

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

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

YÜKSEK LİSANS TEZİ

Müberra AYDIN

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 BULANIKLIĞIN GİDERİLMESİ**

YÜKSEK LİSANS TEZİ

**Müberra AYDIN
(504201409)**

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği Programı

Tez Danışmanı: Doç. Dr. İsa YILDIRIM

EYLÜL 2023

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

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



M.Sc. THESIS

**Müberra AYDIN
(504201409)**

Department of Electronics and Communication Engineering

Biomedical Engineering Programme

Thesis Advisor: Assoc. Prof. Dr. İsa YILDIRIM

SEPTEMBER 2023

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 504201409 numaralı Yüksek Lisans Öğrencisi Müberra AYDIN, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “DENETİMSİZ DERİN ÖĞRENME İLE DİJİTAL MEME TOMOSENTEZİ GÖRÜNTÜLERİNDE BULANIKLIĞIN 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 Biyomedikal Mühendisliği Programı yüksek lisans derecem için yazılmıştır. Yürütülen bu çalışmada, dijital meme tomosentezi görüntülerindeki bulanıklık artefaktlarının azaltılması için denetimsiz derin öğrenme algoritması tasarlanmıştır. Tezde önerilen yöntem, temel gerçek görüntülere ulaşmanın zor olduğu dijital meme tomosentez görüntülerindeki bulanıklık giderme işleminin başarı ile sonuçlandırılmasıyla literatüre önemli bir katkı sağlamıştır.

Bilimsel araştırmanın ve öğrenmenin bir süreç olduğunu gösteren bu çalışma boyunca sağladığı kıymetli destek ve katkıları için danışman hocam Doç. Dr. İsa Yıldırım'a, toplantılarımızdaki değerli katkıları için Dr. Metin Ertaş'a ve lisanstan bu yana akademik yolculuğumuzu paylaştığımız değerli dostum Osman Alpcan Özcan'a teşekkürlerimi sunarım. Bu sürecin bir parçası olmaktan gurur duyuyorum ve bu çalışmayı gelecekteki biyomedikal mühendisleri için bir ilham kaynağı olarak görmeyi umuyorum.

Eylül 2023

Müberra Aydın
(Araştırma Görevlisi)

İÇİNDEKİLER

Sayfa

ÖNSÖZ	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SEMBOLLER	xv
ÇİZELGE LİSTESİ	xvii
ŞEKİL LİSTESİ	xix
ÖZET	xxi
SUMMARY	xxiii
1. GİRİŞ	1
1.1 Problem Tanımı	1
1.2 Tezin Amacı	1
1.3 Literatür Araştırması	2
2. METOT	5
2.1 Denetimsiz Öğrenme İle Bulanıklığın Giderilmesi	5
2.1.1 Üretken Çekişmeli Ağlar (GANs)	5
2.1.2 Otokodlayıcı (AE)	7
3. UYGULAMA	9
3.1 Veri Seti	9
3.2 Model Mimarisi ve Eğitim	10
3.3 Bulgular	12
4. TARTIŞMA	19
5. SONUÇ VE ÖNERİLER	21
KAYNAKLAR	23
ÖZGEÇMİŞ	27



KISALTMALAR

2B	: 2 Boyutlu
3B	: 3 Boyutlu
AE	: Otokodlayıcı (Autoencoder)
BSC-DBT	: Meme Kanseri Taraması-Dijital Meme Tomosentezi (Breast Cancer Screening-Digital Breast Tomosynthesis)
BT	: Bilgisayarlı Tomografi
CNN	: Evrişimsel Sinir Ağı (Convolutional Neural Network)
CNR	: Kontrast Gürültü Oranı (Contrast to Noise Ratio)
DBT	: Dijital Meme Tomosentezi (Digital Breast Tomosynthesis)
DNN	: Derin Sinir Ağı (Deep Neural Network)
DRCNN	: Derin Kalıntı Evrişimsel Sinir Ağı (Deep Residual Convolutional Neural Network)
FDK	: Feldkamp, Davis ve Kress
GANs	: Üretken Çekişmeli Ağlar (Generative Adversarial Networks)
GRNN	: Genel Regresyon Sinir Ağı (General Regression Neural Network)
MSE	: Ortalama Karese Hata (Mean Squared Error)
PSNR	: Tepe Sinyal Gürültü Oranı (Peak Signal to Noise Ratio)
SRCNN	: Süper Çözünürlük Evrişimsel Sinir Ağı (Super-Resolution Convolutional Neural Network)
SSIM	: Yapısal Benzerlik İndeks Ölçüsü (Structural Similarity Index Measure)
TV	: Total Varyasyon (Total Variation)
VAE	: Varyasyonel Otokodlayıcı (Variational Autoencoder)
CLAHE	: Kontrast Sınırlı Uyarlamalı Histogram Eşitleme (Contrast Limited Adaptive Histogram Equalization)



SEMBOLLER

σ : Standart Sapma

μ : Ortalama





ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1: Şekil 3.3'te verilen görüntülere ait CNR değerleri.....	13
Çizelge 3.2: Şekil 3.3'te verilen görüntülere ait MAE değerleri.....	14
Çizelge 3.3: Şekil 3.3'te verilen görüntülere ait SSIM değerleri.	15
Çizelge 3.4: Şekil 3.5'te verilen görüntülerin orijinal görüntülerle SSIM değerlendirmesi.....	16



ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 2.1 : Üretken çekişmeli ağ yapısı.	6
Şekil 2.2 : Otokodlayıcı yapısı.	7
Şekil 2.3 : MNIST veri setinden orjinal görüntüler (a), VAE ile üretilen görüntüler (b) [16].	8
Şekil 3.1 : Eğitim veri setine uygulanan Gaussian bulanıklık parametreleri (kernel boyutu ve sigma değeri) ve görüntü sayıları.	9
Şekil 3.2 : Bu çalışmada önerilen denetimsiz derin öğrenme modelinin yapısı.	10
Şekil 3.3 : Önerilen modelin otokodlayıcı kısmına ait model mimarisi.	11
Şekil 3.4 : BSC-DBT veri setinden örnekler.	13
Şekil 3.5 : Uzman radyolog tarafından incelenen görüntüler.	15
Şekil 3.6 : GAN+AE modeli (A), GAN modeli (B) ve AE modeli (C) çıktıları.	17



DENETİMSİZ DERİN ÖĞRENME İLE DİJİTAL MEME TOMOSENTEZ GÖRÜNTÜLERİNDE BULANIKLIĞIN GİDERİLMESİ

ÖZET

Her yıl binlerce kişinin ölümüne neden olan kanserin teşhisinde, tümörün doğru lokalizasyonu tedavi süreci için hayati önem taşımaktadır. Hastalığın erken teşhisi, kanserli dokunun büyümesini ve daha fazla dokuya yayılmasını önlemek için çok önemlidir. Tıbbi görüntüleme teknikleri, kanserin erken teşhisine önemli katkı sağlamaktadır. Kadınlarda kansere bağlı ölüm oranlarında en yüksek paya sahip olan meme kanserinin erken teşhisinde de görüntüleme teknolojilerinden yararlanılmaktadır. Özellikle 40 yaş üstü kadınların kendilerini kontrol etmeleri ve ailelerindeki kanser öyküsüne bağlı olarak düzenli taramalardan geçmeleri önerilmektedir. Bu tarama işlemlerinde yaygın olarak mamografi kullanılmakla birlikte, dijital meme tomosentezi (DBT) kullanımı da giderek yaygınlaşmaktadır.

Mamografi iki boyutlu (2B) görüntüler oluştururken, DBT üç boyutlu (3B) görüntüler oluşturur. DBT, mamografide üst üste binme nedeniyle gizli kalmış lezyonların teşhisini mümkün kılmaktadır. Ayrıca taramanın farklı açılarda yapılması, oluşturulan görüntülerle yanlış pozitif oranlarını azaltılmasını sağlamaktadır. Taramaların sınırlı açılarla gerçekleştirilmesi, önlenemeyen hasta hareketleri ve dedektör odaklama aşamasındaki aksaklıklar DBT görüntülerinde bulanıklık artefaktlarına neden olabilmektedir. Bulanıklık etkisi, görüntü kalitesini gözle görülür şekilde düşürerek uzmanın görüntüdeki anormallikleri fark etme olasılığının da düşmesine sebep olmaktadır. Bahsi geçen dezavantajların azaltılması için, farklı modalitelerde çeşitli görüntü restorasyon teknikleri uygulanmaktadır.

