

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**MEME KANSERİ TESPİTİ İÇİN SENTETİK MİKRODALGA
GÖRÜNTÜLERİNİN DERİN ÖĞRENME ODAKLI SEGMENTASYONU**

YÜKSEK LİSANS TEZİ

Özlem BAHAR

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği Programı

TEMMUZ 2025

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**MEME KANSERİ TESPİTİ İÇİN SENTETİK MİKRODALGA
GÖRÜNTÜLERİNİN DERİN ÖĞRENME ODAKLI SEGMENTASYONU**

YÜKSEK LİSANS TEZİ

**Özlem BAHAR
(504211421)**

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Mehmet ÇAYÖREN

TEMMUZ 2025

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**DRIVEN SEGMENTATION OF SYNTHETIC MICROWAVE IMAGES FOR
BREAST CANCER DETECTION**



M.Sc. THESIS

**Özlem BAHAR
(504211421)**

Department of Electronics and Communication Engineering

Biomedical Engineering Programme

Thesis Advisor: Prof. Dr. Mehmet ÇAYÖREN

JULY 2025

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 504211421 numaralı Yüksek Lisans Öğrencisi Özlem BAHAR, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “MEME KANSERİ TESPİTİ İÇİN SENTETİK MİKRODALGA GÖRÜNTÜLERİNİN DERİN ÖĞRENME ODAKLI SEGMENTASYONU” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Mehmet ÇAYÖREN**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Ender Mete EKŞİOĞLU**
İstanbul Teknik Üniversitesi

Dr. Öğr. Üyesi Egemen BİLGİN
MEF Üniversitesi

Teslim Tarihi : **30 Mayıs 2025**
Savunma Tarihi : **2 Temmuz 2025**





Sevdiklerime,



ÖNSÖZ

Bu yüksek lisans tezinin hazırlanmasında bilgi ve deneyimini benimle cömertçe paylaşan, çalışmam boyunca yönlendirici katkılarıyla sürece değer katan danışman hocam Prof. Dr. Mehmet Çayören'e içten teşekkürlerimi sunarım. Sabırlı yaklaşımı, yapıcı önerileri ve destekleyici tutumu sayesinde bu çalışmayı başarıyla tamamlayabildim.

Bu zorlu yolculukta, en başından itibaren sevgisiyle beni her daim güçlü kılan canım annem Emine Bahar'a ve artık yanımda olmasa da manevi varlığıyla desteğini hep hissettiğim kıymetli babam Gazi Bahar'a sonsuz teşekkür ederim. Sabırları, duaları, fedakârlıkları ve koşulsuz destekleriyle her adımında arkamda olduklarını hissettirdiler. Verdikleri emek için ne kadar teşekkür etsem az.

Ayrıca, bu süreçte her zaman yanımda olan, anlayışı ve sabrıyla beni motive eden sevgili erkek arkadaşım Emre Katırcı'ya da gönülden teşekkür ederim.

Mayıs 2025

Özlem BAHAR
Biyomedikal Mühendisi



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 Tezin Amacı	1
1.2 Literatür Araştırması	2
1.3 Meme Kanseri	3
1.3.1 Meme kanseri tanı yöntemleri.....	3
1.3.2 Meme anatomisi ve dielektrik özellikleri.....	5
1.3.3 Memenin mikrodalga görüntülenmesi	7
1.4 Yapay Zekâ	10
1.4.1 Autoencoder (AE) mimarisi.....	10
1.4.2 U-Net mimarisi	12
1.5 Görüntü Segmentasyonu	13
1.5.1 Kullanılan verinin boyutuna dayalı segmentasyon	14
1.5.2 Temel stratejiye dayalı segmentasyon	14
1.5.3 İzleme varlığına dayalı segmentasyon	16
2. METOT VE MATERYAL	19
2.1 Mikrodalga Görüntülerinin Oluşturulması.....	19
2.1.1 RTM metodu	22
2.2 Veri Ön İşleme ve Görselleştirme	23
2.2.1 Verilerin normalizasyonu ve şekillendirilmesi	23
2.3 Görüntülerin Görselleştirilmesi.....	24
2.4 Görüntülerin Yüklenmesi	25
2.5 Autoencoder Mimarisinin Oluşturulması	26
2.6 U-Net Mimarisinin Oluşturulması	35
2.7 Eğitim Aşaması	46
2.8 Autoencoder ve U-Net Mimarisinin Karşılaştırılması	48
3. SONUÇLAR	51
KAYNAKLAR	53
ÖZGEÇMİŞ.....	57



KISALTMALAR

MR	: Manyetik rezistans
BT	: Bilgisayarlı tomografi
PET	: Pozitron emisyon tomografi
M	: Mega
G	: Giga
Hz	: Hertz
MRG	: Manyetik rezonans görüntüleme
DL	: Derin öğrenme (deep learning)
XMG	: X-ışını mamografisi
MWI	: Mikrodalga görüntüleme (microwave imaging)
2B	: 2 Boyutlu
US	: Ultrasonografi
SPECT	: Tek foton emisyonlu bilgisayarlı tomografi
MS	: Multipl skleroz
LMIC	: Düşük ve orta gelirli ülkeler (Low- and middle-income countries)
SSIM	: Yapısal benzerlik indeksi ölçütü (Structural similarity indexmeasure)
PSNR	: Tepe-sinyal gürültü oranı (Peak signal-to-noise ratio)
GPU	: Grafik işlem birimi (Graphics processizng unit)



SEMBOLLER

$\epsilon^*(\omega)$	: Karmaşık geçirgenlik
ϵ'	: Karmaşık geçirgenliğin gerçek kısmı
ϵ''	: Karmaşık geçirgenliğin sanal kısmı
ϵ_∞	: Çok yüksek frekanslarda bağıl geçirgenlik
ϵ_s	: Sıfır frekansta bağıl statik geçirgenlik
ω	: Açısal frekans
τ	: Dinlenme zamanı
σ_{dc}	: Statik doğru akım iletkenliği
ϵ_0	: Serbest uzay geçirgenliği
α	: Frekans Üssü
j	: Karmaşık bir sayının sanal birimi
Z	: Empedans
R	: Rezistans
X	: Reaktans
Γ	: Ölçüm Alanı
σ	: Elektriksel İletkenlik
μ	: Manyetik Geçirgenlik



ÇİZELGE LİSTESİ

Sayfa

Çizelge 1.1 : Farklı Frekanslarda Üç Meme Dokusunun Mikrodalga Parametreleri...	9
Çizelge 2.1 : Doku Özellikleri Tablosu.....	19
Çizelge 2.2 : RTM Çalışma Ayarları ve Anten Parametreleri.....	20





ŞEKİL LİSTESİ

Sayfa

Şekil 1.1 : Meme Yapısının Anatomik Görüntüsü.	6
Şekil 1.2 : Autoencoder Şeması.....	11
Şekil 1.3 : U-Net Mimarisi Şeması [28].	13
Şekil 2.1 : Mikrodalga Görüntüleme Anten Yerleşimi ve Elektrik Alan Yayılmı... ..	20
Şekil 2.2 : Segmentasyon Yöntemi ile Elde Edilen Görüntüler.	21
Şekil 2.3 : Mikrodalga Görüntüler.....	22
Şekil 2.4 : Tezde Kullanılan Autoencoder Mimarisi.....	28
Şekil 2.5 : Autoencoder Mimarisinin Katman Çıktılarını Görüntülemek İçin Verilen Girdi Görüntü.	29
Şekil 2.6 : Conv1 İşleminin Görsel Üzerindeki Etkileri.....	29
Şekil 2.7 : Conv2 İşleminin Görsel Üzerindeki Etkileri.....	29
Şekil 2.8 : Conv3 İşleminin Görsel Üzerindeki Etkileri.....	30
Şekil 2.9 : Conv4 İşleminin Görsel Üzerindeki Etkileri.....	30
Şekil 2.10 : Conv5 İşleminin Görsel Üzerindeki Etkileri.....	30
Şekil 2.11 : Conv6 İşleminin Görsel Üzerindeki Etkileri.....	30
Şekil 2.12 : Conv7 İşleminin Görsel Üzerindeki Etkileri.....	31
Şekil 2.13 : Autoencoder Mimarisine Ait Bütün İşlemlerin Uygulanmasından Sonra Elde Edilen Çıktılar.....	31
Şekil 2.14 : Autoencoder Mimarisinin Mikrodalga Görüntülerine Uygulanıp Elde Edilen Eğitim ve Doğrulama Kayıp Grafiği.	31
Şekil 2.15 : Autoencoder Mimarisinin Yaptığı Tahminler.....	32
Şekil 2.16 : Autoencoder Mimarisinin SSIM Raporu.	34
Şekil 2.17 : Tezde Kullanılan U-Net Mimarisi.....	37
Şekil 2.18 : U-Net Mimarisinin Katman Çıktılarını Görüntülemek İçin Verilen Girdi Görüntü.	38
Şekil 2.19 : Conv1_1 Katmanının Görsel Üzerindeki Etkileri.....	38
Şekil 2.20 : Conv1_2 Katmanının Görsel Üzerindeki Etkileri.....	38
Şekil 2.21 : Conv2_1 Katmanının Görsel Üzerindeki Etkileri.....	39
Şekil 2.22 : Conv2_2 Katmanının Görsel Üzerindeki Etkileri.....	39
Şekil 2.23 : Conv3_1 Katmanının Görsel Üzerindeki Etkileri.....	39
Şekil 2.24 : Conv3_2 Katmanının Görsel Üzerindeki Etkileri.....	39
Şekil 2.25 : Conv4_1 Katmanının Görsel Üzerindeki Etkileri.....	39
Şekil 2.26 : Conv4_2 Katmanının Görsel Üzerindeki Etkileri.....	40
Şekil 2.27 : Conv4_2 Katmanının Görsel Üzerindeki Etkileri.....	40
Şekil 2.28 : Conv5_2 Katmanının Görsel Üzerindeki Etkileri.....	40
Şekil 2.29 : Conv5_2 Katmanının Görsel Üzerindeki Etkileri.....	40
Şekil 2.30 : Conv6_1 Katmanının Görsel Üzerindeki Etkileri.....	41
Şekil 2.31 : Conv6_2 Katmanının Görsel Üzerindeki Etkileri.....	41
Şekil 2.32 : Conv6_2 Katmanının Görsel Üzerindeki Etkileri.....	41
Şekil 2.33 : Conv7_1 Katmanının Görsel Üzerindeki Etkileri.....	41
Şekil 2.34 : Conv7_2 Katmanının Görsel Üzerindeki Etkileri.....	42

Şekil 2.35 : Conv2d_Transpose_2 Katmanının Görsel Üzerindeki Etkileri.....	42
Şekil 2.36 : Conv8_1 Katmanının Görsel Üzerindeki Etkileri.	42
Şekil 2.37 : Conv8_2 Katmanının Görsel Üzerindeki Etkileri.	42
Şekil 2.38 : Conv2d_Transpose_3 Katmanının Görsel Üzerindeki Etkileri.....	43
Şekil 2.39 : Conv9_1 Katmanının Görsel Üzerindeki Etkileri.	43
Şekil 2.40 : Conv9_2 Katmanının Görsel Üzerindeki Etkileri.	43
Şekil 2.41 : U-Net Mimarisine Ait Bütün İşlemlerin Uygulanmasından Sonra Elde Edilen Çıktılar.	43
Şekil 2.42 : U-Net Mimarisinin Eğitim ve Doğrulama Kayıp Grafiği.	44
Şekil 2.43 : U-Net Mimarisinin Mikrodalga Görüntüler Üzerindeki Tahmin Sonuçları.....	45
Şekil 2.44 : U-Net Mimarisi SSIM Skoru Grafiği.....	46
Şekil 2.45 : Autoencoder Mimarisi Hiperparametreleri.	47
Şekil 2.46 : U-Net Mimarisi Hiperparametreleri.	48
Şekil 2.47 : Autoencoder ve U-Net Mimarisinin Karşılaştırılması.	48



MEME KANSERİ TESPİTİ İÇİN SENTETİK MİKRODALGA GÖRÜNTÜLERİNİN DERİN ÖĞRENME ODAKLI SEGMENTASYONU

ÖZET

Günümüzde yapay zekâ tabanlı derin öğrenme modelleri, görüntü işleme ve bilgisayarlı görü alanlarında önemli gelişmelere öncülük etmektedir. Bu gelişmeler, özellikle tıbbi görüntüleme alanında hastalıkların erken teşhisi ve doğru tanınması açısından büyük fayda sağlamaktadır. Kadınlarda en yaygın şekilde karşılaşılan kanser türlerinden biri meme kanseridir ve erken teşhis, tedavi başarısını doğrudan etkilemektedir. Bu nedenle, güvenli, taşınabilir ve iyonlaştırıcı radyasyon içermeyen bir yöntem olan mikrodalga görüntüleme, alternatif bir görüntüleme tekniği olarak dikkat çekmektedir. Ancak mikrodalga görüntülerin düşük çözünürlüklü ve gürültülü olması, doğrudan yorumlanmalarını güçleştirmektedir. Bu çalışmada, mikrodalga görüntülerde tümörlü dokuların daha net ve doğru şekilde belirlenebilmesi amacıyla derin öğrenme tabanlı bir segmentasyon yöntemi kullanılmıştır. Bu sayede, düşük kaliteli görüntülerden daha anlamlı bilgiler elde edilerek meme kanseri teşhisinde yardımcı olunması hedeflenmiştir.

