addition to this dataset, DBT-Phantoms dataset was used. The dataset was organized as 70% training data, 15% validation data and 15% test data, with a total of 2148 data and two-dimensional slice images. Since Gaussian and Poisson noises are the most prominent noise shapes due to low dose, these two noises were chosen as the noise removal targets and the training was completed by setting the training parameters to remove these noises. The basic parameter of Gaussian noise is the standard deviation of the region of interest (ROI). For this reason, to calculate the standard deviation of the ROI over the images, a 10% of the data set was randomly selected from the entire data set by sampling method. The standard deviations of the selected data were calculated and averaged. At the same time, the standard deviation of the averaged standard deviation data was calculated. Thus, a stable data with a mean of 25.3 standard deviations and a standard deviation of 1.19 was obtained and the training parameter σ (standard deviation) was set to 25. The basic parameter for Poisson noise is λ , which is the average of the pixel values of the region of interest. With the method applied for Gaussian, λ was determined for Poisson noise and the average λ value was 30.8 with a standard deviation of 1.27. For this reason, it was applied as 30 in the training data. In order to make the comparison fair and to simulate real-world problems well, in addition to the fixed value training, a training set with a normal distribution of noise levels was also created. For this training set, the parameters used in the constant value training were set so that the peak point was set to be the parameters used in the constant value training and they were distributed between 5 and 50 values. Thus, when comparisons were made, tables were created based on constant value constant noise, constant value distributed noise, distributed value constant noise and distributed value distributed noise values.

Contrast-to-noise ratio (CNR), peak signal to noise ratio (PSNR) and structural similarity index (SSIM) metrics were used to evaluate the success of the proposed model. While SSIM is preferred because it allows the closest digital comparison to human perception, CNR is preferred because of the high importance of contrast resolution in medical images. PSNR is a good visual signal analysis method. The parameter values for the metrics were analysed based on the average sigma and lambda values as mentioned. During the study, the success of the mathematical regularizer method Block-matched three-dimensional filtering (BM3D) and the proposed model was compared on the metrics. The comparison was made by training the network with both fixed noise parameters and parameters varying over a normal distribution. In

addition, the performance of the network trained with fixed parameters and sigma and lambda values that the training data is normally distributed and BM3D is tested for varying noise conditions.

As a result of the study, the proposed unsupervised denoiser network was found to be superior to the BM3D mathematical regularizers method with the metrics determined. Considering the data acquisition costs and processing capabilities, the proposed model is quite promising.





1.GİRİŞ

Sahip olunan en değerli varlık sağlıktır. İnsanlık olarak bu varlığı korumak tarihin ilk gününden beri önemli bir gündemdir. Gelişen ve değişen dünyada insan nüfusunun artışıyla beraber hastalıklar da artmış, bu durum insan sağlığını ve varlığını tehdit eder hale gelmiştir. Kanser bu tehditlerin en büyüğüdür. Kanser, bir hücrenin kontrolsüz ve sınırsız bölünmesi ile çoğalan, doğal süreçte ömrünü tamamlayan hücrelerin kendini yıkımı özelliğinden noksan olan aşırı gelişen doku olarak tanımlanır. Kanser, öncelikle oluştuğu bölgede ikamet eder ve daha sonra metastaz olarak isimlendirilen kan dolaşımı ve lenf dolaşımı aracılığı başka dokulara taşınımı ile diğer sistemlere nüfuz ederek nüfuz ettiği sistemi sekteye uğratar, ölümcül bir hastalıktır. Kanser oluştuğu bölgelere göre isimlendirilir, en yaygın türler; tiroit kanseri, kolon kanseri, akciğer kanseri, lenf kanseri, pankreas kanser ve meme kanseridir.

1.1 Meme Kanseri

Meme cinsiyet fark etmeksizin her insanda bulunan bir salgı bezi organıdır. Genellikle kadınlarda daha belirgin şekilde gelişir ve temel işlevi analık sırasında süt üretimidir. Memenin anatomik yapısı; bezler, kan damarları, lenf damarları, sinir lifleri ve bağ dokudan oluşur. Meme anatomik olarak göğüs kaslarının üzerinde yer alır ve areola adı verilen renkli bir kısma sahiptir [1]. Bu kısım meme başını da içerir ve bu kompleks yapıya nipple-areola adı verilir. Bu bölge süt kanallarının dışa açıldığı bölgedir. Memenin iç yapısında lob ve lobul denilen süt bezi yapılar mevcuttur, bunlar bir yağ doku ile çevrelenmiştir ve süt kanalları ile meme başına bağlıdır. Meme kanserinin, genetik yatkınlık, hormon seviyeleri, cinsiyet, yaş obezite, hormonal tedavi, yaşam tarzı ve radyasyon maruziyeti gibi çeşitli faktörler sonucu yoğun damarlanma sayesinde doku beslenmesinin kuvvetli olduğu süt bezlerinde görülme riski fazladır. Bu sebeple, özellikle kadınlarda yaygın görünen bir kanser türüdür. Ulusal Kanser Enstitüsü verilerine göre sekiz kadından biri hayatlarının bir döneminde meme kanserine yakalanmaktadır [2]. Bu durum, Türkiye Halk Sağlığı kurumuna göre de benzerlik göstererek her sekiz Türk kadınından biri meme kanserine yakalanmaktadır. Türk kadınlarının en sık yakalandığı ve ölüm oranı en yüksek olan kanser türüdür [3].

Meme kanseri, erken teşhisinde tedavi oranı yüksek bir kanser türü olsa da memeyi çevreleyen lenf ve damar yapılanması sebebiyle metastaz riskinin yüksek olduğu bir bölgedir. Bu yüzden riski yüksek grupta yer almaktadır [3]. Meme kanseri genellikle fark edilebilir semptomlar üretmezler, bu sebeple düzenli olarak fiziksel muayene ve görüntüleme metotları ile kontrol gerektirir [4]. Düzenli fiziksel muayene ve bu muayenelere ek görüntüleme yöntemleri ile erken teşhis oranı ve kurtulma yüzdesi oldukça yüksektir.

1.2 Memenin Görüntüleme Yöntemleri

Meme kanserinin belirgin semptomlarının bulunmaması sebebiyle erken teşhisinde ve takibinde meme görüntüleme ve tarama yöntemlerinin kullanılması önem arz etmektedir. Yaygın olarak kullanılan yöntemler şu şekildedir:

1.2.1 Mamografi

Meme kanseri erken teşhisi için altın standart kabul edilen ve en yaygın kullanılan yöntemdir [4]. Mamografi, düşük dozda x ışınları kullanılarak meme dokusunun tek bir izdüşüm görüntüsünü oluşturur. Bu görüntüler anormal doku veya tümörlerin görüntülenmesine yardımcı olur. Mamografi radyasyon maruziyeti içeren bir görüntüleme yöntemi olması ve meme dokusu hassas, hücre üretiminin yoğun olduğu bir bölge olması sebebiyle genellikle hücre üreme hızlarının yavaşlamaya başladığı 40'lı yaşından sonra kullanımı tavsiye edilir. Nadiren daha genç yaşlar için de kısıtlı kullanımı söz konusudur. Mamografi görüntülerinde tek bir izdüşüm görüntüsü oluşması birbirinden bağımsız bölgelerde bulunan dokuların görüntü üzerinde birbirleri üzerine gelmesi sebebiyle çoğunlukla yaşanan problem yanlış pozitif ya da yanlış negatif teşhislere yol açmasıdır. Bu problem sebebiyle mamografinin hassasiyeti %50-80 aralığındadır [5]. Bu gibi durumlar için farklı metotlardan yardım alınarak görüntüleme tekrarlanır, bu da hem zaman kaybına hem de maliyetin artmasına sebep olur.

1.2.2 Ultrasonografi

Ultrason, yüksek frekanslı ses dalgaları kullanılarak meme dokusunun görüntüsünün oluşturulmasını sağlar. Meme dokusunun yoğun olduğu hastalar için kullanımı önerilir. Yoğun meme dokusu mamografi gibi tek izdüşüm üzerinden görüntü oluşturma prensibine dayalı görüntüleme metotları için bir engeldir. Bu sebeple

ultrason yoğun meme dokusu görüntülenmesinde ve mamografideki anormal görüntü içeriği tespitinde tercih edilir. Ultrasonografi meme görüntülemesinde doğrudan görüntüleme aracı olmaktan ziyade destekleyici bir görüntüleme metodu olarak karşımıza çıkmaktadır.

1.2.3 Dijital meme tomosentezi

Dijital Meme Tomosentezi, düşük radyasyon dozu, geniş açılı ve az sayıda projeksiyon ile oluşan görüntünün geri çatılması sonucu 3 boyutlu görüntülerin eldesi ile meme görüntülemesi yapılan gelişmiş bir Mamografi cihazıdır [6]. Ultrason ve geleneksel Mamografi ile kıyaslandığı zaman DBT birçok avantaja sahiptir. Üç boyutlu görüntü oluşturması sebebiyle meme dokusunu daha ayrıntılı şekilde değerlendirme imkânı tanır. Bu sayede daha küçük kalsifikasyon denilen başlangıç seviyesi anormalitelerin saptanması kolay hale gelir. Tek projeksiyon ile oluşan görüntülerde dokuların üst üste binmesiyle teşhisin zorlaşmasının aksine anormalite oluşan bölgenin lokasyonu 3 boyutlu görüntüleme sayesinde daha doğru şekilde tespit edilir. Dijital meme tomosentezi üç boyutlu görüntüleme imkânı tanınmasına karşın hasta güvenliği açısından alınan radyasyon dozunu azaltmak amacıyla belirlenen teknik kısıtlamalar sebebiyle elde edilen görüntüler oldukça tatmin edici olsa da görüntü barındırmaktadır.