Bu çalışmada, DBT görüntülerinde tanısal doğruluğu azaltan bulanıklık etkisinin önüne geçebilmek için bir derin öğrenme modeli önerilmektedir. Temel gerçek görüntülere erişimin mevcut olmaması veya zor bulunması nedeniyle, model denetimsiz olarak tasarlanmıştır. Önerilen modelin eğitimi için kanser görüntüleme arşivinden alınan ve 5060 hastaya ait normal, işlem yapılabilir, biyopsi ile kanıtlanmış iyi huylu ve biyopsi ile kanıtlanmış kanser olarak etiketlenmiş görüntüleri içeren Meme Kanseri Taraması-Dijital Meme Tomosentezi (BSC-DBT) veri seti kullanılmaktadır. İşlemci kapasitesinin az olması ve dicom görüntülerin saklanması için çok fazla bellek gerekmesinden ötürü görüntüler png uzantılı olarak kaydedilmektedir. Biçimleri değiştirilen görüntüler ilk olarak kontrast uyarlamalı adaptif histogram eşitleme (CLAHE) ve yeniden boyutlandırma işlemlerini içeren bir ön işleme sürecine tabi tutulmaktadır. Veri setinden seçilen 2600 görüntü eğitim verisi, 350 görüntü validasyon verisi ve 260 görüntü ise test verisi olarak ayrılmıştır. Seçilen verilere farklı seviyelerde kernel boyutları ve sigma değerleri ile Gaussian bulanıklık filtreleri uygulanmıştır.

AE (Autoencoder) ve GANs (Generative Adversarial Networks) modellerinin art arda kullanılması ile tasarlanan bu model 2B konvolüsyon, batch normalizasyon, LeakyReLU aktivasyonu, MaxPool ve Dropout katmanlarını içermektedir. Tasarlanan

model, bulanık görüntüyü temel alarak orijinal görüntüyü yeniden oluşturmayı amaçlar. Bulanık görüntü, gerçek dünya uygulamalarında yaygın olarak bulunan düşük kaliteli veya bozulmuş görüntülerin modellenmesi amacıyla kullanılmaktadır.

Önerilen modelin başarısı kontrast-gürültü oranı (CNR), ortalama mutlak hata (MAE) ve yapısal benzerlik indeksi (SSIM) ve uzman radyolog tarafından yapılan yorumlar ile değerlendirilmiştir. Nicel değerlendirmeler sonucunda bulanıklıktan arındırılan görüntülerin, bulanık görüntülere kıyasla orijinal görüntülere daha benzer olduğunu ortaya koymaktadır. Hem nicel sonuçlar hem de nitel değerlendirmeler, önerilen modelin DBT görüntülerindeki bulanıklaştırma artefaktlarını ele almada oldukça umut verici olduğunu ve bunun da teşhis doğruluğunu artırmasının beklenebileceğini göstermektedir.



UNSUPERVISED DEBLURRING OF DIGITAL BREAST TOMOSYNTHESIS IMAGES USING DEEP LEARNING

SUMMARY

In the diagnosis of cancer, which causes thousands of deaths every year, the correct localization of the tumor is vital for the treatment process. Early diagnosis of the disease is crucial to prevent the cancerous tissue from growing and spreading to more tissues. Medical imaging techniques contribute significantly to the early diagnosis of cancer. Imaging technologies are also utilized in the early diagnosis of breast cancer, which has the highest share in cancer-related mortality rates in women. Especially women over the age of 40 are advised to check themselves and undergo regular screening, depending on their family history of cancer. Although mammography is commonly used in these screening procedures, the use of digital breast tomosynthesis (DBT) is also becoming increasingly common. While mammography creates two-dimensional (2D) images, DBT creates three-dimensional (3D) images. Lesions that are hidden in mammography due to overlapping tissues are more likely to be diagnosed with DBT. Considering the amount of radiation the patient is exposed to, DBT is also less harmful than mammography. In addition, performing scans from different angles helps to reduce false positive rates with the images created. However, the limited angles of the scans, inevitable patient movements and detector defects in the focusing stage can lead to blurring artifacts in DBT images. The blurring effect significantly degrades image quality and makes it less likely for experts to detect abnormalities in the image. To mitigate these drawbacks, various image restoration techniques have been applied using different modalities as an alternative to conventional methods. Furthermore, using machine learning or deep learning algorithms, blurring can be effectively reduced, thus achieving faster and more efficient results.

Since DBT is a newly developing technology, its use has not yet become widespread. For this reason, there are problems in obtaining data or accessing a ready data set. Due to the limitations in DBT datasets and the ongoing development of the imaging methods, obtaining ground truth images is challenging. In the face of this challenge, proposing an unsupervised method is essential to achieve the most effective results with the available data. The proposed model aims to reduce blurriness in DBT images, thereby increasing diagnostic accuracy and preventing false diagnoses, ultimately reducing female deaths from breast cancer. The Breast Cancer Screening-Digital Breast Tomosynthesis (BSC-DBT) dataset, which contains DICOM images labeled as normal, actionable, benign with biopsy-proven, and cancer with biopsy-proven from 5060 patients, obtained from a cancer imaging archive, is used for model training. The dataset does not contain the projections of the images, only the reconstructed DICOM images, which requires a very high memory usage for storage. Due to low processor capacity and the need for significant memory for storing DICOM images, the images are saved in PNG format. In addition, the images are pre-processed by first adjusting their dimensions to 256x256 to match the model's input requirements and then

applying contrast-adaptive histogram equalization (CLAHE). CLAHE is used because the images in the dataset need contrast enhancement. In real life, the blurs in the images will not be at the same levels, so in order to increase the success of the model at different blur levels, Gaussian blur filters with different kernel sizes and sigma values were applied to the selected data to create data sets. Experiments have shown that the closest to ideal blur is obtained with kernel size (5.5) and a sigma value of 0.4, so the images are randomly blurred with a kernel size of 5.5 for 70% and a sigma value of 0.4 for 50%. The remaining blurs were distributed between kernel sizes (3,3), (7,7) and values 0.2, 0.6, 0.8, 0.9 and 1.

GAN, which consists of two models: generative and discriminative, and AE, which consists of encoder and decoder networks, have been widely used for unsupervised de-blurring of real-world images. By using AE (Autoencoder) and GANs (Generative Adversarial Networks) models sequentially, an unsupervised learning model including 2D convolution, batch normalization, LeakyReLU activation, MaxPool and Dropout layers is created. The designed model aims to reconstruct the original image based on the blurred image. Blurred images are widely used to model low quality or distorted images, which are common in real world applications. In the proposed model, the encoder block transforms the images into a high-dimensional feature space containing their attributes, and then the high-dimensional feature space passes into a bottleneck, where dimension reduction is performed. In the decoder block, the features compressed in the bottleneck are reconstructed back to their original size and given as input to the model. The generator is used by the decoder to enhance the reconstructed image and transmits the output to the discriminative block. The generator block output to the discriminator block is compared with the blurred image that is the input of the model. According to the result of the comparison process, this comparison continues until the difference between them is minimized. Experiments were conducted using different epoch, chunk size and learning rate parameters in the training process. The best result, i.e. the lowest loss value, was obtained with a chunk size of 6, a learning rate of 2×10^{-5} and 32 epochs. The mean squared error (MSE) was used as the loss function to train the model.

The success of the proposed model was evaluated using contrast-to-noise ratio (CNR), mean absolute error (MAE), structural similarity index measure (SSIM) and qualitative evaluations performed by specialist radiologists. In image enhancement studies, especially in denoising processes, it is observed that increasing the CNR value improves image quality. Moreover, the CNR values in the result images obtained with the proposed model are higher in blurred images. Since the pixel intensity values of the selected ROI (Region of Interest) and background in breast images are distributed in a narrow range, the results cannot be compared with images other than breast images. Therefore, CNR values for the original image and the blurred image were normalized by comparing them. These ratios were observed for 160 breast images in the test set. Based on these results, it was observed that the application of the proposed method to blurred images led to images that closely resemble the original. Second evaluation criterion was the calculation of the MAE between the blurred and de-blurred images compared to the original image. MAE, commonly used in image quality assessment, is defined as the average of the absolute differences between two different data sets. As the MAE value increases, the similarity between two images decreases, indicating that the resulting image differs from the original image. Another image quality measurement metric, SSIM, which is used when the similarity between two images is to be measured, takes values between 0 and 1. As SSIM approaches 1,

it shows that the similarity between the images increases; as it approaches 0, it shows that the differences between the images increase. The results obtained from the evaluations are mostly higher than 0.94. This result shows how small the difference between the original, blurred and deblurred images is. According to the SSIM results, the similarity between the original and deblurred images is relatively higher than the original and blurred images. Both quantitative and qualitative evaluations show that the proposed model is promising in addressing blurring artifacts in DBT images and is expected to improve diagnostic accuracy.