Bu çalışmada, bir adet tümör dokusu içeren sentetik meme yapısına ait toplam 1000 adet mikrodalga görüntü veri seti ve bu veri setine karşılık gelen segmentasyon görüntüleri girdi verisi olarak kullanılmıştır. Görüntülerin oluşturulabilmesi için 10 cm yarıçaplı 18 adet vivaldi anten içeren özel bir senaryo tasarlanmıştır. Bu senaryoda antenler, sentetik meme dokusunun etrafına yerleştirilerek farklı açılardan sinyal gönderip alacak şekilde konumlandırılmıştır. Bu sayede, tümörlü bölgenin mikrodalga sinyallerine verdiği tepkiler kaydedilmiş ve bu veriler kullanarak dielektrik görüntüler oluşturulmuştur. Bu dielektrik görüntüler Reverse Time Migration (RTM) algoritması kullanılarak mikrodalga görüntülere çevrilmiştir. Elde edilen bu görüntüler, derin öğrenme tabanlı modellerin eğitimi ve testinde kullanılmıştır.

Bu çalışmada iki farklı mimari kullanılmıştır: Autoencoder ve U-Net. Bu mimariler Python yazılım dili kullanılarak tasarlanmıştır. Bu iki mimari için üretilen 1000 adet görüntünün 600'ü eğitim, 200'ü validasyon ve 200'ü test için ayrılmıştır. Autoencoder modeli, gürültüyü azaltmak amacıyla girdiyi kodlayıp yeniden oluşturan bir yapıya sahiptir. Optimizasyon algoritması olarak Adam optimizasyonu kullanılmıştır. U-Net mimarisi ise gürültüyü temizlerken detayları daha iyi koruyabilmek amacıyla geliştirilmiştir. Eğitim sürecinde Binary Crossentropy kayıp fonksiyonu kullanılmıştır.

Mimarilerin başarımı, Yapısal Benzerlik İndeksi (SSIM) metriği ile değerlendirilmiştir. SSIM değeri 0 ile 1 aralığındadır ve sonucun 1 olması orijinal görüntü ile tahmin edilen görüntünün birbiriyle tamamen aynı olduğu anlamına gelmektedir. Yapılan çalışma sonucunda autoencoder mimarisinin SSIM değeri 0,9419 iken, U-Net mimarisinin SSIM değeri 0,9627'dir. Bu sonuçlar doğrultusunda U-Net Mimarisi, autoencoder mimarisine göre %2,21 oranında mikrodalga görüntü segmentasyonunda daha başarılı olmuştur.



DEEP LEARNING-DRIVEN SEGMENTATION OF SYNTHETIC MICROWAVE IMAGES FOR BREAST CANCER DETECTION

SUMMARY

Breast cancer remains one of the most prevalent and life-threatening diseases worldwide, continuing to be the leading cause of cancer-related mortality among women. Current global health statistics reveal that millions of new breast cancer cases are diagnosed annually, with a disproportionate concentration in low- and middle-income countries (LMICs). In these regions, disparities in healthcare infrastructure, socioeconomic challenges, and limited access to advanced diagnostic technologies substantially hinder early detection efforts. Early diagnosis of breast cancer is of paramount importance, as timely intervention significantly improves patient survival rates, reduces the need for aggressive treatments, mitigates treatment-related side effects, and ultimately decreases the economic burden on healthcare systems. Despite technological advancements, conventional breast imaging modalities such as mammography, ultrasound, and magnetic resonance imaging (MRI) still face notable limitations globally in terms of accessibility, cost, and diagnostic efficacy.

Mammography, regarded as the clinical gold standard for breast cancer screening, involves ionizing radiation and poses potential health risks with frequent use. Moreover, its diagnostic sensitivity is considerably reduced in women with dense breast tissue, leading to false-negative results and delayed treatment. Radiation-free ultrasound imaging requires highly skilled operators, resulting in variability in diagnostic accuracy and limiting its widespread application. Nuclear imaging techniques such as positron emission tomography (PET) and single-photon emission computed tomography (SPECT) provide valuable dynamic and functional imaging data; however, their high costs, radiation exposure, and limited availability restrict their broader clinical use. MRI offers superior soft tissue contrast and spatial resolution but is associated with high operational costs, infrastructure demands, and limited accessibility, especially in LMICs. Collectively, these challenges underscore the urgent need for safe, cost-effective, scalable, and reliable novel imaging technologies for early tumor detection.

Microwave Imaging (MWI) has recently emerged as a promising alternative modality that enables non-ionizing electromagnetic wave-based examination of the internal structural and functional properties of breast tissue. The fundamental principle of MWI relies on the dielectric property differences—specifically dielectric permittivity (ϵ_r) and electrical conductivity (σ)—between malignant tumors and normal breast tissue. This contrast provides functional imaging information complementary to the anatomical data obtained from conventional methods. Microwave imaging systems primarily consist of transmitting and receiving antennas, with the collected data computationally reconstructed into images. Additionally, MWI systems are inherently more affordable, portable, and easier to operate, making them highly suitable for resource-constrained clinical environments. Nevertheless, the clinical translation of MWI has been impeded by intrinsic limitations such as relatively low spatial resolution, sensitivity to noise and artifacts, and challenges in accurately localizing tumors within reconstructed images.

In response to these challenges, the present thesis proposes a comprehensive deep learning framework aimed at enhancing the diagnostic performance and tumor

localization accuracy of microwave breast imaging. Within this scope, synthetic breast tissue models were developed using a high-fidelity simulation platform based on the Reverse Time Migration (RTM) algorithm, which realistically models the propagation and scattering of electromagnetic waves in heterogeneous and homogeneous biological tissues. The RTM algorithm processes source and receiver wavefields bidirectionally and establishes correlations between them to generate an image. It consists of two steps involving the backpropagation of complex conjugate data into the imaging domain and computing the cross-correlation norm of the forward and backward propagated fields. Synthetic breast models were generated employing microwave difference imaging based on the total electric field, necessitating knowledge of the healthy breast state during imaging. The total electric field data required for microwave imaging were synthetically produced via numerical solutions of electromagnetic scattering problems.

This study investigates deep learning-based segmentation of low-resolution microwave images generated from total electric field data. The dataset comprises 1000 synthetic transverse breast images, each containing a single tumor, initially created at a high resolution of 400×400 pixels. The use of synthetic data instead of physical breast phantoms provided precise control over critical parameters such as tissue heterogeneity, tumor size and location, and dielectric properties, allowing systematic and reproducible evaluation of model robustness under diverse conditions. The imaging configuration simulates a circular array of 18 Vivaldi antennas placed around the synthetic breast at a radius of 10 cm. The surrounding medium is modeled as a homogeneous environment with a relative permittivity of 10. Simulations incorporate properties of breast, fibroglandular, and tumor tissues. This arrangement ensures wide angular coverage and enhances sensitivity to tissue heterogeneity.

To align with deep learning architectures and reduce computational load, images were resized to 64×64 pixels while preserving essential structural and contrast information necessary for accurate segmentation. It should be noted that microwave images are not inherently RGB; rather, single-channel microwave data were artificially converted into three-channel (64, 64, 3) pseudo-color images using assigned color maps. This transformation enables universal convolutional neural networks designed for RGB inputs to process the data. Both deep learning models used in this thesis accept input and produce output images of (64, 64, 3) dimensions, visually highlighting tumor regions to facilitate interpretation and improve suitability for segmentation tasks.

Within this framework, two distinct deep learning architectures were proposed for tumor segmentation: an autoencoder and a U-Net model. Both architectures were implemented in Python using libraries such as Keras, TensorFlow, skimage, matplotlib, and numpy. Both models focus primarily on semantic segmentation of tumor tissues beyond mere noise removal or artifact suppression. The dataset of 1,000 images was split into 600 for training, 200 for validation, and 200 for testing on unseen samples. Training and testing were conducted in two separate phases; first, the systems were trained and the architectures saved, followed by testing using the trained models.

The autoencoder comprises an encoder that compresses input images through multi-layer convolutional blocks incorporating batch normalization and LeakyReLU activation functions. Batch normalization accelerates training and stabilizes intermediate outputs, while LeakyReLU prevents “dead ReLU” problems by allowing small non-zero gradients for inactive neurons. Dropout regularization in deeper layers prevents overfitting. The encoder compresses fundamental spatial and structural

features into latent representations, which the decoder reconstructs into enhanced images emphasizing tumor regions through transposed convolutions and additional convolutional operations. This architecture not only reconstructs image content but also improves contrast and structural integrity to support subsequent segmentation steps. However, since the autoencoder primarily aims at general image enhancement, its performance in precise tumor localization remains limited.

In contrast, the U-Net model employed in this study is a supervised architecture specifically designed for biomedical image segmentation. U-Net features a symmetric encoder-decoder structure interconnected by skip connections that preserve high-resolution spatial information losslessly. The encoder extracts multi-scale features via convolution and max-pooling layers, while the decoder progressively upsamples these features to generate tumor probability maps. A sigmoid activation function in the final output layer produces binary segmentation masks with well-defined tumor boundaries. Unlike the autoencoder, U-Net is directly optimized for semantic segmentation using custom loss functions that consider both spatial accuracy and tumor region integrity. Consequently, it yields highly precise and clinically meaningful segmentation maps suitable for decision-making.

Both models maintain structural symmetry between compression and expansion rates to ensure performance and stability during training. They were trained and validated on different subsets of the synthetic dataset with extensive data augmentation including rotation, reflection, and scaling to improve generalization and prevent overfitting. The Adam optimizer was used during training, with the autoencoder trained for 150 epochs and the U-Net for 50 epochs. Structural Similarity Index (SSIM) was employed as the primary evaluation metric to assess preservation of structural details and perceptual image quality during both training and testing phases.

Comparative results demonstrate that the autoencoder effectively enhances overall image contrast and suppresses irrelevant details but remains limited in tumor localization due to its reconstruction-centric design. Conversely, the U-Net model significantly outperforms the autoencoder in both SSIM scores and segmentation accuracy, producing highly reliable tumor segmentation masks.

In conclusion, this thesis presents a deep learning-based framework addressing fundamental limitations of microwave breast imaging. Utilizing high-fidelity synthetic datasets and robust neural network architectures, the proposed approach substantially improves tumor detection and localization capabilities. The non-invasive, radiation-free, and low-cost nature of microwave imaging renders this technology particularly promising for expanding early breast cancer screening in resource-limited settings worldwide. The proposed methods close current technological gaps by enabling more accurate tumor detection in low-resolution microwave images.

Moreover, the successful integration of microwave imaging with deep learning not only overcomes existing technical challenges but also paves the way for more accessible and equitable breast cancer diagnostic methods globally. This approach reduces dependence on expensive and complex imaging equipment, holding transformative potential for screening protocols in disadvantaged regions where early detection remains critically insufficient. The innovations presented in this thesis represent a significant step toward reducing global health disparities, providing clinicians with advanced tools for timely diagnosis and personalized treatment planning. Ultimately, this work offers meaningful progress in the fight against breast

cancer by combining technological innovation with intelligent healthcare solutions to enhance patient survival rates and quality of life.