1.3 Problem Tanımlaması

Erken teşhiste kullanılan mamografinin yoğun doku görüntüleme problemleri ultrason ile, ultrasonda iki boyutlu düşük çözünürlüklü görüntüler, üç boyutlu ve yüksek çözünürlüklü dijital meme tomosentezi görüntüleri ile çözüme kavuşturulmuştur. Lakin modalitelerin birbirilerine karşı belirli konularda üstün özellikleri ve dijital meme tomosentezinin diğer metotlara karşı üstünlüğü ispatlanmış olsa da hiçbir sistem görüntü ve artefaktlar için bağışık olmadığı gibi DBT görüntüleri de bağışık değildir. Gürültüler çevresel faktörler, düşük radyasyon dozları, hasta hareketleri ve teknik sınırlamalar gibi birçok sebeple oluşabilirler. Eğer bir görüntünün üzerindeki görüntüyü matematiksel olarak ifade etmek istersek denklemimiz denklem 1.1'de olduğu gibi ifade etmemiz gerekir. Böylece görüntünün görüntü üzerindeki görüntüyü ve bu görüntünün görüntü üzerindeki etkisini incelemek daha kolay hale gelecektir.

$$G(x,y)=I(x,y)+ \eta(x,y) \quad (1.1)$$

Denklem 1.1’de $G(x,y)$ gürültülü görüntüyü temsil ederken, $I(x,y)$ orijinal görüntüyü, $\eta(x,y)$ ise gürültüyü ifade eder. Denklemdaki gürültü değişkeninin türü görüntünün elde edildiği modaliteye bağlı olmakla birlikte dağılımını ve miktarını kestirmek oldukça güçtür. X ışını kullanılan modaliteler ile elde edilen görüntülere ait denklem gürültü parametresinin temel dağılımı beyaz gauss gürültüsü ve poisson gürültüsü olduğu bilinmektedir [7]. Bu sebeple gürültü perspektifimizi daha spesifik bir noktaya çekecek olursak bu iki dağılım üzerinde gürültü parametresinin egale edilmesi üzerine çalışmalar yoğunlaştırılmış ve matematiksel çözümler ortaya konulmuştur. Lakin gürültülerin değişkenlik gösteren parametreleri sebebiyle matematiksel çözümler kısıtlı kalmıştır ve gelişime muhtaçtır. Gelişen teknoloji ile yapay zekâ hayatımıza girmiş ve birçok alanda çığır açan yeni fırsatlar ortaya koymuştur. Yapay zekanın alt kümesi olan derin öğrenme insan beyninin fonksiyonları ve yapısının taklit edilmesiyle problemlere çözüm oluşturabilen ağlardır. Bu ağların dünya üzerindeki birçok probleme uyarlanarak çözüm ortaya koyabileceğine dair çok sayıda çalışma yapılmıştır. Medikal görüntüleme ve görüntü işleme de bunlardan bir tanesidir. Sayısal ve matematiksel çözümlerin yetersiz kaldığı gürültü giderilmesi amacıyla derin öğrenme ağlarının kullanılabilmesi aşıkardır.

1.4 Literatür Taraması

Görüntüler üzerindeki gürültülerin temizlenmesi amacıyla birçok gürültü giderici algoritma önerilmiştir. Toplam değişim gürültü giderici (TV) algoritması bunlardan bir tanesidir [8]. TV matematiksel bir gürültü giderici olarak önerilmiştir ve seçilen bir değer ile orijinal görüntü değeri arasındaki toplam değişimin minimize edilmesi üzerine kurgulanmıştır. Görüntü üzerindeki kenar bilgileri ve yapılar minimum düzeyde zarar vermemesi sebebiyle tercih edilmektedir. Bir başka gürültü giderici algoritma Non-Local Means (NLM)’dir [9]. Bu yöntem temelde bir filtre olsa da matematiksel bir yöntem gibi kullanıma elverişlidir. Görüntü üzerindeki pikselin gürültüsünü azaltmak için pikselin çevresindeki benzer bölgelerin bilgisinden faydalanarak piksel değeri tahmin edilir. Bir benzer şekilde matematiksel gürültü giderme yöntemi olarak Blok eşleme (BM3D) kullanılabilir [10]. BM3D piksellerin gruplanması ile gürültünün azaltılmasını hedefleyen bir düzenleyicidir. Bu yöntemde pikseller ile 3 boyutlu bloklar oluşturulur ve benzer bloklar birbiri ile eşlenerek, hedef pikselin değeri tahmin edilmeye çalışılır. İteratif yöntemler kuvvetli

gürültü düzenleyici ve gidericiler olsalar da işlem yükleri ağır, birçok parametreye bağımlı ve maliyetli yöntemlerdir. İnsanoğlunun nano boyutlarda işlem yapabilme yeteneğinin gelişmesiyle teknoloji için en önemli icatlardan olan bilgisayarların işlem güçleri katlanarak artmıştır. Bu artışın akabinde gelişen bilgi üretme ve bilgiye ulaşım hızı sayesinde büyük veriler elde edilebilir olmuş, büyük verilerin eldesi, bu verilerin yapay sinir ağlarını besleyerek gelişmesine ve yinelemeli yöntemlere alternatif yöntemler haline gelmesine vesile olmuştur. Yapay zekalar görüntü işleme konusunda oldukça başarılıdır, örneğin; Evrişimli Sinir Ağları (CNN) aktif olarak kullanılan ve temel doğru tabanı ile temiz görüntüler ile gürültülü görüntüler arasındaki ilişkiyi baz alarak öğrenen ve gürültü temizleme konusunda oldukça etkili yöntemlerdir [11-14]. Bunlardan birine yakından bakacak olursak eğer, Krizhevsky ve arkadaşlarının geliştirmiş olduğu CNN tabanlı AlexNet ağı grafik işlem birimi üzerinden eğitimleri gerçekleştirmeyi amaçlamış, aşırı uyum sorunlarını rastgele kırpma metodu ile veri artırarak çözmüş ve sigmoid yerine ReLU[15] kullanarak değişken eğim hızını iyileştirmişlerdir[16]. Zhang ve arkadaşları, bir başka CNN ağı olan FFDNet'i geliştirmişlerdir [17]. FFDNet, BM3D ile kıyasla oldukça hızlı GPU ve CPU sonucu veren güçlü bir ağıdır. Genel olarak gürültü haritası ve gürültülü görüntüleri baz alarak çalışan bu ağ tek bir model ile birden fazla gürültünün giderilmesi konusunda iddialıdır. Bir diğer öneri olarak, Elhoseny ve arkadaşları CNN ağları üzerine ön işlem basamakları ekleyerek görüntülerin parametre optimizasyonunu sağlamayı amaçlayıp CNN ağının öznetelik belirlemelerini yapmış ve olumlu sonuçlar elde etmiştir [18]. Bir başka örnek olarak, Tian ve arkadaşlarının önerdiği ECDNet mimarisidir [19]. Bu mimari ile genişletilmiş CNN, artık öğrenme ve toplu normalizasyon bir arada kullanılarak gürültülerin giderilmesi amaçlanmıştır. 17 katmanlı bir ağ olup ağın temel amacı hesaplama maliyetinin azaltılmasıdır. En güncel çalışmalardan biri olan Rongbian Yan ve arkadaşlarının yaptığı çalışmada yeni önerilen ağda, CNN ağlarının sunduğu sınırlamaları ortadan kaldırmak için önerilen 4 farklı alt ağ ve hiper-parametre tahmini yapan ek bir ağ içeren yapısı ile görüntülerde detay kaybının önüne geçilmesi konusunda yenilikçi bir yaklaşım ortaya koymuşlardır [20]. CNN ağlarının biraz daha kompleks hallerini de incelemek gerekirse, Mingjie Gao ve arkadaşları derin evrişimli sinir ağır (DCNN)'nın temiz görüntü ile gürültülü görüntü arasında rekabetçi bir eğitim kullanarak etkili bir gürültü giderici modeli ortaya koymuşlardır [21]. Bir başka yöntem olarak Dominik Eckert ve arkadaşları yapmış oldukları çalışmada görüntüler üzerindeki gürültünün azaltılması için farklı kayıp