1. GİRİŞ

1.1 Problem Tanımı

Kadınlarda kansere bağlı her 6 ölümden 1'ini oluşturan meme kanseri, Dünya Sağlık Örgütü'ne göre 2020 yılında yaklaşık 685000 kadının ölümüne sebep olmuştur [1]. 2 boyutlu mamografi ve 3 boyutlu dijital meme tomosentezi (DBT) yöntemleri, hekimler tarafından meme kanserinin erken teşhis edilmesinde sıklıkla kullanılmaktadır. DBT, görüntüleri farklı açılarla alınmış birden çok görüntüden oluşturduğu için mamografiye göre doku arasında gizli kalan lezyonların tespitini daha mümkün kılmaktadır. DBT görüntülerinde tarama açılarındaki kısıtlama, dedektör ve odak kayması veya hasta hareketi gibi etkenler sonucunda görüntülerde bulanıklık oluşabilmektedir. Bu bulanıklık görüntüdeki detayların kaybolmasına sebep olurken teşhislerdeki doğruluğu azaltmaktadır. Bu sebeple DBT görüntülerindeki bulanıklığın giderilmesi teşhis doğruluğunun artırılabilmesi için önem arz etmektedir. Bulanıklığın giderilmesi için yinelemeli geri çatma, hareket düzeltme algoritmaları, görüntü eldesindeki parametrelerde ince ayarlar yapılması ya da görüntü elde edildikten sonra uygulanabilecek görüntü işleme süreçleri gibi geleneksel yöntemlerle bulanıklık giderilebilmektedir. Bu geleneksel yöntemlere alternatif olarak derin öğrenme algoritmaları ile daha hızlı ve etkin bir biçimde bulanıklık giderilebilir.

1.2 Tezin Amacı

DBT veri setlerindeki yetersizlik ve görüntüleme yönteminin gelişmekte olması sebebiyle temel gerçek görüntülere ulaşmanın zor olduğu bir gerçektir. Bu zorluk karşısında denetimsiz bir yöntem önerilmesi eldeki verilerle en etkili sonuca ulaşılması için oldukça önemlidir. Önerilen derin öğrenme algoritması ile DBT görüntülerindeki bulanıklık azaltılmış olup teşhis doğruluk oranının artırılması ile yanlış teşhislerin önüne geçilerek meme kanserine bağlı kadın ölümlerinin düşmesi hedeflenmiştir.

1.3 Literatür Araştırması

Görüntülerin bulanıklıktan arındırılmasına dair birçok derin öğrenme algoritması geliştirilmiştir. Bunların çoğunluğu doğal görüntüler için eğitilmiş olup bir kısmı ise medikal görüntüler üzerinde denenmiştir. Ancak DBT özelinde denetimsiz derin öğrenme ile bulanıklık giderme çalışmaları bulunmamaktadır.

Choi Y. ve arkadaşları yapmış oldukları çalışmada [2] DBT görüntülerinin kamera hareketinden kaynaklanan bulanıklık etkisinden arındırılması için bulanıklık ve gürültü kaldırma kısımları bulunan bir derin kalıntı evrişimsel sinir ağı (DRCNN) tasarlamışlardır. Xing Gong ve arkadaşlarının önermiş oldukları yöntem [3] ile bilgisayar ortamında simüle ettikleri DBT görüntülerini, ortalama karesel hata (MSE), tepe sinyal-gürültü oranı (PSNR) parametreleri ile değerlendirilmiş ve değerlendirme sonucunda bulanıklığın azaldığını, görüntü kalitesinin geliştiği göstermişlerdir.

Choi Y. ve arkadaşları 2022 yılında yapmış oldukları bir diğer çalışmada [4] aksiyal, koronal ve sagittal düzlemler boyunca etkili olan bulanıklığın etkisini azaltabilmek için ilki 3 boyutlu bulanıklık giderici ikincisi 2 boyutlu bulanıklık giderici olmak üzere model-istifleme (model-stacking) yaklaşımını baz alan iki aşamalı bir evrişimsel sinir ağı önermiştir. Önerdikleri modelin bulanıklaştırma yeteneğini test etmek için piksel tabanlı, çekişme tabanlı ve algı tabanlı kayıp fonksiyonlarını kullanmışlardır. Eğitim sonrasında test görüntüleri ile yapmış oldukları değerlendirmede ortalama kare ve kök ortalama kare hataları azalırken kontrast-gürültü oranının arttığını, sonuç olarak bulanıklaşma etkilerinin azaldığını ve lezyon tespiti performansının iyileştiğini göstermişlerdir. Ayrıca sonuç kısmında çalışmada önerilen yöntem, Feldkamp, Davis ve Kress (FDK) ve Total Varyasyon (TV) Yinelemeli Geri Çatma gibi geleneksel yöntemler ve bir önceki çalışmaları olan DRCNN [2] modeli kıyaslanmıştır.

Ruomei Yan ve arkadaşları yapmış oldukları çalışmada [5] her görüntüdeki bulanıklığın farklı seviyede olabileceğinin altını çizerek bulanıklığı gidermeden önce bulanıklık seviyesini tespit edip ardından bulanıklık azaltma işlemini bu seviyeye göre uyarlayıp gerçekleştirmektedirler. Önceden eğitilmiş bir derin sinir ağı (DNN) ve genel regresyon sinir ağının (GRNN) kombinasyonu ile önerdikleri bu model DNN'in sınıflandırma; GRNN'in ise regresyon yetenekleri ile bulanıklık kaldırma sürecini görüntülere uygulamaktadır. Burada kullanılan görüntüler medikal değildir ve medikal görüntülere kıyasla çok daha fazla detaya sahiptirler. Bir dizi gerçek fotoğrafta

uyguladıkları yöntem sonucunda sıradan olmayan bulanıklığın önceki tekniklere kıyasla daha başarılı olduğunu göstermişlerdir.

Chao Dong ve arkadaşları [6] düşük çözünürlüklü görüntüyü girdi yüksek çözünürlüklü olanı ise çıktı olarak vererek uçtan uca öğrenme yöntemini kullanan tek görüntü süper çözünürlüğü için Süper-Çözünürlük Evrimsel Sinir Ağı (SRCNN) isimli bir derin öğrenme yöntemi önermişlerdir. Önerdikleri bu yöntem ile çalışmayı yaptıkları o dönemki popüler yöntemlere kıyasla daha iyi PSNR ve yapısal benzerlik indeks ölçüsü (SSIM) sonuçları elde etmiş ve geleneksel yöntemlere kıyasla kenar bulanıklıklarının üstesinden geldiklerini göstermişlerdir.

Boyu Lu ve arkadaşları [7] görüntünün içerik ve bulanıklık özelliklerinin ayrıştırılmasını sağlayan bir denetimsiz model önermişlerdir. Ayrıştırılan bulanıklık özelliğinin dağılımını nispeten az içerik bilgisi içerecek şekilde düzenleyerek farklı kayıp fonksiyonları ile eğitim süreçlerini tamamlamışlardır. Deneylerini yüz ve metin görüntüleri ile test etmiş ve amaçlarına ulaştıklarını PSNR ve SSIM metrikleri ile elde ettikleri sonuçlarla göstermişlerdir. Önerdikleri yöntem tez aşamasında DBT görüntüleri ile de denenmiş olup etkili sonuçların medikal görüntüler için elde edilemeyeceği görülmüştür.

Bingnan Wang ve arkadaşları [8] yüz görüntülerinin bulanıklıktan arındırılmasına dair gerçekleştirdikleri araştırma çalışmasında yüz görüntülerindeki bulanıklığın arındırılmasında genel yöntemlerin yetersiz olduğunu, bu sebeple derin öğrenme odaklı çözümleri incelemişlerdir. İncelemeler ilk olarak model tabanlı ardından derin öğrenme tabanlı yöntemler olarak yapılmıştır. Derin öğrenme tabanlı yöntemler kendi içinde denetimli ve denetimsiz yöntemler olarak incelenmiştir. Yapılan araştırmaya göre konvolüsyon blokları, çok ölçekli ağlar [9], üretici çekişmeli ağlar [10], ResNet, bir kodlayıcı ile bir kod çözücünden oluşan U-Net [11] ve kademeli ağlar (cascade networks) başta olmak üzere birçok derin öğrenme ağ yapısı bulanıklık gidermek için kullanılmaktadır. Birden fazla ağın birleştirilmesi ile oluşan kademeli ağlar ile daha kaliteli görüntülerin üretilebilmektedir. Derin öğrenme ağlarındaki performans veri setinin büyüklüğü ile doğru orantılıdır ancak denetimli öğrenmeye uygun olacak şekilde veri çiftlerinden oluşan büyük bir veri setine sahip olmak düşük bir ihtimale sahip olduğundan denetimsiz öğrenme yöntemlerine başvurulmaktadır. Madam NT ve arkadaşlarının önermiş olduğu [12] GAN tabanlı yöntem bulanıklık giderme yönteminde yeniden bulanıklaştırma kaybı ve çok ölçekli gradyan kaybı

eklenmektedir. Bu model ile sentetik veri kümelerinde başarılı sonuçlar elde etseler de bazı gerçek bulanık görüntülerde aynı başarıyı elde edilememektedir.