1. GİRİŞ

Vücut içi anormalliklerin tespit edilebilmesi için vücut iç yapısının görüntülenmesi gerekmektedir. Vücut iç yapısının görüntülenmesi için X-Ray. Manyetik Rezonans (MR), Ultrason, Bilgisayarlı Tomografi (BT) ve Pozitron Emisyon Tomografi (PET) gibi çeşitli görüntüleme teknikleri kullanılır [1]. Bu görüntüleme yöntemlerine ek olarak 300 MHz – 30 GHz aralığında mikrodalga görüntüleme yöntemi kullanılır [2,3]. Mikrodalga görüntülemenin yapılan çeşitli literatür çalışmaları ile beyin ve meme dokusundaki tümörlerde [4], kardiyak ve kemik görüntülenmesi [5,6] gibi yöntemlerde kullanılabileceği saptanmıştır.

Meme kanseri, kadınlar arasında oldukça yaygın görülen, yılda yaklaşık 2,3 milyon vaka gözlemlenen kanser türlerinden biridir. Meme kanserinde de diğer kanser türlerinde olduğu gibi, erken tanı ve zamanında tedavi büyük önem taşımaktadır. Bu aşamada mikrodalga görüntüleme meme kanseri teşhisinde katkıda bulunabilmektedir.

Mikrodalga görüntüleme materyalleri alıcı ve saçıcı antenler, radyo frekans anahtarı ve mikrodalga kaynağı olarak sayılabilir. Doku, dielektrik özelliklerinden dolayı elektromanyetik saçıcı görevi görür ve saçıcının özellikleri, görüntülen dokunun konumunu ve boyutunu belirleyen niteliksel bir ters problem kullanılarak yeniden oluşturulur. Ancak bu bilgi, niteliksel ters problemleri çözmenin yanı sıra, dokunun elektromanyetik özelliklerinin de öğrenilmesini gerektirir. Dokudan ek elektromanyetik bilgilerin elde edilmesi, dokunun tümör dokusu olup olmadığının belirlenmesi noktasında oldukça önemlidir. Niteliksel ters problem çözme yöntemi kullanılarak oluşturulan görüntüler ile iki saçıcının dielektrik değerleri arasındaki ilişkinin incelenmesi ve eğer bir ilişki varsa bunun kanıtlanmasını sağlar. Bu ilişkinin kanıtlanması için derin öğrenme yöntemleri kullanılabilir.

1.1 Tezin Amacı

Bu çalışmanın temel amacı, mikrodalga görüntüleme yöntemiyle elde edilen meme görüntülerinden tümörlü dokunun tespit edilmesini sağlamaktır. Mikrodalga görüntüleme, iyonlaştırıcı radyasyon içermemesi, düşük maliyetli olması ve taşınabilir

sistemlere uygunluđu sayesinde geleneksel yöntemlere alternatif olarak dikkat çekmektedir. Ancak bu yöntemin en büyük dezavantajı, düşük uzamsal çözünürlük ve yüksek görüntü gürültüsüdür. Bu durum, tümörlü alanların doğru bir şekilde ayırt edilmesini zorlaştırmakta ve yorumlamayı güçleştirmektedir. Bu problemi aşmak amacıyla çalışmada derin öğrenme tabanlı iki farklı mimari geliştirilmiştir: biri gürültü azaltma amacıyla kullanılan autoencoder modeli, diğeri ise tümör segmentasyonu için özel olarak tasarlanan U-Net mimarisidir. Her iki modelin mimarisi Python programlama dili kullanılarak, Keras kütüphanesi yardımıyla oluşturulmuş ve Spyder geliştirme ortamında uygulanmıştır. Autoencoder modeli ile görüntülerdeki arka plan gürültüsü azaltılarak daha net ve anlaşılır yapılar elde edilmesi hedeflenmiştir. U-Net modeli, tümörlü bölgeleri piksel düzeyinde ayırt edebilmek amacıyla kullanılmıştır. Bu sayede, tümörün konumu daha hassas bir şekilde belirlenerek tanı sürecine katkı sağlanması hedeflenmiştir. Bu iki modelin çıktıları karşılaştırılarak mikrodalga görüntüleme yapay zekâ temelli yöntemlerin ne ölçüde etkili olabileceğı değerlendirilmiştir. Sonuç olarak bu çalışma, mikrodalga görüntüleme yönteminin meme kanseri tanısında kullanılabilirliğini artırmayı hedeflemekte; görüntü kalitesini iyileştiren ve tümörlü doku ayrımını daha net hale getiren derin öğrenme tekniklerinin bu alandaki potansiyelini ortaya koymaktadır.

1.2 Literatür Araştırması

Mikrodalga görüntüleme ile kanser tespiti, sağlıklı ve sağlıklı olmayan (kötü huylu) meme dokularının arasında bulunan dielektrik özellik farkına dayanmaktadır. Ancak sağlıklı ve kötü huylu meme dokularının mikrodalga frekanslarındaki dielektrik özelliklerine ilişkin kesin bir bilgi veren çalışma yayınlanmamıştır. Literatürde bu problemin çözülebilmesi için 0,5 ile 20 GHz aralığında açık uçlu koaksiyel prob kullanılarak normal, iyi huylu ve kötü huylu göğüs dokularının ultra geniş bant mikrodalga dielektrik özelliklerinin belirlenmesi için birçok deneysel çalışmalar yapılmıştır. Meme küçültme ameliyatlarından elde edilen doku ile meme dokusunun sahip olduğı dielektrik özellikler belirlenmiştir. Yapılmış kanser ameliyatlarından elde edilen iyi huylu ve malign meme dokusunun dielektrik özellikleri belirlenmiştir. Elde edilen bilgiler raporlanmıştır. Elde edilen analiz sonuçlarına göre kötü huylu ve normal huylu dokular arasındaki dielektrik kontrast oranının 10:1 değerinde olduğı gösterilmiştir [7].

Yapılan literatür çalışmasında mikrodalga görüntülemeye çözünürlüğü artırmaya yönelik yeni bir yöntem önerilmiştir. Geleneksel ters problem çözme yöntemleri, çeşitli çözünürlük seviyelerinde görüntüler üretebilse de bağımsız ölçümler sınırlıdır ve bu yüzden gerçek uygulamalarda yetersiz kalmaktadır. Bu problemin çözülebilmesi için tezde iki aşamalı yöntem önerilmiştir. Tezin ilk aşamasında doğrusal olmayan ters çevirme tekniği kullanılmıştır, ikinci aşamada evrişimli sinir ağı ile öğrenme tekniği kullanılmıştır. Bu yöntem, herhangi bir geleneksel teknikle entegre edilebilir ve tüm boyutlar için çözünürlüğü artırabilir. Yöntemin etkinliği, 2B (2 boyutlu) mikrodalga görüntüleme yöntem problemleri üzerinde 3 kat büyütme faktörüyle test edilmiş, ve sonuç olarak daha ayrıntılı ve daha yüksek çözünürlüklü görüntüler elde edilmiştir [8].

Yapılan literatür çalışmasında nitel görüntüleme teknikleri ve derin öğrenmeyi (DL) birleştiren yenilikçi bir mikrodalga görüntüleme yaklaşımı sunulmuştur. Yapılan çalışmanın temel amacı, dağınık alanların bilgisinden yola çıkılarak bilinmeyen hedeflerin şeklini kullanıcıdan bağımsız ve güvenilir şekilde elde edilebilmek amacıyla bir araç geliştirmektir. Nitel görüntüleme yöntemleri, gerçek zamanlı morfolojik bilgi sağlama konusunda etkili bir yöntem olsa da ürettikleri sürekli haritaların hedefleri açıkça tanımlaması için sert eşiklemeye ihtiyaç duymaktadır. Bu eşikleme işlemi ise mevcut duruma bağlı olarak kullanıcıya bağlı, sonuçlar oluşturabilir. Bu problemi çözmek amacıyla yapılan çalışmada, hedefleri (ön plan) arka plandan ayıran ikili maskeler oluşturmak için fizik destekli derin sinir ağı tabanlı DL yaklaşımı geliştirilmiştir. Önerilen ağ, nitel bir görüntüleme ters çevirme tekniklerinden biri olan ortogonallik örnekleme yöntem çıktısını ikili hale getirir. Ayrıca karşılaştırma yapılabilmesi için, herhangi bir nitel görüntüleme tekniği kullanılmadan, doğrudan saçılmış alanlardan ikili maskeler üreten bir DL yöntemi de değerlendirilmiştir. Çalışmada, her iki yöntemin performanslarının nicel bir analizi ve deneysel veriler üzerinde test edilmesi yöntemi sunulmuştur [9].

1.3 Meme Kanseri

1.3.1 Meme kanseri tanı yöntemleri

Meme kanseri tanısının konulabilmesi için hekimler tarafından genellikle ek tetkikler istenir. Tıbbi görüntüleme yöntemleri, tümör dokusunun morfolojisini ve yerini net bir şekilde gösterdiği için klinisyenlere oldukça yardımcı olmaktadır. Ancak görüntüleme yönteminde kimyasal kontrast ve yüksek enerjili ışınlar kullanılması hastada hasara

sebepler olabilir. Tümörün tespiti, Manyetik Rezonans Görüntüleme (MRG) taraması, X-ışını Mamografisi (XMG), Bilgisayarlı Tomografi (BT) taraması, ultrasonografi (US), tek foton emisyonlu bilgisayarlı tomografi (SPECT) ve Pozitron Emisyon Tomografi (PET) gibi çeşitli görüntüleme taramaları ile yapılabilir. Tümörün tespiti için kullanılabilecek diğer bir yöntem ise biyopsidir. Biyopsi, cerrahi müdahale olan bir yöntemdir [10,11].

Meme dokusunun düşük dozlu röntgen ile görüntülenmesi mamografi olarak adlandırılır. Mamografi hekimler tarafından semptomlar çıkmadan meme kanserini tespit etmek amacıyla kullanılan bir yöntemdir. Bir kadın ağrı, yumru, göğüs ucu akıntısı gibi semptomlara sahipse memedeki herhangi bir anormalliği tespit etmek için mamografi yapılabilir.

Mamografinin duyarlılık, iyi hasta toleransı ve düşük maliyet gibi birçok avantajı vardır. Fakat bu avantajlara ek olarak sahip olduğu dezavantajlar da vardır. Bunlar, yanlış tanı ve radyasyon tehlikeleri olarak sıralanabilir [12].

Ultrasonografi, bir kadının göğüslerinin iç kısmını gerçek zamanlı olarak görüntülenmesini sağlar, yüksek frekansta ses dalgaları kullanılarak yapılan ultrason görüntüleme işlemi ile elde edilir. Genellikle herhangi bir anormalliği tespit etmek amacıyla kullanılır. Ultrasonografi testi invaziv değildir. Ultrasonografi, katı tümörler ile kanser riski düşük olan sıvı dolu kistleri gibi farklı kitleleri ayırt edebilmesi nedeniyle faydalıdır. Ancak tek başına yeterli olmadığı durumlarda ek testler gerekebilmektedir.

Mamografi görüntüleme yöntemine ek olarak, ultrasonografi görüntüleme yönteminin düşük radyasyonlu olması ve yüksek hassasiyette olması gibi avantajları bulunmaktadır ve bu da emziren, genç ve hamile kadınlarda kanser tespitinin yapılabilmesi için etkili bir yöntem olmaktadır [13].

Meme yapısı manyetik rezonans görüntüleme ile oldukça iyi bir şekilde görüntülenebilir. Bu görüntüleme yöntemi güçlü bir mıknatıs ve radyo dalgaları üreterek ağrısız ve radyasyonsuz görüntüleme yapar. MR yöntemi, tedavinin ilerleyişini incelemek, tümörün metastazını incelemek ve yüksek riskli hastaları takip etmek gibi amaçlarla meme görüntüleme için kullanılır. Bu görüntüleme yönteminin bazı dezavantajları vardır. Bunlar; görüntüleme süresinin uzun olması, yüksek

maliyetli olması ve hasta vücudunda metal bulunması durumunda kullanılamaması olarak sıralanabilir [14].