fonksiyonlarının gürültü giderilmesi üzerindeki etkisi irdelemiş ve en etkili kayıp fonksiyonunun belirlenmesi üzerine çalışmıştır [22]. Hee-Joung ve arkadaşları, bir koşullu üretken çekişmeli ağ (CGAN) önerisinde bulunmuştur [23]. CGAN'ın amaç fonksiyonu şu şekilde görev almaktadır. Üretecin çıkış resimleri giriş resimleri ile denetlenir, Her çözücü ve kodlayıcı arasında U-Net benzeri kısa yollar vardır. Yeni bir görsel elde etmek yerine bir görselin temel özelliklerinin değiştirilmesi hedeflenir. Böylece temel doğrular ve tanımlanmış gürültü örüntüleri ile eğitilir ve gürültüsüz görüntülerin elde edilmesi için umut vadedicidir. Denetimli sinir ağlarının temel doğru ihtiyaçları sebebiyle medikal görüntü işlemede kullanımları maliyetli ve kısıtlıdır. Medikal görüntüler doğaları gereği gürültülüdürler. Bu problemin ortadan kaldırılması ve gürültülerin giderilmesi için gürültüsüz görüntülere ihtiyaç duymayan ağların varlığı elzemdir. Noise2Noise yaklaşımı tam olarak bu amaçla üretilmiş bir ağıdır [24]. Bu gürültü giderici ağ, aynı bilginin iki farklı gürültülü halini kullanarak öğrenmeyi amaçlar. Bu yaklaşım halen bir bilginin iki farklı versiyonuna ihtiyaç duyar. Bu problemi öngörerek ortaya çıkarılan Noise2Self çalışması, gürültü gidermeyi yalnızca gürültülü ölçümler kullanılarak yani hedef görüntünün de görüntünün kendisi olduğu bir ağ yapısına sahip olarak gürültü giderilmesini önerir [25]. Bu durum modelin kendine yakınsama problemlerini ortaya çıkarır ve çok büyük veri setlerine ihtiyaç duyar. Başka bir gürültü giderici ağ Krull ve arkadaşları tarafından önerilmiştir [26]. Önerilen ağ bir çift temiz görüntü ya da gürültülü bir görüntü kümesinden regresyon yöntemi ile gürültülerin temizlenmesini amaçlamıştır. Bu yöntem de yine Noise2Self yöntemi ile benzer dezavantajlara sahiptir. Tao Huang ve arkadaşlarının geliştirdiği ve gerçek dünya renkli görüntüleri üzerinde etkili olduğunu ispatladığı Neighbor2Neighbor (Ne2Ne) ağı Noise2Noise ağının işlevini taklit ederek, iki farklı gürültülü görüntü kaynağı yerine kendi alt gruplarını eğitim girdisi olarak kullanır ve bir düzenleyici parametre yapısı barındırarak kendine yakınsama problemlerine karşı çözüm ortaya koyar.[27]. Bu sayede iki farklı gürültü ihtiyacını ortadan kaldırarak kendi kendini eğiten ve eğitim sırasında kendine yakınsama riskini de yakınsama parametreleri ile denetleyerek ortadan kaldıran bir ağ olarak karşımıza çıkmaktadır. Temel doğrulara ve gürültüsüz görüntülere bağlı kalmadan görüntülerden arındırılma fikri DBT görüntüleri için oldukça umut vadeder.

1.5 Katkı

Bu çalışmada Tao Huang ve arkadaşlarının geliştirdiği ve gerçek dünya renkli görüntüleri üzerinde etkili olduğunu ispatladığı Neighbor2Neighbor ağına dayanan denetimsiz bir tıbbi görüntü gürültü giderici ağı ile medikal görüntüler üzerindeki beyaz gauss ve poisson gürültülerinin temizlenmesi önerilmiştir. Bu yöntemin, geleneksel matematiksel gürültü giderici yöntemler ile belirlenen metrikler üzerinden kıyası yapılmış ve niteliksel olarak bir uzman görüşü ile üstünlüğü gözle görülür şekilde ortaya konulmuştur. Çalışmanın genel planlaması şu şekildedir. Denetimsiz tıbbi görüntü gürültü gidericisinin kullanımı ve eğitim yönteminin gerekçesi, uygulanması ve akışı ikinci bölümde ele alınmıştır. Üçüncü bölümde deneysel parametrelerin oluşturulması, veri kümesinin sınıflandırılması ve yöntemin ayrıntıları ve uygulanması, tasarım seçimleri ve elde edilen sonuçlar sunulmaktadır. Yöntemin başarısının değerlendirilmesi ve öngörüler dördüncü bölümde dile getirilmiş ve son bölümde tez nihaytlendirilmiştir.




2. YÖNTEM

Bu bölümde medikal dijital meme tomosentezi görüntüleri üzerindeki gürültülerin temizlenmesi için önerilen bir matematiksel yöntem ve bir denetimsiz derin öğrenme ağına ait detaylı anlatımlar verilmiştir. Yöntemlerin teorik gerekçeleri ortaya konulmuş ve uygulamanın detaylarından bahsedilmiştir.

2.1 Matematiksel Yöntemler ile Gürültünün Giderilmesi

Bir düzenleyici olan blok eşlemeli üç boyutlu filtreleme algoritması, en etkili gürültü temizleme yöntemlerinden biri olarak kabul edilir. Özellikle düşük radyasyon dozlarında oluşan beyaz gauss gürültüsü ve poisson gürültüsünün azaltılmasında kullanışlıdır. BM3D genel işleyiş olarak şu şekilde incelenir:

İlk adım olarak bloklara bölme işlemi gerçekleştirilir. Bu işlem orijinal görüntünün birbirileriyle kesişmeyen bloklara bölünmesidir. Bloklar gürültünün azaltılması için işleme sokulacak birimlerdir. Blokların boyutları işleme tabi tutulacak olan görselin özelliklerine göre değişse de genel olarak 8x8 ya da 16x16 piksel boyutunda bloklar kullanılır. Blok eşleme, blokların benzerlik metrikleri kullanılarak diğer bloklar ile eşlenmesidir. Bu işlem görüntü üzerindeki benzer yapıların tayinini sağlamak amacıyla yapılır. Benzerlik metrikleri genellikle öklityen uzaklık gibi bir mesafe ölçüsü kullanılarak hesaplanır. Benzer özelliklere sahip bloklar bir grup haline getirilir. Her gruba bir lider atanır. Grup lideri, o grubun benzer özelliklilerinin ortalamasını temsil eder. Bu liderler, gürültü temizleme esnasında temsilci blok görevi görür. Grup liderlerinin çevresindeki blokların gürültü düzeyleri tahmin edilir. Bu tahmin ile grup lideri ile benzer bloklar arasındaki farklılıklara dayanarak yapılır. Gürültü tahminleri her grup lideri için ayrı ayrı hesaplanır. Her bir grup lideri ve çevresindeki blokların gürültü tahminlerine uygun olarak gruba uygun parametrelerde bir Wiener filtre uygulanır. Her bir grup lideri çevresindeki blokları temizlendiğinde, temizlenmiş grup için grup liderlerinin özellikleri kullanılıp orijinal görüntüler kenar ve örtüşme bölgeleri gibi hassas bölgeler korunarak yeniden oluşturulur.



Şekil 2.1: BM3D Basitleştirilmiş gruplama görseli [10]

BM3D işlemi matematiksel bir işlemdir ve gürültü seviyesinin azaltılması sağlanana kadar görüntü üzerine birden fazla defa uygulanabilir. Şekil 2.1’de gruplama yapısı görselleştirilmiştir. Temel olarak işlevi ve uygulaması anlatılan BM3D için çalışmamız sırasında 8x8 piksel değerinde bir bloklama ızgarası kullanılmış, etkin hedef gürültü değeri parametresi olarak belirlenen sigma değeri 25 olarak kabul edilmiştir. Buna ek olarak arama penceresi boyutu 20x20 olarak kullanılmıştır. Arama penceresi orijinal görüntü üzerinde dolanarak benzer blokların tayininin sağlayan operatördür. Bu işlem sırasında verimlilik ve hesaplama maliyeti göz önünde bulundurularak boyut tayini yapılmıştır.

2.2 Denetimsiz Derin Öğrenme Ağı ile Gürültünün Giderilmesi

Derin öğrenme ağları temel doğrular üzerinde etiketlenmiş veriler ile bağlantılar kurarak hedef olguyu oluştururlar. Bu durum gerçek dünya problemleri, özellikle de görüntüler üzerinden gürültü temizleme işlemleri için oldukça maliyetli veri setleri anlamına gelir ve birçok durumda ihtiyaçları karıştılabilecek veri setlerinin oluşturulması neredeyse imkansızdır. Bu ana problemin çözümü için temel doğrulara ihtiyaç duymayan denetimsiz derin öğrenme ağları önerilmiştir. Denetimsiz derin öğrenme ağları etiketlenmiş temel doğru verilerine ihtiyaç duymadan eğitim girdisi veriler üzerinden temel yapı ve özelliklerin öğrenilerek hedef verinin oluşturulmasını amaçlar. Denetimsiz öğrenme gerçekleştirmek için izlenebilecek birkaç yöntem vardır. Bunlardan bir tanesi bir sahne üzerinden birden fazla bağımsız gürültülü örnek