Düşük dozlu bilgisayarlı tomografi (BT) görüntüleme tekniklerinde görülen radyasyon miktarı ile görüntü kalitesi arasında bir denge sağlamanın sebep olduğu zorluklar BT görüntülerinde bulanıklık ve gürültüye sebep olmaktadır. D. Yim ve arkadaşları, hem gürültü azaltma hem de bulanıklık giderme amacı ile derin evrimsel sinir ağı kullanan bir teknik önermektedirler [13]. DnDbCNN olarak adlandırdıkları ağları ile gürültü giderme ve bulanıklık giderme ağları ayrı ayrı eğitilmiş, daha sonra bu iki ağ arasına bir evrişim katmanı ekleyerek katmanların ağırlıklarını güncelleyerek birleştirilmektedir. Bulanıklık giderme aşamasında, düşük ve yüksek çözünürlüğe sahip görüntüler arasında uçtan uca öğrenme tekniğini kullanan [14], süper çözünürlük evrimsel sinir ağı (SRCNN) kullanılmaktadır. MSE, PSNR, varyasyon katsayısı ve modülasyon transfer fonksiyonu gibi metriklerle BT görüntülerinde DnDbCNN modelinin başarısı gösterilmektedir.

Kaihao Zhang ve arkadaşlarının gerçekçi bulanıklaştırma ile bulanıklığın giderilmesine dair yaptıkları çalışma [15] yapay olarak bulanıklaştırılan görüntülerin gerçek dünya görüntülerindeki bulanıklıklaşma süreci ile yeterince modellenememesi sorununu ele almaktadır. Birisi bulanıklaştıran, diğeri bulanıklığı gideren olmak üzere iki GAN modelinin birleştirilmesi ile tasarlanan yöntem gerçek bulanıklık ile yapay bulanıklık arasındaki farklılığı azaltmak için göreceli bulanıklık kaybını kullanmaktadır. Tasarlanan model gerçek görüntülerden oluşan kendi veri setleri ile ve GoPro veri seti ile başarılı sonuçlar vermektedir.

Michael F. M. Jimenez ve arkadaşlarının yapmış oldukları çalışmada [16] gürültülü ve bulanık görüntüleri iyileştirmek için derin evrimsel otokodlayıcılar incelenmiştir. Street View House Numbers veri seti ile yaptıkları deneylerde modelleri eğitmek için MSE ve Huber fonksiyonlarını kullanan ekip tam bağlantılı çok katmanlı algılayıcıların (MLP) CNN'e göre daha hızlı çalışsa da daha başarısız yeniden yapılandırmalar gerçekleştirdiğini göstermişlerdir. Çalışmada tam bağlantılı MLP ve CNN modelleri ayrı ayrı gözlemlenmiş, ardından CNN yapısı MLP modelinin bağlantılı katmanlarından esinlenerek AE'ye benzeyecek şekilde iki modelin yapısına dayanan CNN-AE modeli önerilmiştir.

2. METOT

Görüntü kalitesini önemli ölçüde etkileyen ve farklı sebeplerden kaynaklanabilen bulanıklıkların giderilmesi için derin öğrenme yöntemlerinin özellikle medikal görüntüler olmak üzere birçok farklı alandaki görüntülere uygulanma şekline dair literatür taraması tezin giriş başlığı altında verilmiştir. Bu kısımda ise dijital meme görüntülerindeki bulanıklığın giderilmesi için tasarlanan denetimsiz derin öğrenme algoritması detaylı bir şekilde açıklanmıştır.

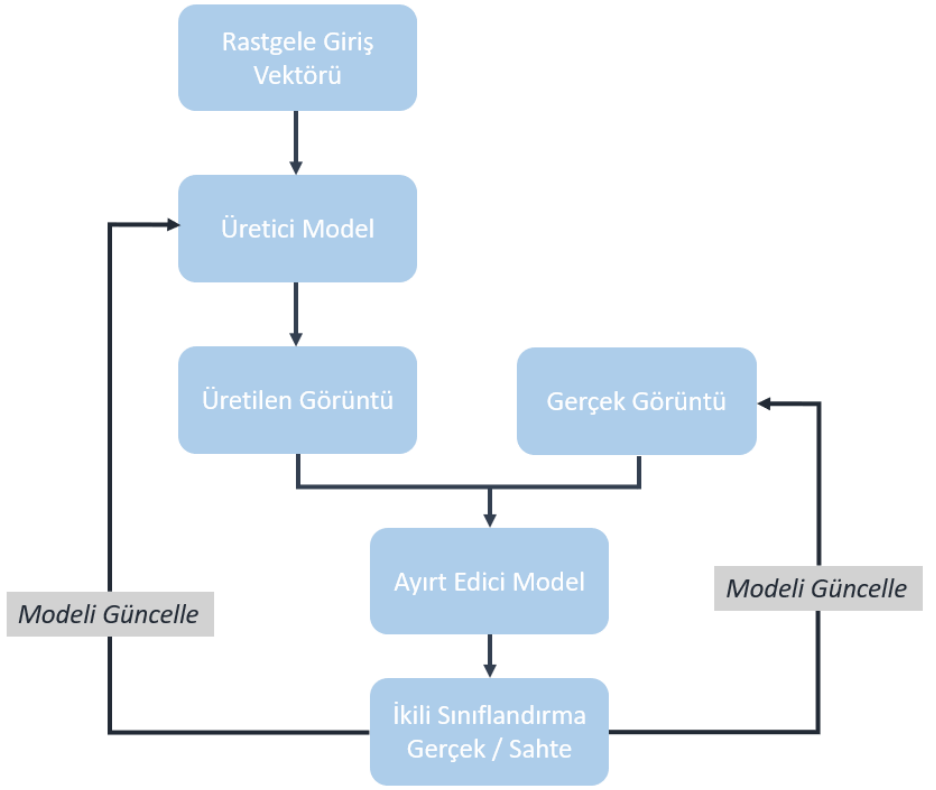
2.1 Denetimsiz Öğrenme İle Bulanıklığın Giderilmesi

Bulanıklık artefaktının etkisinin azaltılması için denetimli ve denetimsiz birçok farklı yöntem kullanılmaktadır. Ancak medikal görüntüleri içeren veri setlerinde temel gerçek görüntüye ulaşmak zor olduğu için önceden etiketlenmiş verilere ihtiyaç duyulmayan denetimsiz öğrenme algoritmaları ile çalışmak daha etkin sonuçlar vermektedir.

2.1.1 Üretken Çekişmeli Ağlar (GANs)

2014 yılında Ian Goodfellow [10] tarafından literatüre sunulan üretken çekişmeli ağlar üretici ve ayırt edici olmak üzere iki ana modelden oluşmaktadır. Gerçekçi veri üretme ve veri artırımı konusunda sıklıkla kullanılan GAN yapısına ait örnek bir akış şeması Şekil 2.1'de gösterilmektedir. Giriş olarak rastgele sayılar alan üretici modeli bir görüntü çıktısı oluştururken, elde edilen bu çıktı ayırt edici model tarafından gerçek görüntü ile kıyaslanarak üretilen görüntünün gerçek veya sahte bir görüntü olup olmadığı değerlendirilmektedir. GANs'lar ayırt edici çıktısı olarak gerçek görüntü için 1; sahte görüntü için 0 olmak üzere 0-1 aralığında değerler vermektedir. Sahte görüntüler gerçek görüntülerle kıyaslanarak gerçek görüntüye en çok benzeyen sahte görüntülerin oluşması beklenmektedir. Burada modelin eğitim sürecindeki epok sayısı, batch boyutu, kayıp fonksiyonu ve öğrenme oranı gibi hiperparametrelerin optimum olarak seçilmesi büyük önem taşımaktadır.

Bu hiperparametrelerin optimum deęerleri alıřılan veri seti, modelin karmařıklıęı ve iřlemci kapasitesi gibi etkenlere gre deęiřiklik gsterebilmektedir.

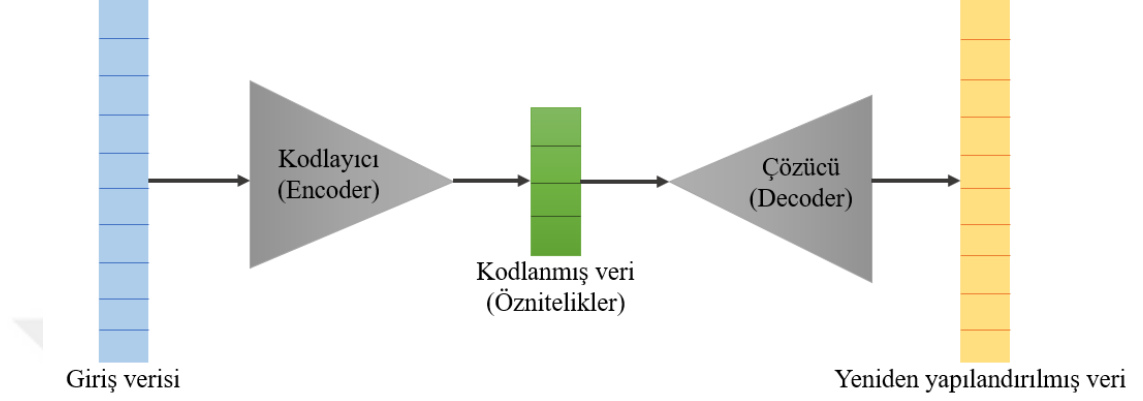


řekil 2.1 : retken ekiřmeli aę yapısı.