Tek foton emisyonlu bilgisayarlı tomografi ve pozitron emisyon tomografisi adı verilen nükleer görüntüleme testleri, meme dokularının hareket halindeki görüntülerini oluşturur. Testlerde enjekte edilmesi güvenli bir radyoaktif madde kullanılır. PET, karbon-11, azot-13, oksijen-15 ve flor-18 gibi pozitronlar yayan radyoaktif izotoplar kullanırken, SPECT iyot-123 ve teknesyum-99m gibi gama fotonları üreten radyoaktif izotoplar kullanır. Hasarlı dokular radyoaktif maddeleri sağlıklı dokulardan daha fazla emer. PET ve SPECT tarayıcıları bu radyasyonu alır ve meme dokusunun görüntülerini oluşturur. PET ve SPECT görüntüleme yöntemlerinin meme kanseri teşhisi için kullanılması, yüksek maliyet, radyasyon tehlikeleri ve sınırlı kullanımı olması sebebiyle önerilmez. Ancak, metastaz oluşmuş meme kanseri taraması, kemik ve lenf metastazları gibi durumlarda, PET ve SPECT yaklaşımları meme kanserini teşhis edebilmek için tamamlayıcı tanı prosedürü olarak kullanılabilir [15].

Biyopsi yönteminde, memeden alınan meme dokusu, hücreleri veya sıvıları mikroskop altında incelenerek hastalıklı doku ile ilgili bilgi elde edilir. Elde edilen bu bilgi de meme kanseri teşhisi için kullanılabilecek ek yöntemlerden biridir.

Bu sıralanan teknikler genellikle tümörün bulunduğu evrede kullanılır ve kötü huylu tümörleri erken evrelerde tespit edemezler. Bu tekniklerin sahip olduğu dezavantaj ve sınırlamalar araştırmacıları kanseri tespit edebilmek için daha ucuz, tahribatsız teşhis tekniği oluşturmaya itmiştir [16].

1.3.2 Meme anatomisi ve dielektrik özellikleri

Meme dokusu genel olarak deri, yağ dokusu (adipoz), bağ dokusu, glandüler doku, kan ve kaslardan oluşur. Bağ dokusunun ana görevi memenin yapısal bütünlüğünü korumaktır. Süt kanalları, meme bezlerini birbirine bağlar ve bu bezler meme ucunda birleşerek anne sütü üretir. 15 ila 20 glandüler doku, bir lob oluşturur; her lob, süt üreten küçük lobüllerden meydana gelir. Meme ucu, pigmentli bir daire ile çevrilidir. Yağ dokusu, loblar arasındaki boşlukları doldurarak memenin şeklini ve boyutunu belirler. Memedeki yağ, bağ ve glandüler dokuların oranları, emzirme ve gebelik gibi durumlara bağlı olarak değişiklik gösterebilir [17]. Kadın memesinin temel anatomisi şekil 1.1’de verilmiştir [18].



Şekil 1.1 : Meme Yapısının Anatomik Görüntüsü.

Etkili ve düşük maliyetli meme kanseri tespit etme teknikleri geliştirebilmek için meme dokularının dielektrik özelliklerini iyi anlamak gerekir. Bu temel özellikler, karmaşık geçirgenlik ile tanımlanır. Karmaşık geçirgenlik, dokunun dış elektrik alanıyla etkileşimini açıklar ve bu etkileşim, elektromanyetik alanın frekansına ve dokunun iletkenliğine bağlıdır. Bir elektrik alanı uygulandığında, yüklerin hareketiyle dielektrik polarizasyon oluşur. Bu polarizasyon, dokuların dielektrik özelliklerinin belirlenmesinde önemli bir rol oynar.

Herhangi bir frekans için biyolojik dokuların ve organların dielektrik özelliklerini edinmek ve hesaplamak için bazı matematiksel modeller geliştirilmiştir. Debye modeli ve Cole-Cole modeli en popüler modellerdendir. Frekansa bağlı karmaşık geçirgenlik fonksiyonu sıklıkla aşağıda verilen Debye modeli tarafından modellenir [19].

$$\varepsilon^*(\omega) = \varepsilon' - j\varepsilon'' = \varepsilon_\infty + \frac{\varepsilon_s - \varepsilon_\infty}{1 + j\omega\tau} + \frac{\sigma_{dc}}{j\omega\varepsilon_0} \quad (1.1)$$

Bu formülasyonda ε' ve ε'' gerçek ve sanal bağıl geçirgenliklerdir, ε_s sıfır frekanstaki bağıl geçirgenliktir, ε_∞ ise çok yüksek frekanslardaki bağıl geçirgenliktir, τ gevşeme süresi, σ_{dc} statik dc iletkenliğidir ve ε_0 serbest uzay geçirgenliğidir.

Cole-cole denklemi aşağıda verilen denklem ile tanımlanır:

$$\varepsilon^*(\omega) = \varepsilon' - j\varepsilon'' = \varepsilon_\infty + \frac{\varepsilon_s - \varepsilon_\infty}{[1 + j\omega\tau]^{1-\alpha}} + \frac{\sigma_{dc}}{j\omega\varepsilon_0} \quad (1.2)$$

Denklemden yer alan α parametresi, 0 ile 1 arasında değişen bir frekans üssü olarak tanımlanır. İnsan memesinin elektromanyetik özellikleri üzerine bugüne kadar birçok çalışma yapılmış olup, bu çalışmalarda kullanılan parametreler genellikle 10 Hz ile 100 GHz arasında değişen frekans aralıklarında ölçülmektedir [20,21].

1.3.3 Memenin mikrodalga görüntülenmesi

Meme tanı yöntemlerinde bahsedilen Mamografi, MR ve PET nispeten maliyetli, zaman alıcı ve yüksek doz radyasyon nedeniyle zararlı yöntemlerdir. Bu sebepten dolayı, radyasyon riski düşük, ilk muayene ve tanı için kullanabilecek, daha hızlı görüntüleme alternatiflerine ihtiyaç duyulmaktadır. Mikrodalga görüntüleme (MWI) meme kanseri görüntüleme yöntemi için umut vadeden bir alternatiftir ve son yıllarda önceden belirlenmiş dezavantajların ortadan kaldırılması için araştırmalar yapılmıştır, [22].

Mikrodalga görüntüleme yönteminin düşük maliyetli olması, bu görüntüleme yönteminin gelişmekte olan ülkelerde kullanılmasına olanak sağlar. Bu durum, görüntüleme tekniklerinin yetersiz olduğu bölgelerde, kanser kaynaklı ölümlerin azaltılmasına katkı sağlayabilecek umut verici bir yöntem olabilir.

Mikrodalga görüntüleme, görüntülenmek istenen ilgili nesneyi 300 MHz ve 300 GHz frekans aralıklarına sahip iyonlaştırıcı özelliği olmayan elektromanyetik radyasyona sahip mikrodalgalara maruz bırakarak görüntüleme yapar [23]. Bu aralıkta penetrasyon derinliği ve çözünürlük arasında denge vardır [24]. Bu modalitenin çıktısı, nesnenin saçtığı ve ölçülen elektromanyetik alanın yeniden yapılandırılmasına dayalı olarak elde edilen görüntülerdir [22]. Mikrodalga görüntüleme dokular arasındaki dielektrik özellik farkına dayanarak görüntü oluşturur. Dokularda suyun varlığı ve suyun dielektrik özelliklerinin frekansa bağlı olması, dokunun mikrodalga frekanslarındaki elektriksel özelliklerini önemli ölçüde etkiler. Tümör dokularının, çevresindeki sağlıklı dokulara kıyasla daha fazla kan damarı ve sıvı içermesi, uygulanan frekansa bağlı olarak geçirgenlik ve iletkenlik açısından meme kanseri dokusu ile sağlıklı dokular arasında ayırt edilebilir farklar oluşmasına neden olur, [22,25]. Meme dokusu ve tümörlü doku arasında bulunan farklar üzerine çok sayıda çalışma yapılmıştır. Cheng ve diğerleri [24], iyi huylu tümör, normal doku ve kanser

dokuları da dahil olmak üzere memedeki bütün doku çeşitlerinin, verimli dielektrik geçirgenliği ve verimli iletkenlik özellik sergilediğini göstermiştir.



Çizelge 1.1 : Farklı Frekanslarda Üç Meme Dokusunun Mikrodalga Parametreleri.

	Doku Türü	0.5 GHz	2 GHz	4 GHz	6 GHz	8 GHz
ϵ_{eff}	Normal	9.070 ± 0.714	8.163 ± 0.577	7.202 ± 0.428	6.569 ± 0.332	6.292 ± 0.291
	İyi Huylu Tümör	24.842 ± 1.829	21.664 ± 1.559	18.303 ± 1.814	16.093 ± 2.214	15.120 ± 2.423
	Kanser	66.696 ± 2.479	63.008 ± 2.108	59.125 ± 1.802	56.551 ± 1.664	55.425 ± 1.623
	p^a	0.0000	0.0000	0.0000	0.0000	0.0000
	p^b	0.0003	0.0002	0.0002	0.0002	0.0002
$\sigma_{eff},$ S/m	Normal	0.245 ± 0.145	0.497 ± 0.069	0.758 ± 0.119	0.930 ± 0.187	1.006 ± 0.219
	İyi Huylu Tümör	0.279 ± 0.187	0.955 ± 0.122	1.669 ± 0.077	2.139 ± 0.079	2.346 ± 0.877
	Kanser	1.697 ± 0.464	4.164 ± 0.074	6.674 ± 0.356	8.487 ± 0.633	9.242 ± 0.755
	p^a	0.0218	0.0000	0.0011	0.0029	0.0036
	p^b	0.0243	0.0000	0.0004	0.0011	0.0014

Yapılan arařtırmalar, mikrodalga görüntüleme yönteminin kötü huylu tümörleri tespit edebildiğini ve mevcut meme kanseri tanı yöntemlerine etkili bir alternatif olarak değerlendirilebileceğini göstermektedir.

1.4 Yapay Zekâ

Yapay zekâ; insanlara özgü anlama, geçmiş deneyimlerden faydalanarak öğrenme ve problemler karşısında çözüm üretebilme gibi karmaşık zihinsel süreçlerin, bilgisayarlar ya da bilgisayar destekli sistemler tarafından gerçekleştirilebilmesini sağlayan bir teknolojidir. Yapay zekâ ile birlikte sıklıkla anılan iki önemli kavram makine öğrenmesi ve derin öğrenmedir. Her ne kadar uygulama alanlarında zaman zaman birbirlerinin yerine kullanılsalar da bu kavramlar arasında yapısal farklılıklar bulunmaktadır. Makine öğrenmesi, yapay zekânın bir alt dalı olarak sınıflandırılırken, derin öğrenme ise makine öğrenmesinin daha spesifik bir alanını temsil eder. Bu nedenle, her derin öğrenme sistemi aynı zamanda bir makine öğrenmesi yöntemi sayılabilir; ancak her makine öğrenmesi yöntemi, derin öğrenme kapsamına girmez [26].

1.4.1 Autoencoder (AE) mimarisi

Autoencoder (AE) veriyi sıkıřtırmak amacı ile kullanılan bir otokodlayıcıdır. Otokodlayıcı veriyi sıkıřtırır ve veriyi geri açar, görsel kayıba neden olabilir ve eğitilmesi için sisteme örnek veriler vermek gerekir. Bu yöntem verilere bağılıdır. Örneğin insan verileri ile eğitilmiş olan bir sistem, ağaçlar gibi bir nesneyi sıkıřtırırken iyi olmaz, çünkü öğrenme aşamasında veri olarak ağaçlar hakkında bilgi verilmemiştir.

Autoencoder Formülasyonu;

$$f : X \rightarrow F \quad (1.3)$$

$$g : F \rightarrow X \quad (1.4)$$


$$f, g = \operatorname{argmin} ||X - g[f(X)]|^2 \quad (1.5)$$

Burada f ile gösterilen kısım kodlayıcı (encoder) kısmını, g ile gösterilen kısım ise kod çözücü (decoder) kısmını temsil etmektedir [27].