üzerinden işlem yapılması, yalnızca tek gürültülü görüntü üzerinden kör nokta ağ yapısının tasarımının gerçekleştirilmesi ya da gürültülü bir görüntü üzerine dağılımı belirlenmiş (ör: Gauss ya da poisson) bir gürültü ekleyerek bu iki gürültülü görüntü arasındaki regresyon yapısının keşfine dayalı ağ yapısıdır. Ancak bu gereklilikler de gerçek gürültü temizleme senaryoları için pratik değillerdir. Örneğin medikal görüntüler gibi hareketli ya da belirli kısıtlamalara sahip görüntülerde aynı sahnenin birbirinden farklı gürültülü görüntü çifti eldesinin zor olmasıdır. Körlük noktası ağlarının ise başarı oranları oldukça düşük ve hesaplama maliyetleri oldukça fazladır. Bu çalışmada, belirtilen sınırlamalara çözüm olarak öne atılan ve başarısı RGB dünya görüntüleri üzerinde ispatlanmış öz-denetimli gürültü temizleme yaklaşımı olan Neighbor2Neighbor yöntemi kullanılmıştır. Bu yaklaşım alt örneklendirmeye dayalı bir eğitim görüntü çifti oluşturma stratejisini barındırır ve bu stratejiyi denetleyecek bir düzenleme terimi önerir [27]. Oluşturulan her görüntü çifti aslında orijinal görüntünün alt kümesi olmasından dolayı tek bir gürültülü görüntüden görüntü çifti elde edilmiş olur. Her pikseldeki gürültünün piksel değeriyle bağımsız olduğu ve farklı konumlardaki gürültüler arasında korelasyon olmadığı varsayılırsa, bu iki alt küme gürültülü görüntü çiftleri, orijinal gürültülü görüntü temel gerçeği göz önünde bulundurulduğunda bağımsızdır. Eğer alt küme gürültülü görüntü çiftlerinin nasıl oluşturulduğunu da göstermek gerekirse, orijinal görüntünün genişliği ve uzunluğu bir k değişkenine bölünür, bu durumda görüntü üzerinden alt kümeler k parametresine bağlı olarak oluşturulur. k burada alt kümelerin ölçeklendirici parametresidir ve bizim çalışmamız için 2 olarak belirlenmiştir. Eğer görüntü üzerindeki piksel adresi $P(i,j)$ olarak belirtilirse, bu değer rastgele olarak belirlenerek yukarıdaki gibi görüntü alt kümesi çifti oluşturulur.

Denetimsiz gürültü giderici ağ yapısı gürültü temizleme konusunda ihtiyaç duyulan aynı sahnenin farklı gürültülü görüntü çiftleriyle eğitilmesi senaryosunun gerçekleştirilmesi için oldukça elverişli ve belirli bir modele bağlı kalma sınırlarını ortadan kaldırmasıyla oldukça esnektir. Bizim çalışmamızda gürültü temizleme yöntemi olarak Noise2Noise yapısından esinlenilerek Neighbor2Neighbor yapısı medikal görüntüler üzerine uygulanmıştır. Eğer ağı matematiksel olarak ifade ederek ağımızın işleyişi anlamlandırmak istersek, denklem 2.1 gürültü giderme ağının matematiksel ifadesi olarak karşımıza çıkar. Oluşturulacak görüntü bir maksimum olabilirlik ifadesi ile temsil edilir.

$$\arg \min_{\theta} \mathbb{E}_{\mathbf{x}, \mathbf{y}, \mathbf{z}} \|f_{\theta}(\mathbf{y}) - \mathbf{z}\|_2^2 \quad (2.1)$$

Burada f_{θ} denklemde matematiksel olarak Noise2Noise gürültü giderici ağı ifade eder. Bu denklem üzerinde \mathbf{x} ile gösterilen değer orijinal görüntü parametresini ifade ederken, \mathbf{y} ve \mathbf{z} görüntü çiftlerinin her birini ifade etmektedir. Alt küme gürültülü görüntü çiftini matematiksel olarak ifade edilirse $G = (g_1, g_2)$ olarak yazılabilir. Bu durumda görüntüler üzerine gürültü de eklenirse $(g_1(\mathbf{y}), g_2(\mathbf{y}))$ ifadesi elde edilmiş olur. Bu gürültülü görüntü çiftleri ağın ana denklemine adapte edilirse eğer denklem 2.2 elde edilir.

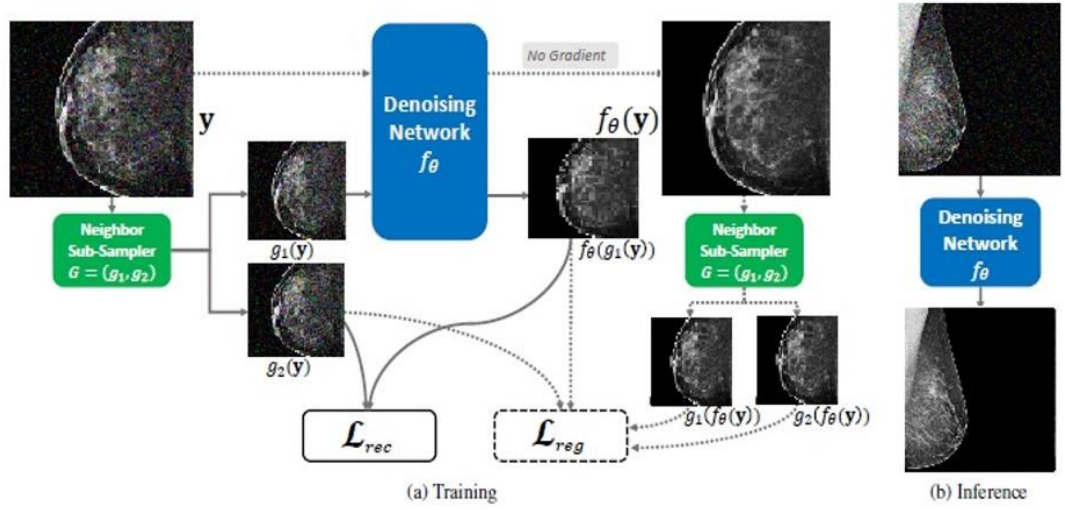
$$\arg \min_{\theta} \mathbb{E}_{\mathbf{x}, \mathbf{y}} \|f_{\theta}(g_1(\mathbf{y})) - g_2(\mathbf{y})\|_2^2 \quad (2.2)$$

Verilen denklemde kullanılan alt örnek kümeleri, Noise2Noise modelinde kullanılan aynı sahnenin farklı gürültü seviyelerindeki hallerini temsil etmektedir. Yukarıdaki denkleme ek olarak öğrenme eğilimini düzenlemek adına denklem içerisine \mathcal{L} kayıp fonksiyonu dahil edilerek düzenleme hiper parametresi eklenir. Bu durumda denklem 2.3 ifade edilebilir.

$$\begin{aligned} \mathcal{L} &= \mathcal{L}_{rec} + \gamma \cdot \mathcal{L}_{reg} \\ &= \|f_{\theta}(g_1(\mathbf{y})) - g_2(\mathbf{y})\|_2^2 \\ &\quad + \gamma \cdot \|f_{\theta}(g_1(\mathbf{y})) - g_2(\mathbf{y}) - (g_1(f_{\theta}(\mathbf{y})) - g_2(f_{\theta}(\mathbf{y})))\|_2^2, \end{aligned} \quad (2.3)$$

Denklem 2.3 içerisindeki γ ifadesi öğrenmeyi stabilize etmek için kullanılan düzenleme parametresinin kontrolünü sağlayan hiper parametreyi ifade eder. Bu hiper parametre öğrenme sırasında öğrenmeyi durdurarak ya da bölerek alt örnekleme kümelerinin gradyanlığını sağlamak için belirlenen değerlerde değiştirilebilmektedir. Denklemler özet halinde sunulmuştur. Denklemlerin ayrıntılı açıklaması ve teoremin ispatı için mutlaka kaynağını kontrol ediniz.[27].

Şekil 2.2’de Neighbor2Neighbor ağ yapısının bütünü bir şeması verilmiştir. Bu şema ile açıkça ağın alt kümelerinin düzenleyici ve yeniden yapılandırıcı görevleri ve düzenleyici kayıp fonksiyonları gösterilmektedir.



Şekil 2.2: Ağ yapısı.

Şekilde 2.2’de görüldüğü üzere, $g_1(y)$ ve $g_2(y)$ orijinal görüntüden elde edilen alt örnekleme kümeleridir. \mathcal{L}_{rec} terimi yeniden yapılandırma kayıp fonksiyonunu, \mathcal{L}_{reg} terimi ise Düzenlilik kayıp fonksiyonunu ifade eder. \mathcal{L}_{rec} eğitim çıktısı ile girdi arasında hesaplanır. \mathcal{L}_{reg} ise eğitim çıktısı ile girdisi arasındaki piksel değerlerinin farklılıklarını düzenlemek için kullanılır [27].



3. DENEY

Bu bölümde deney düzeneği, deneysel veriler, yöntemin uygulanışı ve deneyin sonuçları ortaya konmuş, karşılaştırma yöntemleri detaylı şekilde tablo ve grafikler ile açıklanmış, sonuçlar görseller ile pekiştirilmiştir. Buna ek olarak nicel kıyasın yanında bir uzman görüşü alınarak nitel kıyas da gerçekleştirilmiştir.