Yksek znrlkl grntlerin oluřturulması iin ‘Derin Evriřimsel GAN’ modelleri [17]; dřk znrlkl grntlerden daha yksek znrlęe sahip grntler oluřturulmasını saęlayan ‘Sper znrlk GAN’ modelleri [18]; grntler arasında dnřm yapılabilmesine imkan tanıyan (rn: bir ev kedisi grntsnden leopar grntsnn oluřturulması) ‘Cycle GAN’ modelleri [19]; ya da en basit haliyle bir retici ve bir ayırt ediciden oluřan, her seferde tek bir veri zerinden tm veri kmesini ęrenerek ilerleyen, grntlerin sınıflandırılmasında ya da artırımında kullanılan ‘Vanilya GAN’ modelleri [20] olmak zere farklı GAN yapıları literatrde mevcuttur.

2.1.2 Otokodlayıcı (AE)

Denetimsiz öğrenme yöntemlerinin en başında gelen otokodlayıcılar, kodlayıcı (encoder) ve çözücü (decoder) olarak isimlendirilen iki ana yapıdan oluşmaktadır [21]. Şekil 2.2’de örnek bir otokodlayıcı akış şeması gösterilmektedir.




Şekil 2.2 : Otokodlayıcı yapısı.

Kodlayıcı girdi olarak aldığı etiketlenmemiş verinin özellik çıkarımını yaptıktan sonra elde edilen özellikler çözücüye aktarılır ve çıktı olarak yeniden oluşturulan veri elde edilir. Elde edilen çıktının girdi ile benzer çıkmaması durumunda kayıp fonksiyonu sonucuna göre çıktının yeniden yapılandırılması sağlanmaktadır. Amacı sıkıştırılan verinin minimum kayıp ile yeniden üretilmesi olduğu için AE yapılarının kayıp fonksiyonu çıktı ile girdi arasındaki farka bağlı olarak hesaplanmaktadır. Burada genellikle MSE olarak bilinen, girdi ile çıktı arasındaki farkın karesine bağlı olarak hesaplanan L2 fonksiyonu kayıp fonksiyonu olarak kullanılmaktadır [16].

AE modelleri başlıca öznitelik çıkarımı, boyut azaltma, gürültüden arındırma konularında kullanılsa da bu modellerin bir çeşidi olan Varyasyonel Otokodlayıcılar (VAE) tıpkı GANs gibi yeni veri üretiminde de kullanılmaktadırlar. VAE modellerine girdi olarak görsel veriler gönderildiğinde bu verilere benzer daha yüksek çözünürlüklü verilerin üretildiği yapılan çalışmalarda [21] görülmektedir.

Şekil 2.3 a’da MNIST veri setinden orjinal görüntüler, b’de ise VAE ile üretilen MNIST verileri görülmektedir. Kayıp fonksiyonu olarak MSE’nin kullanıldığı bu VAE modeli ile üretilen görüntülerde bulanıklık söz konusudur. Bulanıklık oluştursa da bu hata fonksiyonu sayesinde model çıktısı kontrol edilebilmektedir. VAE ve GAN

modelleri yeni veri üretimi konusunda birbirlerine alternatif olarak görülmektedir. GAN yapıları içerdiği üretici ve ayırt edici arasındaki rekabete göre kullandığı kayıp fonksiyonu ile eğitildiği için VAE'ye göre daha ilgi çekici görüntüler oluştursa da işlem maliyeti daha yüksek olmaktadır [21]. Ayrıca literatürde her iki modeli içeren yöntemler de yeniden oluşturma problemlerine çözüm olarak kullanılmaktadır [22].

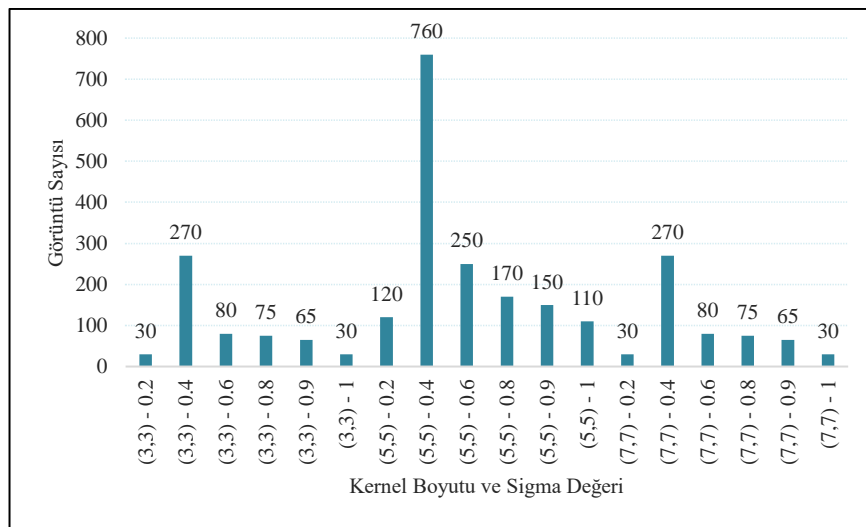


Şekil 2.3 : MNIST veri setinden orjinal görüntüler (sol), VAE ile üretilen görüntüler (sağ) [16].

3. UYGULAMA

3.1 Veri Seti

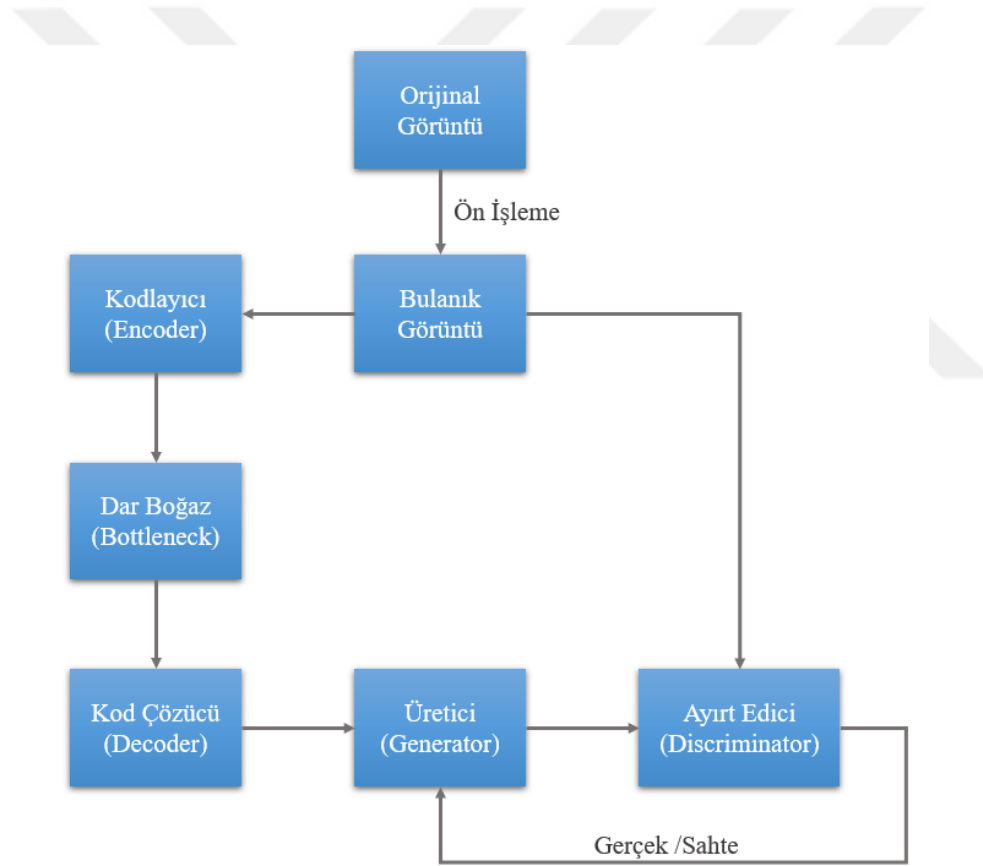
Bu çalışmadaki meme görüntüleri Breast Cancer Screening- Digital Breast Tomosynthesis (BSC-DBT) veri setinden alınmıştır [23]. Veri setinde 5060 hastaya ait normal, işlem yapılabilir, biyopsi ile kanıtlanmış iyi huylu ve biyopsi ile kanıtlanmış kanser olmak üzere 4 grup altında toplanan dicom uzantılı görüntüler bulunmaktadır. İşlemci kapasitesinin az olması ve dicom görüntülerin saklanması için çok fazla bellek gerektiğinden dolayı görüntüler png uzantılı olarak kaydedilmiştir. Biçimleri değiştirilen görüntüler ilk olarak kontrast uyarlamalı adaptif histogram eşitleme (CLAHE) ve yeniden boyutlandırma işlemlerini içeren bir ön işleme sürecine tabi tutulmuştur. Veri setinden seçilen 2600 görüntü eğitim, 350 görüntü validasyon ve 260 görüntü ise test verisi olarak ayrılmıştır. Seçilen verilere Şekil 3.1’de gösterildiği üzere farklı seviyelerde kernel boyutları ve sigma değerleri ile Gaussian bulanıklık filtreleri uygulanmıştır. Yapılan deneyler sonucunda ideale en yakın bulanıklık (5,5) kernel boyutu ve 0.4 sigma değeri ile elde edildiği görülmüş, bu sebeple %70 oranında (5,5) kernel boyutu ve %50 oranında 0.4 sigma değeri olacak şekilde görüntüler rastgele bulanıklaştırılmıştır.