Autoencoder (AE) mimarisinde veri önce sıkıştırılıp daha sonra açıldığı için veride kayıplar meydana gelmektedir. AE verilen veri örneklerinden otomatik olarak öğrenir. AE mimarisi tasarlamak için yapılması gereken 3 adım vardır.

Bunlar;

Kodlayıcı tasarlamak, kod çözücü tasarlamak ve yapılan sıkıştırma nedeniyle ne kadar bilginin kaybolacağını hesaplayan bir kayıp fonksiyonu belirlemek.



Şekil 1.2 : Autoencoder Şeması.

Autoencoder'ın kullanım alanları 4 gruba ayrılmaktadır. Bunlar;

- 1- Veri Sıkıştırma: Verinin boyutunu azaltarak, daha az depolama alanı kullanılmasını sağlar.
- 2- Gürültü Giderme (Denoising Autoencoder): Gürültülü girdilerden, temiz veri elde etmek için kullanılır.
- 3- Anomali Tespiti: Normal veri ile anormal veri arasındaki farkları tespit etmek için kullanılır.
- 4- Öznitelik Öğrenme: Girdi verisinin temel özelliklerini otomatik olarak öğrenir ve öğrenmiş olduğu bu özellikleri farklı görevlerde kullanır.

Autoencoder mimarisi 3 çeşit varyasyona sahiptir. Bunlar;

Denoising Autoencoder: Gürültülü girdilerden en iyi şekilde çıktıyı elde edebilmek amacıyla girdideki gürültülerin temizlenmesinde kullanılır.

Sparse Autoencoder: Girdideki ortaya çıkarılması istenen özelliğin daha baskın şekilde gösterilmesini sağlar.

Variational Autoencoder (VAE): Olasılıksal modelleme yöntemi ile yeni veri örnekleri oluşturmak amacıyla kullanılır.

1.4.2 U-Net mimarisi


U-Net, 2015 yılında Ronneberger ve ekibi tarafından geliştirilen ve görüntü segmentasyonu uygulamalarında yüksek başarı gösteren bir derin öğrenme mimarisidir [28]. U-Net'in geliştirilmesindeki temel amaç, özellikle biyomedikal görüntülerin segmentasyonu için uygun bir model oluşturmaktır. Bu mimarinin dikkat çeken yönü, sınırlı sayıda etiketli veri ile yüksek doğruluk sağlayabilmesidir, ki bu özellik tıbbi verilerde önemli bir avantaj sağlamaktadır.

U-Net'in yapısı, isminden de anlaşılacağı gibi "U" şeklinde bir mimari tasarım ile karakterize edilmiştir. Model, giriş görüntüsünü analiz ederken hem ince detayları hem de bütünsel özellikleri birlikte değerlendirir. U-Net mimarisinin ana bölümleri "downsampling" (alt örnekleme) ve "upsampling" (üst örnekleme) aşamalarından oluşur. Alt örnekleme aşaması, modelin giriş görüntüsündeki özellikleri farklı çözünürlük seviyelerinde öğrenmesini sağlarken, üst örnekleme aşaması ise yüksek çözünürlüklü segmentasyon maskesi üretmeye yöneliktir.

1. Downsampling Aşaması: Bu aşamada, görüntüden özellikler çıkarılır ve özellik haritaları oluşturulur. Konvolüsyon ve maks havuzlama işlemleriyle, her adımda çözünürlük azaltılarak daha derin ve genel özellikler öğrenilir.
2. Bottleneck Katmanı: U-Net'in en dar kısmında, model görüntüden çıkarılan en soyut özellikleri öğrenir. Bu kısım, segmentasyonun başarısını artıran önemli özellikleri daha iyi anlamaya yardımcı olur.
3. Upsampling Aşaması: Bottleneck katmanında öğrenilen özellikler, daha yüksek çözünürlüklü segmentasyon maskesi oluşturmak için yukarı örneklenir. Yukarı örnekleme sırasında, önceki adımlarda öğrenilen özellik haritaları

birleştirilerek (concatenate) daha fazla bilgi aktarılır. Bu aşamada "skip connection" adı verilen bağlantılar kullanılır, böylece orijinal çözünürlükteki bilgiler kaybolmadan yukarı örneklenmiş maskeye taşınır.

U-Net mimarisi, özellikle hücre ve organ segmentasyonu gibi tıbbi görüntü segmentasyonu uygulamalarında yaygın biçimde tercih edilir. Ayrıca, U-Net'in verimli bilgi aktarım yapısı sayesinde, küçük veri setleriyle çalışılan alanlarda da üstün performans gösterdiği kanıtlanmıştır. U-Net'in daha ileri versiyonları, bu temel yapıyı daha da geliştirerek segmentasyon performansını artırmayı hedeflemektedir.



Şekil 1.3 : U-Net Mimarisi Şeması [28].

1.5 Görüntü Segmentasyonu

Görüntü segmentasyonu, benzer özelliklere sahip farklı bölgelere ayırma işlemidir; burada pikseller arasındaki benzerlik ve farklılıklar temel alınır. Özellikle tıbbi görüntüleme, görüntülerin analiz edilmesi, özelliklerin çıkarılması ve görselleştirilmesi açısından segmentasyon büyük önem taşır. Segmentasyon, bazı durumlarda görüntü piksellerini kemik, kas gibi anatomik yapılar doğrultusunda sınıflandırmak için kullanılırken; beyin görüntülerinde beyaz madde, gri madde veya

beyin-omurilik sıvısı gibi alt bölgelere ayırmak için de tercih edilebilir. Ayrıca, kanserli bölgeler veya multipl skleroz (MS) lezyonları gibi hastalıklı alanların tespitinde ya da meme MR görüntülerinde tümör gibi belirli yapıların çıkarılmasında da segmentasyon yöntemleri uygulanmaktadır. Bu yöntemlerin başlıca kullanım alanları arasında tümör boyutunun belirlenmesi ve tedaviye yanıtının izlenmesi, mamogramlarda mikrokalsifikasyonların saptanması, MS lezyonlarının miktarının ölçülmesi, cerrahi planlama ve simülasyonlar, fonksiyonel haritalama, tümör tespiti, görüntülerin kaydı ve eşleştirilmesi, anjiyogramlarda koroner damar sınırlarının belirlenmesi, kan hücrelerinin otomatik sınıflandırılması ve beyin gelişiminin takibi gibi pek çok uygulama yer almaktadır. Tıbbi görüntülerin manuel olarak segmentasyonu hem oldukça zahmetli bir süreçtir hem de insan hatasına açık olabilir; bu nedenle, makine öğrenmesi tekniklerinin kullanımı bu zorlukların üstesinden gelmede etkili bir çözüm sunmaktadır. Bu alanda kayda değer gelişmeler sağlanmış olsa da halen tüm durumlar için genel geçer ve hatasız çalışan bir algoritma geliştirilememiştir; bu nedenle daha etkili çözümler arayışı sürmektedir. Segmentasyon yöntemleri genel olarak veri boyutuna, kullanılan temel yaklaşıma ve denetimli ya da denetimsiz olmalarına göre sınıflandırılmaktadır [29].

1.5.1 Kullanılan verinin boyutuna dayalı segmentasyon

Segmentasyon yöntemleri, kullanılan verinin boyutuna göre iki gruba ayrılır: görüntü tabanlı yöntemler ve hacimsel bilgiye dayalı yöntemler. Görüntü tabanlı yöntemlerde işlem, iki boyutlu görüntüler üzerinde ve piksel düzeyinde gerçekleştirilir. Hacimsel bilgiye dayalı yöntemlerde ise işlem, üç boyutlu veriler üzerinde ve voxel düzeyinde yapılır.

1.5.2 Temel stratejiye dayalı segmentasyon

Strateji açısından bakıldığında, segmentasyon yöntemleri altı ana gruba ayrılır:

Veriye dayalı yöntemler, tıbbi görüntüleri bölütlemek için eşikleme ve bölge büyütme gibi veri odaklı tekniklerden yararlanır.

Eşikleme, sıkça kullanılan bölge tabanlı segmentasyon tekniklerinden biridir. Bu yöntemde, görüntü histogramı ve yerel özellikler dikkate alınarak belirli bir eşik değeri (T) seçilir. Ardından, görüntüdeki pikseller iki gruba ayrılır: değeri T'ye eşit ya da büyük olanlar ve T'den küçük olanlar. Kullanılan eşik sayısına göre farklı eşikleme stratejileri uygulanabilir. Görüntü çift tepe şeklinde bir histogram yapısına sahipse ve

eşikleme işlemi tüm piksel değerleri için sabit bir değer üzerinden yapılıyorsa, bu yöntem global eşikleme olarak adlandırılır. Bu tür bir eşikleme, genellikle nesneyi arka plandan ayırmak için kullanılır ve sonuç ikili bir görüntüdür. Eğer eşik değeri, görüntünün farklı bölgelerinin yerel özelliklerine göre belirleniyorsa, bu yöntem yerel eşikleme olarak tanımlanır. Her bir piksel veya piksel grubu için eşik değeri ayrı ayrı hesaplanıyorsa, bu durum dinamik ya da uyarlanabilir eşikleme olarak ifade edilir. Eşikleme yöntemi, piksel yoğunlukları arasındaki farklara odaklanırken; bölge büyütme yaklaşımı ise benzer yoğunluğa sahip piksel gruplarını belirlemeyi hedefler. Bu yöntemde, algoritma "tohum noktası" olarak adlandırılan bir piksel veya piksel grubuyla başlar. Bu noktalar, hedeflenen yapıyı temsil eder ve kullanıcı tarafından el ile belirlenebileceği gibi, otomatik yöntemlerle de seçilebilir. Ardından, komşu piksellerin benzerliklerine göre bölge genişletilir ve sonuç olarak homojen ve birbirine bağlı alanlar oluşturulur [30].

Öznitelik tabanlı yöntemlerde, görüntülerden çıkarılan çeşitli öznitelikler kullanılarak giriş verisi modellenir. Yoğunluk, enerji ve entropi gibi görüntü öznitelikleri, ilgili analizlerde sıklıkla değerlendirilen parametreler arasında yer alır. Bu yaklaşımda amaç, temel veriden elde edilebilecek tüm anlamlı bilgileri seçilen öznitelikler aracılığıyla ortaya çıkarmaktır. Böylece, sonraki işlem adımlarında kullanılmak üzere verilerin daha net ve temsil edilebilir bir tanımı elde edilir.

Atlas tabanlı yöntemlerde, atlas belirli bir organa ait istatistiksel veya topolojik bilgileri içeren bir harita niteliğindedir. İstatistiksel atlaslar, her bir vokselin belirli bir doku sınıfına ait olma olasılığına ilişkin bilgiler sunar. Topolojik atlaslar ise organın her bir bölümünün geometrik yapısını ve bu bölümlerin bir araya gelerek oluşturduğu yapısal düzeni ifade eder. Bu yöntemlerin kullanılabilmesi için, segmentasyon işleminden önce görüntü kayıt (image registration) işleminin gerçekleştirilmesi gerekmektedir.

İstatistiksel yöntemlerin temel kavramı, olasılık yoğunluk fonksiyonları ve olasılıksal segmentasyonun kullanılmasıdır.

Doku tabanlı yöntemlerin temel amacı, sağlıklı dokuları tanımlamak ve sağlıklı dokuların dışındaki bölgeleri lezyon olarak belirlemektir.

Lezyon tabanlı yöntemlerde amaç, lezyonu doğrudan ya da sağlıklı doku ile birlikte izole etmektir. Doku tabanlı yöntemlerden farklı olarak, lezyon ayrı bir sınıf olarak ele alınır.