3.1 Deneysel Veriler

Bu çalışmada gerçek hastalardan edinilmiş verilerden oluşan BSC-DBT veri seti ve in slico çalışmalar için oluşturulmuş 2D phantom veri seti kullanılmıştır [28,29]. BSC-DBT veri seti 5060 veriden oluşmaktadır. Bu veriler tanısal anlamda, normal, aksiyon gerektiren, iyi huylu ve kötü huylu kanser olarak etiketlenmiştir. Veriler kullanıma hazırlanırken her tanısal kategoriden rastgele olacak şekilde eşit sayıda veri alınarak bir bütün halinde kullanıma hazırlanmıştır. İki veri grubu için de kullanıma hazırlanan verilerin %70'i eğitim verisi %15'i validasyon verisi ve %15'i test verisidir. Her veri grubu içinde 2148 veri deney için kullanılmıştır. Görseller 256x256 piksel değerlerinde kırılarak eş boyutlu hale getirilmiştir. Kullanılan veriler Jpeg formatında ve siyah beyaz görüntülerdir.

3.2 Karşılaştırma Yöntemi

Çalışma esnasında önerilen gürültü giderici ağ, en etkili matematiksel gürültü giderici yöntem olan BM3D ile belirlenen PSNR, SSIM ve CNR metrikler üzerinden iki veri seti için de niceliksel kıyaslanmıştır. Kıyaslama matematiksel yöntem ve yapay sinir ağı ile gaussian gürültüsü ve poisson gürültüsünün giderilmesi üzerinden yapılmıştır. Veri seti içerisinde rastgele seçilen 100 veri üzerinden piksel değerlerinin standart sapması (σ) ve ortalama değeri (λ) ve bu iki değere ait standart sapmalar hesaplanmıştır. BSC-DBT veri setine ait standart sapma=25.3 ve ortalama değer=30,2 olarak hesaplanmıştır. Veri setinden elde edilen bu değerlerin kararlı bir yapıya sahip olduklarını kontrol etmek amacıyla rastgele seçilen, ortalaması ve standart sapması hesaplanan verilerin standart sapmalarına bakılmış, standart sapma değerlerinin

standart sapması 1.12 ve ortalama değerlerinin standart sapması 1.19 bulunmuştur. Veri setlerinin kararlı olduğuna kanaat getirilmiştir. Benzer yol 2D phantom veri seti için de uygulanmış, standart sapma=25.7, ortalama değer=30,4 olarak hesaplanmıştır. Elde edilen verilerin standart sapma değerleri kontrol edilmiş, 1,21 ve 1,32 olarak hesaplanmıştır. Bu veri setlerinin de kararlılığı ortaya konulmuştur. Elde edilen ortalama değer ve standart sapma değeri tam sayılara indirgenmiş ve hem yapay sinir ağı için hem de BM3D için parametre girdisi olarak kullanılmıştır. Bu elde edilen değerlerinin ideal olduğunun ispatı için PSNR değerleri üzerinden kontrol edilmiş, standart sapma ve lambda değerlerin artması ve azalması durumunda PSNR değerinin düştüğü gözlemlenmiştir.

3.3 Ağ Mimarisi ve Eğitim Süreçleri

Ağ mimarisi Neighbor2Neighbor ağının medikal görüntü özelinde uyarlanması üzerine kurgulanmıştır. Medikal görüntüler için uygun hale getirmek adına hiper parametre ayarları şu şekildedir; batch boyutu 2, öğrenme oranı 0.0003 olarak ayarlanmıştır. Eğitim varyans değeri 0,4 olarak belirlenmiştir. $\gamma=1$ olarak belirlenmiştir. Eğitim, eğitim süresini optimize etmek adına 75 epoch üzerinden kurgulanmıştır. Öğrenme sırasında Adam optimizeri kullanılmış ve öğrenme oranı her 15 epochtan sonra yarılanmıştır [30]. Eğitim görselleri 256x256 piksel değerlerinde Jpeg ve siyah beyaz görüntülerdir. Eğitim için Python 3.11 dili ve Pytorch 2.0.1 kütüphanesi kullanılmıştır [31]. Bir kişisel bilgisayar üzerinden RTX3050TI ekran kartı aracılığıyla eğitim işlemleri BSC-DBT veri seti için 74 saat, 2D Phantom veri seti için 64 saat sürmüştür.

3.4 Sonuçlar

BSC-DBT ve 2D phantom veri setleri kullanılarak ağ eğitimleri tamamlanmıştır. Ağ eğitimi sırasında iki farklı yaklaşım izlenmiştir. İlk yaklaşım sabit gürültü değerleri ile ağ hem gauss gürültüsü için hem de poisson gürültüsü için eğitilmiştir. Yöntem kısmında da bahsedildiği üzere gürültüler üzerinden temin edilen ortalama σ ve λ değerleri sabit kabul edilmiş ve eğitim bu değerler ile tamamlanmıştır. İkincil yaklaşım olarak gürültü seviyelerinin değişken olduğu bir yöntem ile eğitim tamamlanmıştır. Bu değişkenlik hem gaussian gürültüsü için hem de poisson gürültüsü için değişkenlerin 5 ve 50 değerleri arasında normal dağılıma uyacak şekilde

uygulanmıştır. Sonuçlar PSNR ve SSIM metrikleri ile niceliksel olarak değerlendirilmesi için Çizelge 3.1'e kaydedilmiştir. Çizelge 3.2'de ise PSNR ve SSIM metriklerine ek olarak CNR değeri üzerinden kıyas yapılmış ve kaydedilmiştir. Her iki tablo üzerindeki en iyi değer koyu punto, ikinci iyi değer ise altı çizili punto ile ifade edilmiştir. PSNR eşik değeri 30 dB, SSIM eşik değeri ise 0.75'tir.

Çizelge 3.1: Her iki veri seti ile yapılan eğitim sonucu matematiksel yöntem ile yapay sinir ağının gürültü parametrelerine göre temizleme yeteneğinin metrikler üzerinden karşılaştırma çizelgesi.


GÜRÜLTÜ TİPİ	YÖNTEM	BSC-DBT VERİSETİ		2D PHANTOM	
		PSNR (dB)/ SSIM		PSNR (dB) / SSIM	
Gaussian $\sigma=25$	Ne2Ne Ağı	33.15 / 0.888		34,87 / 0,896	
	BM3D	31.96 / 0.814		32,23 / 0,824	
Gaussian $\sigma=\varepsilon[5,50]$	Ne2Ne Ağı	32.05 / 0.847		<u>33,12 / 0,855</u>	
	BM3D	30.87 / 0.793		31,15 / 0,793	
Poisson $\lambda=30$	Ne2Ne Ağı	31.21 / 0.803		31,55 / 0,812	
	BM3D	30.86 / 0.788		31,08 / 0,795	
Poisson $\lambda=\varepsilon[5,50]$	Ne2Ne Ağı	30.92 / 0.797		31,15 / 0,798	
	BM3D	30.56 / 0.751		30,76 / 0,774	

Çizelge 3.1'de görüldüğü üzere en etkili sonuç gürültü giderici ağ ile sabit gürültü değerinde eğitim yapıldığı zaman elde edilmiştir. Ayrıca sonuçlara bakıldığında açıktır ki ağ gaussian gürültüsünü temizleme konusunda poisson gürültüsüne nazaran daha etkilidir. Fakat şu aşıkardır ki gürültü giderici ağ poisson gürültüsünü temizleme konusunda da matematiksel yöntemlere kıyasla daha iyi sonuç göstermektedir.

Çizelge 3.2: Her iki veri seti ile yapılan eğitim sonucu matematiksel yöntem ile yapay sinir ağının gürültü parametrelerine göre temizleme yeteneğinin CNR değeri üzerinden karşılaştırma çizelgesi.

GÜRÜLTÜ TİPİ	YÖNTEM	BSC-DBT VERİSETİ			2D PHANTOM		
		Orijinal CNR	Gürültülü CNR	Temizlenen CNR	Orijinal CNR	Gürültülü CNR	Temizlenen CNR
Gaussian $\sigma=25$	Ne2Ne Ağı	2,12	1,79	2,36	1,43	0,84	1,56
	BM3D	2,12	1,79	1,96	1,43	0,84	1,48
Gaussian $\sigma=\varepsilon[5,50]$	Ne2Ne Ağı	2,12	1,65	2,18	1,43	1,06	1,44
	BM3D	2,12	1,65	1,82	1,43	1,06	1,39
Poisson $\lambda=30$	Ne2Ne Ağı	2,12	1,83	<u>2,07</u>	1,43	0,98	1,36
	BM3D	2,12	1,83	1,78	1,43	0,98	1,09
Poisson $\lambda=\varepsilon[5,50]$	Ne2Ne Ağı	2,12	1,51	2,35	1,43	0,91	1,32
	BM3D	2,12	1,51	1,98	1,43	0,91	1,04

Çizelge 3.1’de olduğu gibi Çizelge 3.2’de de benzer şekilde sabit değerde eğitilen gürültü giderici ağıın CNR değeri iyileştirme konusunda da en iyi sonucu elde etmiş, poisson gürültüsü giderme konusunda da yine sabit değerler üzerinden en iyi ikinci skoru elde etmiştir. Niceliksel değerlendirmenin yanında niteliksel değerlendirmeyi de dahil edersek aşağıdaki şekilleri incelemeliyiz.




Şekil 3.1: BSC-DBT data seti ile eğitilmiş denetimsiz gürültü giderici sinir ağıının (Ne2Ne) etkisinin görsel üzerinde karşılaştırılması.