Şekil 3.1 : Eğitim veri setine uygulanan Gaussian bulanıklık parametreleri (kernel boyutu ve sigma değeri) ve görüntü sayıları.

3.2 Model Mimarisi ve Eğitim

Yapılan çalışmada 2 boyutlu konvolüsyon, batch normalizasyon, LeakyReLU aktivasyon, MaxPool ve Dropout katmanları içermekte olan AE ve GANs modellerinin art arda kullanılması ile bir denetimsiz öğrenme modeli oluşturulmuştur. Önerilen modelin işleyişinin anlaşılması için akış şeması Şekil 3.2’de verilmiştir. Tasarlanan model, bulanık görüntüyü temel alarak orijinal görüntüyü yeniden oluşturmayı amaçlar. Bulanık görüntü, gerçek dünya uygulamalarında yaygın olarak bulunan düşük kaliteli veya bozulmuş görüntülerin modellenmesi amacıyla kullanılmaktadır.

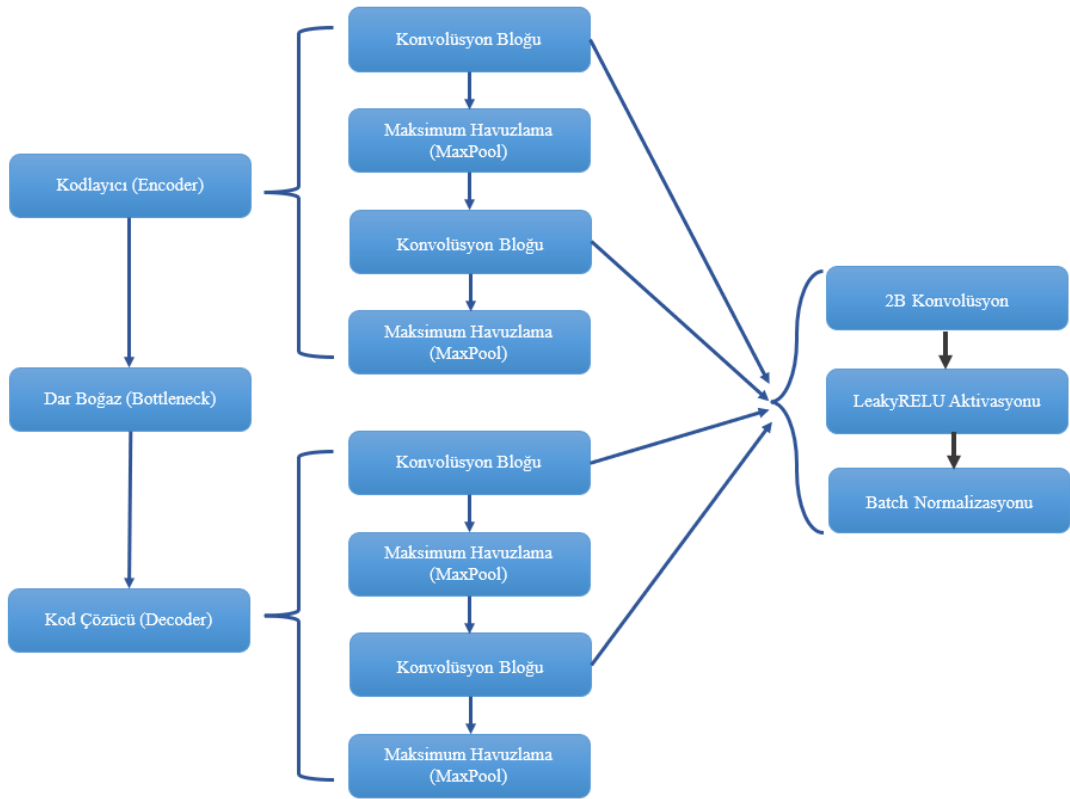


Şekil 3.2 : Bu çalışmada önerilen denetimsiz derin öğrenme modelinin yapısı.

Görüntüler arasındaki benzerlikleri ve farkları yakalamak için kullanılan kodlayıcı bloğu, görüntüleri, niteliklerini içeren yüksek boyutlu özellik uzayına dönüştürmektedir. Kodlayıcı ardından dar boğaza geçen yüksek boyutlu özellik uzayının bu kısımda boyut azaltma işlemi gerçekleştirilmektedir. Bu kısım sayesinde modelin karmaşıklığı azaltılmakta ve daha az parametre ile daha iyi sonuçların elde

edilmesi sağlanmaktadır. Kod çözücü blokta, dar boğazda sıkıştırılan özellikler, orjinal boyutlarına geri döndürülerek modele giriş olarak verilen veriye benzeyecek şekilde yeniden oluşturma yapmaktadır.

Şekil 3.3'te önerilen modelin AE kısmına ait ağ mimarisi verilmiştir. Kodlayıcı ve kod çözücü kısımlar art arda 2 defa konvolüsyon bloğu ve maksimum havuzlama katmanlarından oluşmaktadır. Her konvolüsyon bloğu ise kendi içinde 2B konvolüsyon, LeakyRELU ve Batch normalizasyonu katmanlarını içermektedir. Batch normalizasyonu katmanı ile modelin eğitim süresinin kısaltılması hedeflenmektedir. Eğitim sırasında burada LeakyRELU aktivasyon fonksiyonu kullanılmıştır.



Şekil 3.3 : Önerilen modelin otokodlayıcı kısmına ait model mimarisi.

Üretici, kod çözücü tarafından yeniden oluşturulan görüntünün iyileştirilmesi için kullanılmakta ve ürettiği çıktıyı ayırt edici bloğa iletmektedir. Ayırt edici bloğa gelen üretici blok çıktısı modelin girdisi olan bulanık görüntü ile karşılaştırılmaktadır. Karşılaştırma işlemi sonucuna göre bu karşılaştırma aralarındaki fark minimuma inene kadar devam etmektedir.

Modelin eğitimi sırasında rastgele olarak farklı seviyelerde bulanıklıklar uygulanmış 2600 görüntüden oluşan bir veri seti kullanılmaktadır. Etiketli veriler kullanılmaması sebebiyle önerilen model denetimsiz bir öğrenme süreci gerçekleştirmektedir. Eğitim

süreci boyunca farklı epoch, batch boyutu ve öğrenme oranı (learning rate) parametreleri kullanılarak denemeler yapılmıştır. Yapılan denemeler sonucunda batch boyutu 6, öğrenme oranı 2×10^{-5} olmak üzere 32 epoch ile eğitilen modelde en düşük kayıp değeri yani en iyi sonuç elde edilmiştir. Modelin eğitimi sırasında kayıp fonksiyonu olarak ortalama karesel hata (MSE) kullanılmıştır.

3.3 Bulgular


Şekil 3.3'te BSC-DBT veri setinden orjinal, bulanıklaştırılmış ve önerilen model çıktısı olan bulanıklıktan arındırılmış 5 örnek meme görüntüsüne ait sonuçlar bulunmaktadır. Çizelge 3.1'de görüntülere ait CNR değerleri bulunmaktadır. Bu değerlerin hesaplanmasında kırmızı çember ile çizili bölgeler doku (ROI), mavi çember ile çizili bölgeler ise arkaplan olarak kullanılmıştır. Elde edilen sonuçlarda farklı meme görüntülerinde birbirinden oldukça farklı CNR değerleri elde edilirken; bu farklılığın görüntülerin farklı piksel yoğunluk değerlerine sahip olmalarından kaynaklandığı görülmektedir. Denklem 3.1'de CNR hesaplamasında kullanılan eşitlik bulunmaktadır [24]. μ_{roi} ilgilenilen bölgedeki piksellerin yoğunluk değerlerini; μ_b arkaplan olarak seçilen dokunun piksel yoğunluk değerlerini; σ_b^2 ise arkaplanın standard sapmasını temsil etmektedir.

$$CNR = \frac{|\mu_{roi} - \mu_b|}{|\sigma_b^2|} \quad (3.1)$$

Literatürde görülen görüntü iyileştirme çalışmalarında, özellikle gürültü azaltma işlemlerinde, artan CNR değeri ile görüntü kalitesinin arttığı görülürken, çalışmamızda edinilen CNR değerlerinin bulanıklaşan görüntülerde daha yüksek olduğu görülmektedir. Bu sebeple öncelikle orjinal görüntü ile bulanık görüntü CNR değerleri ardından orjinal görüntü ile bulanıklıktan arındırılmış görüntü CNR değerleri oranlanarak normalize edilmiştir. Test setinde bulunan 160 meme görüntüsü için uygun doku ve arkaplan seçilerek bu oranlar gözlemlenmiştir. Şekil 1'de verilen örneklerde olduğu gibi $\frac{CNR(bulanıklıktan\ arındırılan)}{CNR(orjinal)}$ oranının $\frac{CNR(bulanık)}{CNR(orjinal)}$ oranından küçük olduğu görülmektedir. Çizelge 3.1'de görülen sonuçlardan yola çıkarak bulanıklık eklenmesi sonucu bozulan görüntüye önerilen yöntemin uygulanması sonucunda elde edilen görüntünün orjinaline yaklaştığı görülmüştür.