1.5.3 İzleme varlığına dayalı segmentasyon

Segmentasyon yöntemlerinin sınıflandırılmasında üçüncü ölçüt, denetim miktarıdır; yani segmentasyon sürecinde insan bilgisinin varlığıdır. Yöntemler, uygulama şekline göre denetimli ya da denetimsiz olarak iki temel kategoriye ayrılmaktadır. Denetimli ve denetimsiz yöntemler arasındaki başlıca farklılık, önceden etiketlenmiş verinin varlığıdır. Denetimsiz yöntemler, manuel olarak etiketlenmiş veriye ihtiyaç duymazken, denetimli yöntemlerin uygulanmasında bu tür veriler kritik bir öneme sahiptir. Denetimsiz yöntemlerde algoritma, benzer pikselleri otomatik olarak sınıflandırır. Görüntü verisi etiketlenmediğinde, segmentasyon kümelenme algoritmaları kullanılarak gerçekleştirilebilir. Bu durumda, eğitim verilerinin etiketlenmesinde insan bilgisinin müdahalesi olmaz. Tüm veri kümesi kümelenme algoritmasına girdi olarak verilir ve algoritmanın yardımıyla kümeler belirlenir. Ayrıca, kümelenme işlemi tamamlandıktan sonra, her küme üyelerinin etiketlenmesi ve anlamlı hale getirilmesi gerekir [31]. Denetimsiz segmentasyonun iki temel amacı vardır: Birincisi, görüntünün aynı anatomik özelliklere sahip homojen bölgelere ayrılmasıdır. İkincisi ise, tıbbi görüntü segmentasyonunda, görüntünün kendisini aynı doku yapısı ve parlaklığa sahip homojen bölgelere bölmektir. Anatomik amaç taşıyan doku segmentasyon yöntemlerinde, görüntü en az iki anatomik açıdan anlamlı bölgeye ayrılmalıdır; bunlardan biri hasar görmüş doku bölgesidir. Bu yöntemlerin çoğu yalnızca iyileşmiş lezyon dokusunun segmentasyonuna odaklanmakta olup, bu da kullanım alanlarını sınırlamaktadır. Bu sınırlamanın temel nedeni, uzman bilgisi ve görsel inceleme yoluyla elde edilen bilginin bilgisayar programına aktarılmasının zorluğudur. Anatomik amaçlı yöntemlerin aksine, görüntü özelliklerine dayanan segmentasyon tekniklerinin hedefi, görüntüyü aynı doku yapısı ve ışık yoğunluğuna sahip homojen bölgelere ayırmaktır. Görüntü özelliklerine dayalı denetimsiz yöntemler ise bazı kısıtlamalara sahiptir: i) bölge sayısının önceden belirlenmesi gerekliliği, ii) hastalıklı dokuların birden fazla bölgeye ayrılabilmesi, iii) hastalıklı doku parlaklığının sağlıklı dokudan çok farklı olmaması iv) sağlıklı ile hastalıklı doku arasındaki sınırın belirgin olmaması. Bu dezavantajların yol açtığı hataları azaltmak için kontrast artırma ve doku dokusuzluğu düzeltme gibi yöntemler kullanılabilir.

Yaygın olarak kullanılan denetimsiz segmentasyon algoritmaları arasında K-means kümelenme, Bulanık c-ortalama kümelenme, Hiyerarşik kümelenme ve Gauss karışım kümelenmesi sayılabilir.

Denetimli segmentasyon algoritmalarında, kullanıcı tarafından sınıflandırılmış veriler algoritmanın ilk eğitimi ve ardından görüntü segmentasyonu için kullanılır. Denetimli segmentasyon iki aşamadan oluşur: Öncelikle sınıflandırılmış verilerle bir model eğitilir, ardından eğitilen model, sınıflandırılmamış veriler üzerinde test edilerek performansı değerlendirilir. Modelin başarısı büyük ölçüde kullanılan veri kümesine bağlıdır, çünkü veri setindeki değişiklikler sonuçlarda sapmalara neden olabilir. Kullanıcı, verilerin sınıf sayısını belirlemekle yükümlüdür. Tıbbi görüntü segmentasyonunda denetimli yöntemler kullanılırken, görüntü genellikle iki sınıfa, sağlıklı doku ve hastalıklı doku, ayrılır ve özellik olarak nokta parlaklık yoğunluğu kullanılır. Eğitim aşamasında, görüntü parlaklığı kullanılarak sağlıklı ve şüpheli dokular ayrılır. Test aşamasında ise eğitilmiş model, sınıflandırılmamış veriyi ayırmak için kullanılır. Denetimli segmentasyonun etkinliği, kullanılan eğitim ve test verilerinin kaynağına bağlıdır. Tıbbi segmentasyon verileri hasta bazlı ya da hasta-dışı olabilir. Hasta bazlı veride, eğitim verisi segmentasyonu yapılacak görüntülerden seçilirken; hasta-dışı modda, eğitim ve test farklı hastalardan elde edilen görüntüler üzerinde gerçekleştirilir. Denetimli yöntemlerin en büyük avantajı, eğitim veri seti değiştirildiğinde farklı görevler için esnek şekilde kullanılabilmesidir. Doğru özellikler ve segmentasyon algoritması seçildiğinde, segmentasyon sürecinde gereken manuel iş yükü azalır. Ancak, bu yöntemlerin temel dezavantajı hasta bazlı veri gereksinimidir. Eğitim verilerinin farklı biçimlerde sınıflandırılmış olması da yöntemin uygulanabilirliğini etkileyen bir diğer güçlük olarak öne çıkar. Denetimli teknikler, sürekli veri için regresyon, ayrık veri için ise sınıflandırma algoritmaları olarak iki gruba ayrılabilir [32].



2. METOT VE MATERYAL

2.1 Mikrodalga Görüntülerinin Oluşturulması

Mikrodalga görüntülerin oluşturulmasında ‘Single-slice microwave imaging of breast cancer by reverse time migration’ isimli makale referans alınmıştır [33]. Yapılan çalışmada meme kanserinin mikrodalga görüntüleme prototipi kullanılarak teşhis edilmesi amaçlanmıştır. Bu prototip görüntüleme algoritması, anten dizisini ve ölçüm yapılandırmasını içermektedir. Sistem, farklı dokuların dielektrik özelliklerindeki değişimleri kullanarak, meme içindeki anormallikleri koronal düzlemde tek dilimli bir görüntü olarak göstermeyi amaçlamaktadır.

Geliştirilen sistem, ortası boşaltılmış katı bir silindirik dielektrik platformdan oluşmaktadır ve içine 18 adet optimize edilmiş Vivaldi anteni yerleştirilmiştir. Bu vivaldi antenler 10 cm yarıçaplıdır ve bir dizi 1.5, 2, 2.5 GHz için ϵ_r 10 ile dolu bir ortamda olacak şekilde tasarlanmıştır. Meme dokusunun konulması için tasarlanan bu boşluğun çevresinde, antenler aracılığıyla mikrodalga saçılma verileri toplanmaktadır. Platform, mikrodalga uyumunu artırarak meme yağı dokusu ile daha iyi bir etkileşim sağlamak ve ölçümler sırasında sinyalin dikey polarizasyonunu korumaktadır. Görüntüleme aşamasında, elektromanyetik saçılmayı tersine çözümleyen ters zaman göçü (RTM) algoritması kullanılmış ve sistemin gerçek ölçümlerle uyumlu çalışması sağlanmıştır.

Senaryoda kullanılan doku tür ve özellikleri şu şekildedir;

Çizelge 2.1 : Doku Özellikleri Tablosu.


Doku Türü	Özellik	Değer Aralığı
Meme	Yarıçap	6-8 cm
	Bağıl Permitive (ϵ_r)	12.5-14
	İletkenlik (σ)	0.2-1.0 S/m
Fibroglandüler	Sayı	1-2
	Bağıl Permitive (ϵ_r)	28-33
	Yarıçap X	1-3 cm
	Yarıçap Y	1-3 cm
	İletkenlik (σ)	1.2-5.0 S/m
Ortam	Bağıl Permitive (ϵ_r)	10
Tümör	Sayı	1
	Bağıl Permitive (ϵ_r)	47-55
	Yarıçap	0.75-1.50 cm
	İletkenlik (σ)	1.2-5.0 S/m
Görüş Alanı	X (cm)	-8.5-8.5 (68 Piksel)
	Y (cm)	-8.5-8.5 (68 Piksel)

Senaryoda kullanılan RTM çalışma ayarları ve anten parametreleri şu şekildedir;

Çizelge 2.2 : RTM Çalışma Ayarları ve Anten Parametreleri.

Parametre	Değerler
Anten Eleman Sayısı	18
Anten Yarıçapı	10 cm
Frekans Spektrumu (GHz)	1.5-2-2.5
Algoritma	RTM
İterasyon Sayısı	250
Çözünürlük	400 x 400 Piksel

Kullanılan senaryonun şekli şu şekildedir;



Şekil 2.1 : Mikrodalga Görüntüleme Anten Yerleşimi ve Elektrik Alan Yayılımı.

Dalga sayısı κ_M olan eşleşme ortamına toplam $N = 18$ adet verici-alıcı anten gömülüdür ve bu antenler silindirik ölçüm alanı Γ üzerine eş açılarla dağıtılmıştır. Kullanılan bu antenler, Ω hacimsel alanlı meme fantomunu $\{\omega_1, \omega_2, \dots, \omega_k\}$ gibi ayırık frekans setleriyle aydınlatır. Γ üzerinde q konumunda bulunan anten, $s \in \Omega$ noktasındaki elektrik alanı $E_i(s, q)$ olarak yaydığında $p \in \Gamma$ konumunda bir anten ile ölçülen saçılan elektrik alan şu şekilde ifade edilebilir:

$$E_s(p, q) = \kappa_M^2 \int_{\Omega} \overline{\overline{G_E}}(p, s) \chi(s) E(s, q) d\Omega(s) \quad (2.1)$$

Burada diyadik elektrik alan Green Fonksiyonu şu şekilde verilir:

$$\overline{\overline{G_E}}(p, s) = \left(\overline{\overline{I}} + \frac{\nabla_P \nabla_P}{\kappa_M^2} \right) \frac{e^{-i\kappa_M |p-s|}}{4\pi |p-s|} \quad (2.2)$$

ve $\overline{\overline{I}}$, birim diyadı ifade eder. Nesne fonksiyonu olarak adlandırılan ifade

$X^{(s)} = \epsilon_B^{(s)} / \epsilon_M - 1$, memenin karmaşık dielektrik geçirgenliği olan

$\epsilon_B(s) = \epsilon_r(s) - i \frac{\sigma(s)}{\omega \epsilon_0}$ ifadesine bağlı olarak değişir. Bu ifadede bulunan ϵ_0 ifadesi

boşluğun dielektrik geçirgenliğini ifade eder. Memenin mikrodalga görüntülemesine yönelik nicel yaklaşımlar, saçılan alan ölçümlerinden memeye ait geçirgenlik $\epsilon_r(s)$ ve iletkenlik $\sigma(s)$ profillerinin çıkarılmasına dayanarak formüle edilir. Öte yandan faktörizasyon yöntemi ve lineer örnekleme yöntemi [34,35] gibi diğer nitel ters saçılma yöntemlerinde olduğu gibi, RTM algoritması da incelenen nesnelerin elektriksel özelliklerini doğrudan çıkarmaya dayanmaz.


Önerilen sistem, gerçek meme dokusunu taklit eden ve farklı dielektrik özelliklere sahip fantomlar üzerinde test edilmiştir. Elde edilen tek dilimli görüntüler, tümör fantomlarının boyutlarını ve yerini doğru bir şekilde belirleyerek sistemin doğruluğunu göstermiştir. Yapılan deneyler, mikrodalga görüntüleme prototipinin başarılı çalıştığını kanıtlamıştır.

Sonuç olarak, geliştirilen prototip sistem, RTM algoritmasıyla meme içindeki anormallikleri tek dilimli ve anatomik olmayan görüntüler şeklinde gösterebilmektedir. Bu görüntülerde görülen sıcak noktalar (hotspots), meme dokusundaki anormal bölgelerin yerini işaret etmektedir [33].



Şekil 2.2 : Segmentasyon Yöntemi ile Elde Edilen Görüntüler.

Mikrodalga Görüntüler;



Şekil 2.3 : Mikrodalga Görüntüler.

2.1.1 RTM metodu

RTM algoritmasında, kaynak dalgaları ve alıcı dalgaları iki yönde işlenir ve bunlar içinde bir korelasyon kurularak bir imaj elde edilir. RTM algoritması, kompleks eşlenik verilerin geri yayılmasını u alanına yönlendiren ve gelen alan ile geri yayılmakta olan alanın çapraz korelasyon normunu hesaplayan iki adımdan oluşur [36].