Şekil 3.1’de gürültü giderici ağı ile BSC-DBT veri seti üzerinden elde edilen gerçek meme görüntüleri ile gürültü giderilmesi sonucu görülmektedir. a grubu görseller orijinal gürültülü görüntüdür. Ağıın etkinliğini en iyi seviyede gözlemlemek adına görüntü üzerine sentetik olarak gaussian gürültüsü eklenmiş ve b grubunda gösterilmiştir. c grubunda ise ağı ile gürültüsü giderilmiş görselleri görmekteyiz. Yukarıdaki görsellerde de açıkça görüldüğü üzere gürültüsü görece bir hayli artırılmış görüntü üzerinden bile gürültü giderici ağıın görsellerdeki ayrıntıları yok etmeden gürültüden arındırdığı ortaya konulmuştur. Ortaya konulan bu tatmin edici sonuca ilaveten bazı meme görüntüleri üzerinde ilgilenen bölge ile geri plan görüntüsü arasında görüntü kalitesini ve görüntü üzerindeki ayrıntıları etkilemeyen belli belirsiz bir kenar çizgisi oluştuğu gözlemlenmiştir. Şekil-3.2’de ise 2D phantom veri seti üzerinden gürültü giderici ağı performansı niteliksel olarak değerlendirilebilir. Burada da açıktır ki gürültü giderici sentetik olarak artırılmış ekstra gürültüye rağmen tatmin edici derecede görüntü üzerindeki temizleme etkisi görülmektedir. Gerçek meme

görüntüleri üzerinde beliren kenar çizgisi oluşumuna ise phantom görüntüleri üzerinde rastlanmamıştır. Bu iki kıyas için bir yorum yapılması gerekirse, gürültü giderici ağ görüntüler üzerindeki gürültüyü temizlediği sırada kontrast değerinin gürültüye göre baskın hale gelmesini sağlamasıyla artan kontrastla beraber görüntü üzerindeki çizginin belirginleşmesi aslında görüntünün doğasında olduğu ve gürültü sebebiyle bastırıldığı ön görülmüştür.


Benzer şekilde BM3D ile elde edilen görseller üzerinden niteliksel değerlendirme yapmak gerekirse, sentetik gürültünün eklenmesine rağmen görsel üzerinde detay ve kenar bilgilerinin korunarak etkili şekilde gürültü temizlemesinin yapılmasına rağmen, görsel üzerinde gözle inceleme yapıldığı zaman sentetik gürültü izlerinin azalmış da olsa devam ettiği görülmüştür. Niceliksel değerlendirme sırasında temizlenen görüntünün orijinal görüntüye göre PSNR ve SSIM değerlerinin yanı sıra CNR değerinin de arttığı gözlemlenmişti, lakin niteliksel değerlendirme sırasında sentetik gürültü izlerinin izlenebilir olduğu not edilmiştir. Gözlemlenen gürültülerin arka plan görüntüsü üzerinde kaldığı ve ilgilenen bölge üzerinde gürültünün gözle tespit edilemediği de aşikardır. Bu sebeptendir ki metrikler üzerinden incelenen niceliksel değerler iyileşmiştir. Şekil 3.3'te bahsedildiği gibi gerçek meme görüntüsündeki arka plan görüntüsü üzerinde gürültü gözlemlenebilirken, Şekil 3.4'te phantom görüntüler üzerinde bahsedilen durum nispeten ortadan kalkmıştır.



Şekil 3.2: BSC-DBT veri seti ile BM3D matematiksel yöntemin gürültü giderme etkisinin görsel üzerinde karşılaştırılması.




Şekil 3.3: 2D phantom veri seti ile eğitilmiş denetimsiz gürültü giderici sinir ağının etkisinin görsel üzerinde karşılaştırılması.




Şekil 3.2: 2D Phantom veri seti ile BM3D matematiksel yöntemin gürültü giderme etkisinin görsel üzerinde karşılaştırılması.

Sonuçların niteliksel olarak iki veri setinden elde edilen görüntüler üzerinden daha kolay kıyaslanması için iki gürültü giderme yöntemini de içeren görseller Şekil 3.5 ve Şekil 3.6 ile verilmiştir. a grubunda görsellerin orijinalleri olacak şekilde b grubu ağ ile c grubu ise matematiksel yöntem ile temizlenmiş görselleri içermektedir.



Şekil 3.3: BSC-DBT veri seti ile BM3D matematiksel yöntem ile denetimsiz sınır ağının (Ne2Ne) gürültü giderme etkisinin görsel üzerinde karşılaştırılması.



Şekil 3.4: 2D Phantom veri seti ile BM3D matematiksel yöntem ile denetimsiz sınır ağının (Ne2Ne) gürültü giderme etkisinin görsel üzerinde karşılaştırılması.

Çizelge 3.3: Her iki veri seti ile eğitim sonucu matematiksel yöntem ile yapay sinir ağının gaussian gürültüsünü temizleme yeteneğinin metrikler üzerinden karşılaştırma tablosu.

Ne2Ne Ağı			BM3D	
Gaussian (σ)	BSC-DBT VERİ SETİ PSNR (dB)/ SSIM	2D PHANTOM PSNR (dB) / SSIM	BSC-DBT VERİ SETİ PSNR (dB) / SSIM	2D PHANTOM PSNR (dB) / SSIM
5	32,55 / 0,869	32,96 / 0,863	31,12 / 0,799	31,86 / 0,806
10	32,63 / 0,873	33,12 / 0,871	31,21 / 0,801	31,91 / 0,811
15	32,72 / 0,879	33,86 / 0,881	31,52 / 0,806	32,03 / 0,816
20	32,89 / 0,882	34,35 / 0,889	31,84 / 0,809	32,16 / 0,819
25	<u>33,15</u> / <u>0,888</u>	34,87 / 0,896	31,96 / 0,814	32,23 / 0,824
30	32,46 / 0,868	34,18 / 0,873	31,76 / 0,807	31,89 / 0,817
35	31,98 / 0,838	33,47 / 0,851	31,53 / 0,803	31,67 / 0,811
40	31,35 / 0,823	32,65 / 0,835	31,35 / 0,791	31,54 / 0,811
45	30,61 / 0,799	31,74 / 0,814	30,61 / 0,783	31,21 / 0,795
50	30,18 / 0,769	30,15 / 0,783	30,18 / 0,775	30,65 / 0,783


Çizelge 3.4: Her iki veri seti ile eğitim sonucu matematiksel yöntem ile yapay sinir ağının Poisson gürültüsünü temizleme yeteneğinin metrikler üzerinden karşılaştırma tablosu.

Ne2Ne Ağı			BM3D	
Poisson (λ)	BSC-DBT VERİ SETİ PSNR (dB)/ SSIM	2D PHANTOM PSNR (dB) / SSIM	BSC-DBT VERİ SETİ PSNR (dB) / SSIM	2D PHANTOM PSNR (dB) / SSIM
5	30,72 / 0,788	30,79 / 0,791	30,36 / 0,768	30,65 / 0,774
10	30,92 / 0,791	31,03 / 0,793	30,43 / 0,772	30,71 / 0,779
15	31,11 / 0,795	31,16 / 0,798	30,51 / 0,776	30,76 / 0,781
20	31,23 / 0,806	31,27 / 0,814	30,73 / 0,779	30,87 / 0,787
25	31,37 / 0,811	31,65 / 0,823	30,81 / 0,783	31,01 / 0,791
30	<u>31,51</u> / <u>0,818</u>	31,71 / 0,834	30,86 / 0,788	31,51 / 0,795
35	31,21 / 0,806	31,39 / 0,816	30,76 / 0,778	31,25 / 0,789
40	30,9 / 0,797	31,08 / 0,803	30,65 / 0,773	30,81 / 0,781
45	30,45 / 0,783	30,65 / 0,793	30,43 / 0,769	30,49 / 0,774
50	30,18 / 0,775	30,33 / 0,786	30,09 / 0,761	30,21 / 0,767


Eğitim yaklaşımı olarak iki farklı yöntem iki farklı veri seti üzerinden denenmiş ve yukarıda sonuçları paylaşılmıştı. Sabit bir değer ile iki farklı veri seti için eğitilen ağın değişken gürültü durumlarındaki etkileri test edilmek üzerine bir deney düzeneği daha kurulmuş ve sonuçları Çizelge 3.3 ve Çizelge 3.4'e kaydedilmiştir.