Çizelge 3.1: Şekil 3.3'te verilen görüntülere ait CNR değerleri.

Görüntü No	CNR (orijinal)	CNR (bulanıklaştırılmış)	CNR (bulanıklıktan arındırılan)
1	1,31	1,34	1,22
2	0,69	0,73	0,67
3	0,72	0,82	0,69
4	0,92	1,00	0,91
5	1,08	1,21	0,99



Şekil 3.4 : BSC-DBT veri setinden örnekler.

Bir başka değerlendirme kriteri olarak ortalama mutlak hata hesaplaması (MAE) ile bulanık ve bulanıklıktan arındırılan görüntülerin orjinal görüntü ile benzerlikle incelenebilir. Denklem 3.2’de MAE hesaplamasında kullanılan eşitlik verilmiştir. Burada x ve y iki farklı görüntüyü i ise görüntüdeki piksel adresini ifade etmektedir.

$$MAE = \frac{1}{N} \sum_{i=1}^N |x_i - y_i| \quad (3.2)$$

İki farklı veri seti arasındaki farkların mutlak değerlerinin ortalaması olarak tanımlanan bu metrik görüntü kalitesi değerlendirmesinde sıklıkla kullanılmaktadır. MAE değeri arttıkça, iki görüntü arasındaki benzerlik azalır ve düşük kalite veya işlem sonucunun orijinal görüntüden daha farklı olduğunu gösterebilir. Şekil 3.3’te verilen DBT görüntülerine ait MAE değerlendirmesi Çizelge 3.2’de verilmiştir.

Çizelge 3.2: Şekil 3.3’te verilen görüntülere ait MAE değerleri.


Görüntü No	MAE (orijinal, bulanıklaştırılmış)	MAE (orijinal, bulanıklıktan arındırılmış)
1	24,21	11,16
2	39,44	15,97
3	44,56	13,18
4	20,16	13,35
5	40,76	15,42

İki görüntü arasındaki benzerliğin ölçülmek istendiği durumlarda kullanılan görüntü kalitesi metriği SSIM [25] değerlendirmesinin Şekil 3.4’teki görüntülere ait sonuçları Çizelge 3.3’te verilmiştir. SSIM değerleri python “skimage” kütüphanesindeki “skimage.metrics”in barındırdığı SSIM karşılaştırma fonksiyonu ile elde edilmiştir. 0-1 arasında değer alan bu parametre 1’e yaklaştıkça görüntüler arasındaki benzerliğin arttığını; 0’a yaklaştıkça görüntüler arasındaki farklılıkların arttığını göstermektedir. Yapılan değerlendirmeler sonucunda elde edilen sonuçlar çoğunlukla 0,94 değerinden yüksektir. Bu sonuç ile aslında orjinal, bulanık ve deblur görüntüler arasındaki farkın ne denli küçük olduğu görülmektedir. SSIM sonuçlarına göre orjinal ve deblur görüntüler arasındaki benzerlik orjinal ve blur görüntülere göre nispeten fazladır.

Çizelge 3.3: Şekil 3.3'te verilen görüntülere ait SSIM değerleri.

Görüntü No	SSIM (orijinal, bulanıklaştırılmış)	SSIM (orijinal, bulanıklıktan arındırılmış)
1	0,9572	0,9735
2	0,9486	0,9772
3	0,9625	0,9658
4	0,9577	0,9724
5	0,9587	0,9802

Şekil 3.4'te görülen, test veri setinden rastgele seçilmiş 3 farklı meme görüntüsü uzman radyolog tarafından incelenmiş ve aşağıdaki yorumlar yapılmıştır. Bu şekilde; “a” orijinal, “b” bulanıklaştırılmış, “c” ise bulanıklıktan arındırılan görüntüleri temsil etmektedir.



Şekil 3.5 : Uzman radyolog tarafından incelenen görüntüler.

- 1. görüntüde; b’de kontrast çözünürlük artmış, parlaklık artmıştır ancak uzaysal çözünürlük düşmüştür. c de ise a’ya göre kontrast ve uzaysal çözünürlük artmıştır.

- 2. görüntüde; b’de a’ya göre kontrast ve uzaysal çözünürlük azalmış, c’de ise kontrast çözünürlük ve uzaysal çözünürlük artmıştır.

- 3. görüntüde; b’de kontrast çözünürlük artmış, uzaysal çözünürlük düşmüştür, c de ise uzaysal çözünürlük artmış, kontrast çözünürlüğü azalmıştır.


Görüntüdeki netlik hakkında bilgi veren uzaysal çözünürlük iki noktanın birbirinden ayırt edilebilme yeteneği olarak açıklanmaktadır [26]. Birbirine komşu olan iki yapının yoğunlukları arasındaki fark, yani kontrast ayırımında ise kontrast çözünürlüğü değerlendirilmesi yapılmaktadır [26]. Yapılan yorumlar neticesinde, bu 3 örnek arasından en iyi sonucun 1. görüntüde, en kötü sonucun ise 3. görüntüde alındığı görülmektedir.

Çizelge 3.4’te Şekil 3.5’teki görüntülerin orjinal görüntülerle arasındaki SSIM değerlendirmesinin sadece AE, sadece GAN ve önerilen hibrit model için sonuçları verilmiştir.

Çizelge 3.4: Şekil 3.5’te verilen görüntülerin orjinal görüntülerle SSIM değerlendirmesi.

Görüntü No	Sadece AE	Sadece GAN	Hibrit Model
1	0.9488	0.9501	0.9627
2	0.9514	0.9508	0.9621
3	0.9521	0.9526	0.9556

Şekil 3.6’da A sütunu önerilen hibrit model, B sütunu GAN modeli ve C sütunu AE modeli ile edinilen bulanıklıktan arındırılmış meme görüntüleri mevcuttur. Şekilde de görüldüğü üzere GAN ve AE’nin tek başına kullanıldığı modellerde görüntülerdeki bulanıklıktan giderilememiştir ve hibrit modelin başarısı bariz şekilde görülmektedir.



Şekil 3.6 : GAN+AE modeli (A), GAN modeli (B) ve AE modeli (C) çıktıları.



4. TARTIŞMA

Bu çalışmada meme tomosentez görüntülerinin bulanıklıktan arındırılması için AE ve GAN ağlarından oluşan bir hibrit denetimsiz derin öğrenme modeli önerilmektedir. Önerilen modelde, farklı seviyelerde Gaussian bulanıklığı uygulanan meme görüntüleri ile eğitilmiş ve ardından test işlemleri gerçekleştirilmiştir. Test sürecinde farklı bulanıklık seviyelerine sahip görüntülerin bulanıklıktan arındırıldıktan sonra edinilen çıktılar, bulgular başlığı altında da görüldüğü üzere kullanılan veri seti için oldukça verimli bir çalışma olduğu göstermektedir. Uzman radyolog tarafından değerlendirildiğinde bulanıklıktan arındırıldığı görülen meme görüntülerine ait CNR sonuçları literatürün aksine iyileşen görüntülerde düşme eğilimi göstermektedir. CNR hesaplamalarında beklenmedik bir sonuçla karşılaşılsa da bulanıklıktan arındırılan görüntünün CNR değerinin orjinal görüntüye bulanık görüntüden daha yakın olduğu görülmektedir. Ayrıca, SSIM ve MAE metrikleri ile gerçekleştirilen değerlendirmeler modelin bulanıklık gidermekte başarılı olduğunu nicel olarak da göstermektedir. AE ve GAN ağlarının ayrı ayrı eğitilmesinden elde edilen çıktılar tasarlanan modelin hibrit olmasının getirdiği başarıyı ve iki ağın birlikte daha kaliteli çıktılar verdiğini göstermektedir. Daha büyük bir veri seti ve daha yüksek kapasiteli bir işlemci ile modelin tekrardan eğitilmesi, daha geniş gürültü kümesinde model başarısının artmasını mümkün kılacaktır. Bulanıklık giderme çalışmaları literatürde çoğunlukla gerçek dünya görüntüleri ile gerçekleştirilmiştir. Bu eksiklik gözetilerek farklı modalitelere ait medikal görüntülerin veri setine dahil edilmesi ile önerilen model daha geniş kapsamlı bir kullanım alanına sahip olabilir.