1- Geri yayılma

Ölçülmüş saçılan alan E_s , görüntüleme alanındaki her bir $z \in \Lambda$ noktasına, radyasyon koşulu altında, geri yayılım yapılarak elde edilir, [37]:

$$\nabla \times \nabla \times E_b(z, q) - \kappa_M^2 E_b(z, q) = -\frac{\alpha}{N} \sum_{n=1}^N \overline{E_s(p_n, q)} \delta(z - q) \quad (2.3)$$

Burada α , her bir antenin eşdeğer açıklığını ifade eder ve üzerindeki çizgi (overline) karmaşık eşleniği göstermektedir. Geri yayılım alanı $E_b(z, q)$, şu şekilde ifade edilebilir:

$$E_b(z, q) = -\frac{\alpha}{N} \sum_{n=1}^N \overline{G_E(z, p_n)}^T \overline{E_s(p_n, q)} \quad (2.4)$$

burada ifadenin üssü olarak verilen T, transpoz işleminin yapıldığını göstermektedir.

2- Çapraz Korelasyon

Çapraz korelasyon formülasyonu görüntüleme alanındaki her bir nokta için şu şekilde ifade edilebilir;

$$\mathcal{P}(z) = \frac{\alpha}{N} \kappa_M^2 \sum_{n=1}^N E_i(z, q_n) \cdot E_b(z, q_n) \quad (2.5)$$

Denklem 2.5 için içerisinde 2.4 denkleminin dahil edilmesiyle şu açık ifade çıkar:

$$\mathcal{P}(z) = -\left(\frac{\alpha}{N} \kappa_M\right)^2 \sum_{n=1}^N \sum_{m=1}^N E_i(z, q_n) \cdot \overline{G_E}(z, p_m)^T \overline{E_s(p_m, q_n)} \quad (2.6)$$

2.2 Veri Ön İşleme ve Görselleştirme

Özellikle görüntü işleme alanında kullanılan derin öğrenme mimarileri, ham verilerle doğrudan eğitildiklerinde genellikle istenilen düzeyde performans gösterememektedir. Bunun temel sebebi, ham görüntü verilerinin farklı çözünürlükler, parlaklık düzeyleri, kontrast oranları ve renk alanlarında yer almasıdır. Bu çeşitlilik, modelin öğrenme sürecini karmaşıktırarak genel performansı olumsuz etkileyebilir. Bu kapsamda, görüntü tabanlı derin öğrenme yaklaşımlarının etkinliğini artırmak amacıyla veri ön işleme adımları vazgeçilmez bir unsur olarak öne çıkar. Özenle ön işleme tabi tutulmuş veriler, modelin daha hızlı ve doğru öğrenmesini sağlayarak başarının temel belirleyicilerinden biri haline gelir.

2.2.1 Verilerin normalizasyonu ve şekillendirilmesi

Derin öğrenme modellerinin başarılı bir şekilde eğitilebilmesi için görüntü verilerinin uygun format ve boyutlara dönüştürülmesi gerekmektedir. Bu amaçla geliştirilen ön işleme fonksiyonu, ham görüntüleri modelin girişine uygun hale getirerek eğitim performansını önemli ölçüde iyileştirir. Söz konusu fonksiyonun temel işleyiş adımları şu şekilde özetlenebilir:

Piksel Değerlerinin Normalizasyonu: Görüntüler, bilgisayarda genellikle 0–255 aralığında tamsayı (uint8) formatında saklanır. Ancak, bu ham piksel değerlerinin doğrudan modele sunulması, öğrenme sürecini olumsuz etkileyebilir. Bu nedenle, piksel değerleri 255'e bölünerek 0 ile 1 aralığına normalize edilir:

`görüntü = görüntü.astype("float32") / 255.0`

Bu işlem, modelin ağırlık güncellemelerini daha dengeli bir şekilde gerçekleştirmesini sağlayarak öğrenme sürecini hem stabilize eder hem de hızlandırır. Boyutların Standardize Edilmesi: Farklı boyutlara sahip görüntüler, doğrudan modele işlenemez.

Bu nedenle, tüm görüntüler sabit bir boyuta getirilir. Bu çalışmada, görüntüler (64, 64, 3) boyutuna yeniden boyutlandırılmıştır:

64×64: Görüntünün genişlik ve yüksekliğini ifade eder.

3: Görüntünün kanal sayısını temsil eder (pseudocolor- renkli görüntüler için 3, gri tonlamalı görüntüler için 1).

Bu standartlaştırma, verinin modelin giriş formatına tam uyumluluğunu sağlar.

Model Uyumlu Girdi Formatı Sağlama: Normalize edilmiş ve yeniden boyutlandırılmış görüntüler, modelin giriş katmanına hatasız bir şekilde aktarılır. Bu işlem sayesinde model, görüntüleri homojen bir yapıda değerlendirebilir ve böylece öğrenme aşamasında daha etkili, stabil ve hızlı sonuçlar elde edilir. Bu adımlar, modelin veriden daha etkin bir şekilde öğrenmesini sağlayarak eğitim sürecinin başarısını artırır.

2.3 Görüntülerin Görselleştirilmesi

Derin öğrenme modellerinin performansını değerlendirmede sayısal metrikler yaygın olarak kullanılsa da özellikle görüntü işleme alanında görsel değerlendirme büyük önem taşımaktadır. Bunun nedeni, sayısal metriklerin görsel kaliteyi tam anlamıyla yansıtmakta yetersiz kalabilmesidir. Model tahminlerinin daha net bir şekilde değerlendirilmesi için, giriş ve çıkış verileri görsel yöntemlerle karşılaştırılmıştır. Bu amaçla, geliştirilen modelin çıktıları, özel bir görüntüleme fonksiyonu aracılığıyla görselleştirilmiştir. Bu fonksiyon, rastgele seçilen 10 farklı örnek görüntü ile modelin bu görüntüler üzerindeki tahminlerini karşılaştırmalı olarak sunar. Böylece, modelin tahmin başarısı, görsel kalite açısından detaylı bir şekilde analiz edilebilmektedir.

Görselleştirme işlemi sırasında yapılan bu karşılaştırmalar, modelin düşük kaliteli görüntüleri ne ölçüde iyileştirdiğini, kontrast düzeylerini nasıl etkilediğini ve görüntünün önemli detaylarını ne kadar koruduğunu değerlendirme imkânı sağlar. Ayrıca, görsel inceleme sayesinde modelin orijinal görüntüdeki kritik detayları koruyup korumadığı ya da kaybettiği açıkça gözlemlenebilir. Bu yöntemin bir diğer avantajı, yalnızca sayısal metriklerle tespit edilemeyen sorunların ortaya çıkarılabilmesidir. Örneğin, SSIM (Yapısal Benzerlik İndeksi) ve PSNR (Tepe Sinyal-Gürültü Oranı) gibi metrikler belirli eşikleri aşırsa dahi, insan gözü için tatmin edici olmayan sonuçlar üretebilir. Bu tür durumlarda, görsel değerlendirme, modelin gerçek performansını anlamak için daha güvenilir bir yöntem olarak öne çıkar.

Özellikle gürültü giderme gibi uygulamalarda, görsel karşılaştırmalar, modelin yalnızca gürültüyü temizlemekle kalmayıp aynı zamanda görüntünün ince detaylarını ve yapısal bütünlüğünü ne ölçüde koruduğunu ortaya koyar. Etkili bir gürültü giderme algoritmasının yalnızca rastgele parazitleri ortadan kaldırmakla kalmayıp, aynı zamanda görüntünün temel yapısal özelliklerini bozulmadan koruyabilmesi gerekmektedir; bu nedenle, görsel analiz, modelin başarısını değerlendirmek ve geliştirilmesi gereken yönleri tespit etmek için olmazsa olmaz ve tamamlayıcı bir yöntem olarak işlev görmektedir.

Bu bağlamda, çalışmada oluşturulan modellerin başarısı sadece sayısal göstergelerle değil, görsel kalite değerlendirmeleriyle de detaylı biçimde ele alınmıştır. Bu değerlendirme yaklaşımı, modelin farklı koşullar altında nasıl performans gösterdiğine dair daha bütüncül ve açıklayıcı bir perspektif sunmuştur.

2.4 Görüntülerin Yüklenmesi

Bu çalışmada, mikrodalga görüntülerinin derin öğrenme modeline düzenli, tutarlı ve etkin bir şekilde aktarılabilmesi amacıyla, veri yükleme sürecini otomatikleştiren ve standartlaştıran `MicrowaveImages` adında özel bir Python sınıfı geliştirilmiştir. Bu sınıf, görüntü verilerinin farklı klasör yapılarında, çeşitli formatlarda ve boyutlarda bulunabileceği durumlara karşı esnek ve modüler bir yapı sunar. Sınıf bünyesinde yer alan `load_from` metodu, hem mikrodalga görüntülerini modelin eğitim ve test süreçlerinde kullanılabilir bir formata dönüştürmeyi amaçlar. Bu dönüşüm, hem modelin giriş verisini doğru bir şekilde anlaması hem de eğitimin kararlılığı açısından büyük önem taşır. Söz konusu metodun çalışma prensibi, aşağıdaki temel adımlar etrafında şekillenmektedir:

Görüntü Dosyalarının Taranması: İlk aşamada, kullanıcının belirttiği dizin (klasör) içinde yer alan ve yaygın görüntü uzantılarına sahip dosyalar (örneğin, .png, .jpg, .jpeg, .bmp) Python'un `os` ve `glob` kütüphaneleri kullanılarak taranır. Bu işlem, geçerli görüntü dosyalarının tespit edilmesini ve işlenmeye hazır hale getirilmesini sağlar.

Görüntülerin Yüklenmesi ve Yeniden Boyutlandırılması: Tespit edilen görüntüler, `PIL` (Python Imaging Library) veya `OpenCV` gibi kütüphaneler aracılığıyla belleğe yüklenir ve önceden tanımlanmış sabit bir boyuta, bu çalışmada 64×64 piksele, yeniden boyutlandırılır. Bu işlem, tüm görüntülerin ortak bir giriş formatına sahip

olmasını sağlayarak, derin öğrenme modellerinin giriş katmanında karşılaşılabilecek boyut uyumsuzluklarını ortadan kaldırır.

Verilerin NumPy Dizisine Dönüştürülmesi: Yeniden boyutlandırılan görüntüler, tek bir NumPy dizisi (array) halinde organize edilerek bellekte saklanır. Bu diziler, görüntü verilerinin vektörleştirilmiş ve optimize edilmiş bir formatta depolanmasını sağlar. Böylece, model eğitim aşamasında verileri etkili ve hızlı biçimde işleyebilir. Ayrıca, NumPy dizileri, TensorFlow veya PyTorch gibi derin öğrenme kütüphaneleriyle GPU (Grafik işlem birimi) hızlandırmalı işlemlerde doğrudan uyumlu olduğundan, veri aktarımı sorunsuz gerçekleşir ve işlem yükü hafifler.

Ön İşleme Seçeneklerinin Entegrasyonu: `load_from` metoduna, gerektiğinde çeşitli ön işleme adımları entegre edilebilir. Örneğin, görüntülerin normalize edilmesi, gri tonlamaya dönüştürülmesi veya piksel değerlerinin $[0, 1]$ aralığına ölçeklenmesi gibi işlemler, veri hazırlık sürecine eklenebilir. Bu işlemler, modelin eğitim sürecinde daha etkili ve doğru çıktılar elde etmesini destekler. Bu otomatikleştirilmiş süreç, büyük ölçekli mikrodalga görüntü verilerinin daha verimli bir şekilde işlenmesini sağlayarak, kullanıcının model geliştirme sürecine daha fazla odaklanmasına olanak tanır. Bu yaklaşım, veri hazırlık sürecindeki manuel çalışmaları sınırlandırarak zaman açısından avantaj sağlamak ve modelin istikrarlı bir şekilde öğrenmesini sağlamaktadır.