Koyu punto ile yazılmış olan sonuç tüm karşılaştırma üzerinden en iyi sonucu ifade edecek şekilde düzenlenmiş olup altı çizili punto ise en etkili ikinci sonucu belirtir. PSNR eşik değeri 30 dB, SSIM eşik değeri ise 0.75'tir. Buradaki amaç, sabit bir değer ile eğitilen ağ ve sabit değerli BM3D algoritmasının değişkenlik gösteren gürültü durumları üzerindeki performansının gösterilmesidir. Bu tablo üzerinde yer alan her değer test veri grubu içerisinde rastgele elde edilmiş 20 verinin ortalamasıdır. Veri grubunun stabil olması adına standart sapması eşik değeri 1,5 olarak belirlenmiş ve elde edilen verilerin standart sapmaları bu değer altında kalmıştır. Elde edilen sonuçlarda görülmüştür ki sabit değer eğitimi neticesinde eğitimin gerçekleştirdiği değerlerde performans hem BM3D hem de ağ için en üst seviyededir. Öngörüldüğü gibi gürültü derecesi arttıkça metriklerde hızlı bir düşüş gerçekleşmiştir. Gürültünün azaldığı durumlarda ise öngörülen iyileşme derecesinin artmasının aksine yavaş bir trend ile düştüğü görülmüştür. Şekil 3.7 ve Şekil 3.8 de düşüş trendleri hem artan gürültü hem de azalan gürültü durumlarında açıkça gösterilmiştir. Elde edilen bu sonucu yorumlamak gerekirse, optimum değerde en iyi performansın görülmesi aslında gürültü dağılımının ve miktarının tam olarak algoritma ve ağa tanıtılması sebebiyle hedefler belirgindir, artan gürültü durumunda hedefin üstünde kalan bir gürültü oranı sebebiyle hızlı bir düşüş trendi gözlenir, azalan gürültü durumunda ise durum biraz daha karmaşıktır. Algoritma ve ağ azalan gürültü durumunda optimum noktadaki değeri baz alarak işlem yapmaya devam etmek ister, bu durumda da görüntü üzerindeki frekansı yüksek detay ve kenar noktalarına saldırıya ve görüntünün kalitesine etki etmeye başlar. Lakin bu bozulma derecesi 5 sigma ve lambda değerlerinde orijinal görüntünün PSNR ve SSIM değerlerinin üstünde seyrettiği ve bu sebeple aslında görüntüye negatif etki yapmak yerine pozitif etkisinin azaldığı gözlemlenmiştir.

Şekil 3.7 ve Şekil 3.8' de verilen grafiklerde SSIM ve PSNR için belirlenen eşik değerleri 0.75 ve 30 dB'dir. Gürültülü görüntülerin PSNR ve SSIM değerleri bu eşik değerlerinin altında kalmaktadır. Bu sebeple gürültülü görüntülerin değerleri grafikler üzerinde gösterilmemiştir. Bununla birlikte grafik üzerinde yatayda gürültü değerleri dikeyde ise solda PSNR değerleri ve sağda SSIM değerleri yer almaktadır. Değerlendirmeye tabi tutulan her parametre farklı renkler ile ifade edilmiştir. Bu sayede tek bir grafik üzerinde her parametre niceliksel olarak değerlendirmeye tabi tutulması amaçlanmıştır.



Şekil 3.5: Her iki veri seti ile eğitim sonucu matematiksel yöntem ile yapay sınır ağının gaussian gürültüsünü temizleme yeteneğinin metrikler üzerinden karşılaştırma grafiği.



Şekil 3.6: Her iki veri seti ile eğitim sonucu matematiksel yöntem ile yapay sınır ağının poisson gürültüsünü temizleme yeteneğinin metrikler üzerinden karşılaştırma grafiği.

Elde edilen sonuçlar bir uzman görüşünce Şekil 3.5'te gösterilen a orijinal görseller, b ağ ile temizlenmiş görseller ve c BM3D ile temizlenmiş görseller üzerinden değerlendirilmiştir. Değerlendirme sırasında görseller toplu halde gösterilmiş ve orijinal görsel dışında görsellerin üretildiği yöntem gizli tutulmuştur. Yapılan değerlendirmeye göre:

1. görseller arasında c grubu görselinin uzaysal çözünürlüğü b grubu ve orijinal görüntüye nazaran düşmüştür. Kontrast çözünürlüğünde ise b grubuna nazara düşüken orijinal görüntü ile benzerlik göstermektedir. b grubu görselinde c grubuna göre uzaysal çözünürlük ve kontrast çözünürlüğü görece iyi olduğu gözlemlenmiştir.

3. görseller arasında c grubu görselinin orijinal görüntüye ve b grubuna göre uzaysal çözünürlüğü ve kontrast çözünürlüğü düşüktür, b grubu görselin ise orijinal ve c grubu görsellere göre uzaysal ve kontrast çözünürlüğünün yüksek olduğu gözlemlenmiştir.

Uzman görüşünü de göz önünde bulundurarak sonuçlarımızı tekrar değerlendirmek gerekirse, uzman görüşünce belirtilen niteliksel iyileştirmelerde de b grubu görseller yani ağ ile gürültüsü giderilmiş görseller için en iyi sonuçlar ortaya konulmaktadır. Bu da ağın başarısının niceliksel kanıtlarına ek niteliksel olarak da ispatıdır.



4. TARTIŞMA

Bu bölümde çalışmamızda sunulan ağın sınırlamaları ve tasarım seçenekleri hakkında detaylı bilgiler verilmektedir. Önerilen yöntem gürültü azaltımı için uzamsal düzlemde doğrudan 2 boyutlu görüntülerin piksel değerlerini baz alır ve siyah-beyaz görüntüler için tasarlanmıştır. Gürültü temizlemeye odaklanan matematiksel ve derin öğrenme tabanlı birçok çalışma var olsa da çalışmamız gerçek veri setlerini baz alarak temel doğru barındırmayan bir yöntem izlenerek yapıldığı için yine kıyası temel doğru olmadan çalışan matematiksel yöntemler ve uzman görüşüncü yapılmıştır. Çalışma içerisindeki karşılaştırma yöntemi olarak PSNR, SSIM ve CNR metrikleri üzerinden niceliksel ve görseller üzerinden niteliksel değerlendirme yapılmıştır. Değerlendirme yapılırken tercih edilmiş olan farklı eğitim parametreleri ve bu parametrelerin etkisinin birbirilerine olan kıyası da gözler önüne serilmiştir. Önerilen ağ bir denetimsiz gürültü giderici ağı yapısıdır. Temel olarak denetimsiz gürültü giderme ağlarının gerekliliklerinden olan bir sahnenin farklı gürültü değerlerindeki örneklemeleri üzerinden eğitim ihtiyacını karşılamaya yönelik alt kümelerinin kullanımı prensibini uygulamıştır. Bu sayede aynı sahnenin medikal görüntüleme ve dinamik görüntüleme durumları gibi yakalanamayacağı durumlarda kullanımı sağlanmıştır. Önerilen ağ için temizleme ağı olarak Noise2Noise yaklaşımına benzer bir yapı tercih edilmiş olsa da bu ağ yapısında gürültü temizleme için farklı yaklaşımların da tercih edilmesi olanağı mevcuttur. Bu durum ile veri elde etme maliyeti minimize edilebilir ve eğitim maliyetleri üzerinde yeni çalışmalar yapılarak gerçek dünya problemlerinde ağın kullanımı yaygınlaştırılabilir. Elde edilen veriler ışığında, gaussian gürültüleri için oldukça verimli olan ağın poisson gürültülerinin temizlenmesinde nispeten daha yetersizdir. Ayrıca sabit değer eğitimi ile daha verimli olacağı gösterilen ağın, sabit değer ile farklı gürültü seviyesindeki iyileştirme verileri de gözler önüne serilmiştir.



5. KAPANIŞ

Sonuç olarak, veri seti temininin oldukça zor ve maliyetli olduğu tıbbi görüntüleme alanında denetimsiz derin öğrenme kullanılarak DBT görüntülerinin gürültüsünün azaltılması seçeneği, meme kanseri taraması alanında dönüştürücü bir fırsat sunmaktadır. Sunulan denetimsiz gürültü giderici algoritması görüntü üzerinde matematiksel yöntemlere göre niceliksel ve niteliksel kıyası yapıldığında gözle görülür iyileşmeler sağlayarak, DBT görüntülerinin tanısal doğruluğunu ve güvenilirliğini artırır. Denetimsiz yapay sinir ağlarının sahip oldukları birçok kısıta rağmen önerilen görüntüler üzerindeki gürültülere karşı esnek bir yaklaşım sergileyen ağ, farklı medikal görüntüleme yöntemlerine de uygulanabilir. Klinisyenler, mühendisler ve veri bilimcileri arasında devam eden araştırma-geliştirme iş birliği sayesinde görüntüleme tekniklerinin geliştirilmesini ve uygulanabilirliğinin artmasını sağlayarak hastalıkların erken, doğru ve verimli bir şekilde tespit edildiği bir geleceğin önünü açacaktır.