5. SONUÇ VE ÖNERİLER

Sonuç olarak, veri setlerine erişimi veya yeni bir veri setinin oluşturulması zor olan DBT görüntülerinde bulanıklığın giderildiği bu çalışmada iki farklı ağ yapısı içeren denetimsiz bir derin öğrenme modeli tasarlanmıştır. Bu çalışmanın kantitatif sonuçları ve yapılan uzman radyolog yorumları, DBT görüntülerinin kalitesini artırma ve meme kanseri taramasının doğruluğunu yükseltme potansiyeline işaret etmektedir. Özellikle, bu yaklaşımın daha fazla klinik çalışma ve test aşamasına geçirilmesi, meme kanseri teşhisinin geliştirilmesinde önemli bir adım olabilir.



KAYNAKLAR

- [1] **Arnold M, Morgan E, Rungay H, Mafra A, Singh D, Laversanne M, Vignat J, Gralow JR, Cardoso F, Siesling S, Soerjomataram I.** Current and future burden of breast cancer: Global statistics for 2020 and 2040. *Breast*. 2022 Dec; 66:15-23. doi: 10.1016/j.breast.2022.08.010. Epub 2022 Sep 2. PMID: 36084384; PMCID: PMC9465273.
- [2] **Choi, Y., Shim, H., & Baek, J.** (2018, November). Image Quality Enhancement of Digital Breast Tomosynthesis Images by Deblurring with Deep Residual Convolutional Neural Network. In 2018 IEEE Nuclear Science Symposium and Medical Imaging Conference Proceedings (NSS/MIC) (pp. 1-3). IEEE.
- [3] **Xing Gong et al.**, "A computer simulation study comparing lesion detection accuracy with digital mammography breast tomosynthesis and cone beam CT breast imaging", *Medical physics*, vol. 33, no. 4, pp. 1041-1052, 2006.
- [4] **Choi, Y., Han, M., Jang, H., Shim, H., & Baek, J.** (2022). Two-phase learning-based 3D deblurring method for digital breast tomosynthesis images. *Plos one*, 17(1), e0262736.
- [5] **Yan, R., & Shao, L.** (2016). Blind image blur estimation via deep learning. *IEEE Transactions on Image Processing*, 25(4), 1910-1921.
- [6] **Dong, C., Loy, C. C., He, K., & Tang, X.** (2015). Image super-resolution using deep convolutional networks. *IEEE transactions on pattern analysis and machine intelligence*, 38(2), 295-307.
- [7] **Lu, B., Chen, J. C., & Chellappa, R.** (2019). Unsupervised domain-specific deblurring via disentangled representations. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 10225-10234).
- [8] **Wang, B., Xu, F., & Zheng, Q.** (2023). A survey on facial image deblurring. *arXiv preprint arXiv:2302.05017*.
- [9] **Nah S, Hyun Kim T, Mu Lee K.** Deep multi-scale convolutional neural network for dynamic scene deblurring. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, 3883–3891.
- [10] **Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y.** (2014). Generative adversarial nets. *Advances in neural information processing systems*, 27.
- [11] **Ronneberger, O., Fischer, P., & Brox, T.** (2015). U-net: Convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015: 18th International*

Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III 18 (pp. 234-241). Springer International Publishing.

- [12] **Nimisha, T. M., Sunil, K., & Rajagopalan, A. N. (2018).** Unsupervised class-specific deblurring. In Proceedings of the European Conference on Computer Vision (ECCV) (pp. 353-369).
- [13] **Yim, D., Kim, B., & Lee, S. (2020).** A deep convolutional neural network for simultaneous denoising and deblurring in computed tomography. *Journal of Instrumentation*, 15(12), P12001.
- [14] **Dong, C., Loy, C. C., He, K., & Tang, X. (2015).** Image super-resolution using deep convolutional networks. *IEEE transactions on pattern analysis and machine intelligence*, 38(2), 295-307.
- [15] **Zhang, K., Luo, W., Zhong, Y., Ma, L., Stenger, B., Liu, W., & Li, H. (2020).** Deblurring by realistic blurring. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 2737-2746).
- [16] **Jimenez, M. F. M., DeGuchy, O., & Marcia, R. F. (2020, October).** Deep convolutional autoencoders for deblurring and denoising low-resolution images. In 2020 International Symposium on Information Theory and Its Applications (ISITA) (pp. 549-553). IEEE.
- [17] **Radford, A., Metz, L., & Chintala, S. (2015).** Unsupervised representation learning with deep convolutional generative adversarial networks. arXiv preprint arXiv:1511.06434.
- [18] **Liu, B., & Chen, J. (2021).** A super resolution algorithm based on attention mechanism and srgan network. *IEEE Access*, 9, 139138-139145.
- [19] **Huang, X., Liu, M. Y., Belongie, S., & Kautz, J. (2018).** Multimodal unsupervised image-to-image translation. In Proceedings of the European conference on computer vision (ECCV) (pp. 172-189).
- [20] **Zhao, Z., Zhang, Z., Chen, T., Singh, S., & Zhang, H. (2020).** Image augmentations for gan training. arXiv preprint arXiv:2006.02595.
- [21] **Bank, D., Koenigstein, N., & Giryes, R. (2020).** Autoencoders. arXiv preprint arXiv:2003.05991.
- [22] **Feigin, Y., Spitzer, H., & Giryes, R. (2020).** GMM-based generative adversarial encoder learning. arXiv preprint arXiv:2012.04525.
- [23] **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.
- [24] **Rodriguez-Molares, A., Rindal, O. M. H., D'hooge, J., Måsøy, S. E., Austeng, A., & Torp, H. (2018, October).** The generalized contrast-to-noise ratio. In 2018 IEEE International Ultrasonics Symposium (IUS) (pp. 1-4). IEEE.

- [25] **Hore, A., & Ziou, D.** (2010, August). Image quality metrics: PSNR vs. SSIM. In 2010 20th international conference on pattern recognition (pp. 2366-2369). IEEE.
- [26] **Kaya, T.** (2017). Radyografinin Temel Prensipleri ve Radyografik Yorumda Temel İlkeler.
- [27] **Su, J., Xu, B., & Yin, H.** (2022). A survey of deep learning approaches to image restoration. *Neurocomputing*, 487, 46-65.
- [28] **Higaki, T., Nakamura, Y., Tatsugami, F., Nakaura, T., & Awai, K.** (2019). Improvement of image quality at CT and MRI using deep learning. *Japanese journal of radiology*, 37, 73-80.
- [29] **Wolterink, J. M., Leiner, T., Viergever, M. A., & Išgum, I.** (2017). Generative adversarial networks for noise reduction in low-dose CT. *IEEE transactions on medical imaging*, 36(12), 2536-2545.
- [30] **Zhang, K., Ren, W., Luo, W., Lai, W. S., Stenger, B., Yang, M. H., & Li, H.** (2022). Deep image deblurring: A survey. *International Journal of Computer Vision*, 130(9), 2103-2130.
- [31] **Tang, X., Zhao, X., Liu, J., Wang, J., Miao, Y., & Zeng, T.** (2023). Uncertainty-Aware Unsupervised Image Deblurring With Deep Residual Prior. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 9883-9892).
- [32] **Lim, B., Son, S., Kim, H., Nah, S., & Mu Lee, K.** (2017). Enhanced deep residual networks for single image super-resolution. In *Proceedings of the IEEE conference on computer vision and pattern recognition workshops* (pp. 136-144).



ÖZGEÇMİŞ

Ad-Soyad : **Müberra Aydın**

ÖĞRENİM DURUMU:

- **Lisans** : 2020, Fatih Sultan Mehmet Vakıf Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü
- **Yükseklisans** : 2023, İstanbul Teknik Üniversitesi, Elektronik ve Haberleşme Mühendisliği Fakültesi, Biyomedikal Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2021-Devam: Araştırma Görevlisi, Fatih Sultan Mehmet Vakıf Üniversitesi, Biyomedikal Mühendisliği Bölümü

ÖDÜLLER:

- 2020, TÜBİTAK 2242 Üniversitesi Öğrencileri Araştırma Projeleri Yarışması İstanbul-Asya Bölge Birincisi, “Portable Vein Imaging Device Operating with Hyperspectral Imaging Technique”

YÜKSEK LİSANS TEZİNDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Aydın M.**, Ertas M., Yıldırım İ., 2023. Unsupervised Deblurring Of Digital Breast Tomosynthesis Images Using Deep Learning IGRS’23- 2nd International Graduate Research Symposium, 16-18 May 2023, Istanbul – 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.