KAYNAKÇA

- [1] **Cleveland Clinic**, Breast Anatomy, 26/08/2023, <https://my.clevelandclinic.org/health/articles/8330-breast-anatomy>
- [2] **National Cancer Institute**, Breast Cancer, 26/08/2023, <https://www.cancer.gov/>.
- [3] **Türkiye Halk Sağlığı Genel Müdürlüğü, Kanser Daire Başkanlığı**, Meme Kanseri, 26/08/2023, <https://hsgmdestek.saglik.gov.tr/>
- [4] **Köksal, N. G. (2022)**. Meme Kanserinde Tarama Ve Erken Tanı. Doğu Karadeniz Sağlık Bilimleri Dergisi, 1(2), 50-56.
- [5] **Aruleba, K., Obaido, G., Ogbuokiri, B., Fadaka, A. O., Klein, A., Adekiya, T. A., & Aruleba, R. T. (2020)**. Applications of computational methods in biomedical breast cancer imaging diagnostics: a review. Journal of Imaging, 6(10), 105.
- [6] **Vedantham, S., Karellas, A., Vijayaraghavan, G. R., & Kopans, D. B. (2015)**. Digital breast tomosynthesis: state of the art. Radiology, 277(3), 663-684.
- [7] **Luisier, F., Blu, T., & Unser, M. (2010)**. Image denoising in mixed Poisson–Gaussian noise. IEEE Transactions on image processing, 20(3), 696-708.
- [8] **Rudin, L.I., Osher, S. and Fatemi, E. (1992)**. Nonlinear total variation based noise removal algorithms, Physica D: Nonlinear Phenomena, 60(1), 259–268.
- [9] **Buades, A., Coll, B. and Morel, J.M. (2005)**. A non-local algorithm for image denoising, 2005 IEEE Computer Society Conference on ComputerVision.
- [10] **Dabov, K., Foi, A., Katkovnik, V. and Egiazarian, K. (2007)**. Image Denoising by Sparse 3-D Transform-Domain Collaborative Filtering, IEEE Transactions on Image Processing, 16(8), 2080–2095.
- [11] **Jin, K.H., McCann, M.T., Froustey, E. and Unser, M. (2017)**. Deep Convolutional Neural Network for Inverse Problems in Imaging, IEEE Transactions on Image Processing, 26(9), 4509–4522.
- [12] **Chen, H., Zhang, Y., Kalra, M.K., Lin, F., Chen, Y., Liao, P., Zhou, J. and Wang, G. (2017)**. Low-Dose CT With a Residual Encoder-Decoder Convolutional Neural Network, IEEE Transactions on Medical Imaging, 36(12), 2524–2535.
- [13] **Liu, Z., Bicer, T., Kettimuthu, R., Gursoy, D., Carlo, F.D. and Foster, I. (2020)**. TomoGAN: low-dose synchrotron x-ray tomography with generative adversarial networks: discussion, J. Opt. Soc. Am. A, 37(3), 422–434, <http://josaa.osa.org/abstract.cfm?URI=josaa-37-3-422>

- [14] **Yang, Q., Yan, P., Zhang, Y., Yu, H., Shi, Y., Mou, X., Kalra, M.K., Zhang, Y., Sun, L. and Wang, G.** (2018). Low-Dose CT Image Denoising Using a Generative Adversarial Network With Wasserstein Distance and Perceptual Loss, *IEEE Transactions on Medical Imaging*, 37(6), 1348–1357.
- [15] **Nair, V., Hinton, G. E.** (2010). Rectified linear units improve restricted boltzmann machines, 27th international conference on machine learning, Haziran 2010, Haifa, Israel, 807–814.
- [16] **Krizhevsky, A., Sutskever, I., Hinton, G. E.** (2012). Imagenet classification with deep convolutional neural networks, *Advances, Neural Information Processing Systems*, Kasım 2012, NY United States, 1097–1105.
- [17] **Zhang, K., Zuo, W., Zhang, L.** (2018): FFDNet: toward a fast and flexible solution for CNN based image denoising. *IEEE Trans. Image Process.*
- [18] **Elhoseny, M., & Shankar, K.** (2019). Optimal Bilateral Filter and Convolutional Neural Network based Denoising Method of Medical Image Measurements. *Measurement*.2019.04.072
- [19] **Tian, C., Xu, Y., Fei, L., Wang, J., Wen, J., Luo, N.** (2019). Enhanced cnn for image denoising, *CAAI Transactions on Intelligence Technology*, 4(1), 17–23.
- [20] **Yan, R., Liu, Y., Liu, Y., Wang, L., Zhao, R., Bai, Y., & Gui, Z.** (2023). Image denoising for low-dose CT via convolutional dictionary learning and neural network. *IEEE Transactions on Computational Imaging*, 9, 83-93.
- [21] **Gao, M., Fessler, J. A., & Chan, H. P.** (2021). Deep convolutional neural Network with adversarial training for denoising digital breast tomosynthesis images. *IEEE transactions on medical imaging*, 40(7), 1805-1816.
- [22] **Eckert, D., Ritschl, L., Herbst, M., Wicklein, J., Vesal, S., Kappler, S., ... & Stober, S.** (2022). Deep learning based denoising of mammographic x-ray images: an investigation of loss functions and their detail-preserving properties. In *Medical Imaging 2022: Physics of Medical Imaging* (Vol. 12031, pp. 455-462). SPIE.
- [23] **Kim, H.-J., & Lee, D.** (2020). Image denoising with conditional generative adversarial networks (CGAN) in low dose chest images. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 954, 161914. doi:10.1016/j.nima.2019.02.041
- [24] **Lehtinen, J., Munkberg, J., Hasselgren, J., Laine, S., Karras, T., Aittala, M. and Aila, T.** (2018). Noise2Noise: Learning Image Restoration without Clean Data, *Proceedings of the 35th International Conference on Machine Learning, ICML 2018, Stockholmsmässan, Stockholm, Sweden, July 10-15, 2018*, volume 80 of *Proceedings of Machine Learning Research*, PMLR, pp.2971–2980, <http://proceedings.mlr.press/v80/lehtinen18a.html>.

- [25] **Batson, J. and Royer, L. (2019)**. Noise2Self: Blind Denoising by Self-Supervision, Proceedings of the 36th International Conference on Machine Learning, ICML 2019, 9-15 June 2019, Long Beach, California, USA, volume 97, PMLR, pp.524–533, <http://proceedings.mlr.press/v97/batson19a.html>
- [26] **Krull, A., Buchholz, T., Jug, F. (2019)**. Noise2void - learning denoising from single noisy images, CVPR, arXiv:1811.10980.
- [27] **Huang, T., Li, S., Jia, X., Lu, H., & Liu, J. (2021)**. Neighbor2neighbor: Self-supervised denoising from single noisy images. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 14781-14790).
- [28] **Buda, M., Saha, A., Walsh, R., Ghate, S., Li, N., Świącicki, A., ... & Mazurowski, M. A. (2021)**. A data set and deep learning algorithm for the detection of masses and architectural distortions in digital breast tomosynthesis images. *JAMA network open*, 4(8), e2119100-e2119100.
- [29] **Sarno, A., Mettivier, G., di Franco, F., Varallo, A., Bliznakova, K., Hernandez, A. M., ... & Russo, P. (2021)**. Dataset of patient-derived digital breast phantoms for in silico studies in breast computed tomography, digital breast tomosynthesis, and digital mammography. *Medical Physics*, 48(5), 2682-2693.
- [30] **Kingma, D.P. and Ba, J. (2015)**. Adam: A Method for Stochastic Optimization, 3rd International Conference on Learning Representations, ICLR 2015, San Diego, CA, USA, May 7-9, 2015, Conference Track Proceedings, <http://arxiv.org/abs/1412.6980>.
- [31] **Adam Paszke, Sam Gross, Francisco Massa, Adam Lerer, James Bradbury, Gregory Chanan, Trevor Killeen, Zeming Lin, Natalia Gimelshein, Luca Antiga, et al.** Pytorch: An imperative style, high-performance deep learning library. In *Advances in Neural Information Processing Systems*, pages 8026–8037, 2019.



ÖZGEÇMİŞ

Ad-Soyad : Osman Alpcan ÖZCAN

ÖĞRENİM DURUMU:

- **Lisans** : 2020, Fatih Sultan Mehmet Vakıf Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği
- **Yüksek lisans** : 2023, İstanbul Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Elektronik ve Haberleşme Mühendisliği Anabilim Dalı, Biyomedikal Mühendisliği Programı

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2022 yılından beri Koç Medikal Bıçakçılar Tıbbi Cihaz San. ve Tic. AŞ'de ARGE Mühendisi olarak çalışıyor.
- 2020 yılında Portable Vein Imaging Device Operating with Hyperspectral Imaging Technique projesi ile “TUBİTAK 2242 Üniversitesi Öğrencileri Araştırma Projeleri Yarışması İstanbul-Asya Bölge Birincisi” ödülü kazandı.

YÜKSEK LİSANS TEZİNDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Ozcan O.**, Ertas M., Yıldırım İ., 2023. Unsupervised Denoising Of Digital Breast Tomosynthesis Images Using Deep Learning IGRS'23- 2nd International Graduate Research Symposium, 16-18 May 2023, İstanbul – Turkey

DİĞER YAYINLAR, SUNUMLAR VE PATENTLER:

- Ozkan, H., Aydın, M., **Ozcan, O. A.**, & Zengin, U. (2023). A portable multispectral vein imaging system. *Journal of Electrical Engineering*,74(1), 64-69.
- **Ozcan, O. A.**, Hammouda, M., Aslan, M., (2022). *Bir İdrar Ölçme Tertibatı ve Bir Bağlantı Aparatı*. Türk Patent 2022/020467. Erişim adresi: turkpatent.gov.tr
- Metin, M., **Ozcan, O. A.**, Cıldan, Y., (2023). *Ameliyat Masaları İçin Aksesuar Tanımlama Sistemi, Buna Uygun Ameliyat Masası ve Aksesuarlar*. Türk Patent 2023/004125. Erişim adresi: turkpatent.gov.tr