2.5 Autoencoder Mimarisinin Oluşturulması

Bu çalışmada geliştirilen autoencoder mimarisi, 64×64 piksel boyutunda ve üç kanallı (pseudocolor) renkli görüntüler üzerinde uygulanmıştır. Modelin temel amacı, gürültülü görüntülerden orijinal (ground-truth) görüntüleri yeniden inşa ederek görüntü kalitesini artırmak ve anlamlı yapısal özellikleri geri kazanmaktır. Bu doğrultuda tasarlanan mimari, simetrik bir yapıda hem kodlayıcı (encoder) hem de çözücü (decoder) katmanlarından oluşmakta olup modern derin öğrenme teknikleriyle desteklenmiştir.

Model Mimarisi: Modelin giriş katmanı, 64×64 piksel boyutunda ve 3 kanallı bir görüntüyü işleyecek şekilde yapılandırılmıştır. Kodlayıcı kısmı, görüntüdeki temel özellikleri çıkararak boyutları küçültmeyi hedefler. Bu süreç şu şekilde ilerler:

Kodlayıcı (Encoder) Yapısı: İlk olarak, 32 filtreye sahip 3×3 boyutunda çekirdekler içeren bir konvolüsyon katmanı (Conv2D) uygulanmıştır. Bu katmanın ardından,

öğrenme sürecini stabilize etmek ve daha hızlı yakınsama sağlamak için bir Batch Normalization katmanı eklenmiştir. Aktivasyon fonksiyonu olarak klasik ReLU yerine LeakyReLU tercih edilmiştir. LeakyReLU, negatif girişlerde küçük bir gradyan sağlayarak öğrenme sürecinin kesintisiz devam etmesine olanak tanır. Uzaysal boyutları azaltmak ve daha soyut özelliklerin öğrenilmesini sağlamak amacıyla 2×2 boyutunda bir MaxPooling2D katmanı eklenmiştir.

İkinci aşamada, filtre sayısı 64'e çıkarılmış ve benzer bir yapı tekrarlanmıştır: konvolüsyon katmanı, Batch Normalization, LeakyReLU ve MaxPooling. Bu katmanlar, modelin daha derin ve karmaşık özellikleri öğrenmesine katkı sağlar. Kodlayıcı kısmının sonlarına doğru, modelin kapasitesini artırmak için 128 ve 256 filtrelili iki ek konvolüsyon katmanı kullanılmış, her birinin ardından Batch Normalization, LeakyReLU ve %30 oranında Dropout katmanları eklenmiştir. Modelin aşırı uyum sağlamasını engellemek için Dropout yöntemi, bazı nöronları rastgele devre dışı bırakarak genelleştirme performansını güçlendirir.

Çözücü (Decoder) Yapısı: Kodlayıcı tarafından sıkıştırılan özelliklerin orijinal görüntü boyutuna geri döndürülmesi amacıyla UpSampling2D katmanları kullanılarak görüntü boyutu kademeli olarak büyütülmüştür. Her UpSampling işleminden sonra, detayların yeniden yapılandırılması için bir konvolüsyon katmanı eklenmiştir. İlk olarak, 128 filtrelili bir konvolüsyon katmanı uygulanmış, ardından Batch Normalization ve LeakyReLU aktivasyonu kullanılmıştır. Benzer bir yapı, 64 filtrelili ikinci bir çözücü katmanında devam ettirilmiştir. Daha düşük düzeyli detayların yeniden oluşturulması için 32 filtrelili bir Conv2D katmanı eklenmiştir. Çıkış katmanında üç filtrelili bir konvolüsyon uygulanmış ve sigmoid aktivasyonu tercih edilmiştir; bu sayede piksel değerleri $[0, 1]$ aralığında normalize edilerek daha gerçekçi ve keskin görüntü sonuçları ortaya çıkar.

Kayıp Fonksiyonu ve Eğitim Süreci: Modelin eğitiminde, Yapısal Benzerlik İndeksi (SSIM) dikkate alınarak özel bir combined_loss fonksiyonu tasarlanmıştır. SSIM, insan gözünün görsel algısına daha yakın bir değerlendirme sunduğundan, görsel kalitenin ölçümünde etkili bir metrik olarak kullanılmıştır. Bu iki metriğin birleşimi, hem piksel düzeyinde doğruluk hem de yapısal bütünlük açısından modelin optimize edilmesini sağlamıştır.

Eğitim sürecinde, modelin kararlılığını ve verimliliğini artırmak için çeşitli callback yöntemleri kullanılmıştır:

Erken Durdurma (EarlyStopping): Eğitim, doğrulama kaybında uzun süreli bir iyileşme gözlenmediğinde durdurulur.


Öğrenme Oranı Azaltma (ReduceLROnPlateau): Eğitimde ilerleme durduğunda öğrenme oranını dinamik olarak azaltır.

En İyi Modeli Kaydetme (ModelCheckpoint): En iyi performansı gösteren model ağırlıklarını kaydeder.

Modelin eğitimi sırasında, eğitim ve doğrulama verilerine ilişkin kayıp değerleri grafiklerle gösterilmiş, böylece modelin optimizasyon süreci detaylı bir şekilde izlenmiştir.


Sonuçlar ve Değerlendirme: Geliştirilen autoencoder mimarisi, mikrodalga görüntüler gibi düşük çözünürlüklü ve gürültülü veriler üzerinde oldukça başarılı sonuçlar üretmiştir. Model, hem nicel (SSIM metrikleri) hem de nitel (görsel kalite) açılardan tatmin edici bir performans sergilemiştir. Esnek ve derin yapısı sayesinde, bu mimarinin benzer görüntü iyileştirme problemlerinde de etkin bir şekilde kullanılabileceği öngörülmektedir. Bu çalışma, autoencoder tabanlı yaklaşımların görüntü işleme alanındaki potansiyelini bir kez daha ortaya koymuştur.

Autoencoder Mimarisi;



Şekil 2.4 : Tezde Kullanılan Autoencoder Mimarisi.


Mimari tasarlanırken oluşturulan katmanların görsel üzerindeki etkilerini görüntülemek için bir girdi verildi ve katmanlarda elde edilen sonuçlar görüntülendi. Autoencoder mimarisi ile elde edilen katman sonuçları;




Şekil 2.5 : Autoencoder Mimarisinin Katman Çıktılarını Görüntülemek İçin Verilen Girdi Görüntü.

Autoencoder senaryosunda her katmanın görsel sonuçları şu şekildedir:


Encoder kısmı katman çıktıları;



Şekil 2.6 : Conv1 İşleminin Görsel Üzerindeki Etkileri.




Şekil 2.7 : Conv2 İşleminin Görsel Üzerindeki Etkileri.




Şekil 2.8 : Conv3 İşleminin Görsel Üzerindeki Etkileri.

Gizli katman kısmı katman çıktıları;




Şekil 2.9 : Conv4 İşleminin Görsel Üzerindeki Etkileri.


Decoder kısmı katman çıktıları;




Şekil 2.10 : Conv5 İşleminin Görsel Üzerindeki Etkileri.



Şekil 2.11 : Conv6 İşleminin Görsel Üzerindeki Etkileri.




Şekil 2.12 : Conv7 İşleminin Görsel Üzerindeki Etkileri.




Şekil 2.13 : Autoencoder Mimarisine Ait Bütün İşlemlerin Uygulanmasından Sonra Elde Edilen Çıktılar.

Autoencoder mimarisinin mikrodalga görüntülere uyarlanması ile elde edilen eğitim ve doğrulama kayıp grafiği;



Şekil 2.14 : Autoencoder Mimarisinin Mikrodalga Görüntülerine Uygulanıp Elde Edilen Eğitim ve Doğrulama Kayıp Grafiği.

Eğitim sürecinde yer almayan, modelin daha önce görmediği test görüntüleri üzerinde Autoencoder mimarisi kullanılarak tahminler gerçekleştirilmiştir. Tahminler şu şekildedir;



Şekil 2.15 : Autoencoder Mimarisinin Yaptığı Tahminler.

Görüntü işleme ve bilgisayarla görme alanında, bir modelin tahmin ettiği görüntüler ile orijinal (ground-truth) görüntüler arasındaki kalite ve benzerlik ölçümü, model performansının nesnel bir şekilde değerlendirilmesi açısından kritik bir öneme sahiptir. Bu amaçla kullanılan en yaygın ve etkili metriklerden biri, insan görsel algısına uygun olarak tasarlanmış Yapısal Benzerlik İndeksi'dir (Structural Similarity Index Measure- SSIM).

SSIM Metriğinin Tanımı ve Matematiksel Formülasyonu:

SSIM, iki görüntü kümesi I_1 (genellikle orijinal/referans görüntü) ve I_2 (modelin tahmin ettiği görüntü) arasındaki yapısal benzerliği ölçmek için matematiksel bir formülle ifade edilir. SSIM'in temel amacı, parlaklık, kontrast ve yapısal uyum gibi temel bileşenleri aynı anda değerlendirerek, yalnızca piksel bazlı mutlak farkları ölçen geleneksel metriklerden daha anlamlı ve algısal olarak tutarlı sonuçlar üretmektir. SSIM metriği şu formülle hesaplanır:

$$SSIM(I_1, I_2) = \frac{(2\mu_x\mu_y + c_a)(2\sigma_{12} + c_b)}{(\mu_1^2 + \mu_2^2 + c_a)(\sigma_1^2 + \sigma_2^2 + c_b)} \quad (2.7)$$

Bu formülde μ_x ve μ_y değeri, I_1 ve I_2 isimli görüntülerin ortalama piksel değerleridir, σ_1 ve σ_2 her iki görüntünün piksel değerlerinin varyanslarıdır, σ_{12} iki görüntü arasındaki kovaryanstır, c_a ve c_b numerik kararlılığı sağlamak için formüle eklenen sabitlerdir [38].

Bu yapı, SSIM'in parlaklık, kontrast ve yapısal benzerlik bileşenlerini eş zamanlı olarak değerlendirmesine olanak tanır. Formülün pay kısmında parlaklık ve yapısal benzerlik terimleri, payda kısmında ise parlaklık ve kontrastın karelerinin toplamı yer alır. Bu kombinasyon, iki görüntünün görsel algıya uygun bir şekilde ne kadar benzer olduğunu nicel olarak ifade eder.

SSIM Değerinin Yorumlanması:

SSIM metriği normalize bir ölçüttür ve değerleri 0 ile 1 arasında değişir:

0 değeri: İki görüntü arasında yapısal olarak hiçbir benzerlik olmadığını, yani görüntülerin tamamen farklı olduğunu gösterir.

1 değeri: İki görüntünün piksel bazında tamamen aynı olduğunu, yani modelin tahmininin orijinal görüntüyle tam anlamıyla örtüştüğünü belirtir.

Ara değerler: Görüntülerin yapısal benzerlik derecesini kademeli olarak ifade eder. Örneğin, 0.9'un üzerindeki SSIM değerleri yüksek kalite ve benzerlik gösterirken, 0.7 civarındaki değerler modelin hala belirgin farklılıklar içerdiğine işaret eder.


SSIM'in Avantajları ve Kullanım Alanları:

SSIM, özellikle medikal görüntü işleme, süper çözünürlük, gürültü giderme, görüntü sıkıştırma ve segmentasyon gibi alanlarda yaygın olarak kullanılmaktadır. Bunun temel nedeni, SSIM'in insan görsel sisteminin yapısal algısını daha iyi taklit etmesi ve piksel bazlı mutlak fark ölçümlerine kıyasla daha anlamlı sonuçlar sunmasıdır. Ayrıca, SSIM'in yerel bölgelerde de hesaplanabilmesi, görüntü kalitesindeki lokal değişimlerin analizine olanak sağlar. Bu özellik, modelin performansının güçlü ve zayıf olduğu alanların belirlenmesinde önemli bir araç sunar.

Bu çalışmada, mikrodalga görüntülerin iyileştirilmesi ve segmentasyonu gibi uygulamalarda, SSIM metriği, model çıktılarının orijinal görüntülerle yapısal benzerliklerini nesnel bir şekilde değerlendirmek için kullanılmıştır. SSIM, modelin görsel kalite açısından ne kadar başarılı olduğunu ölçmek ve optimize etmek için ideal bir kriter olarak öne çıkmıştır. Bu metrik, yalnızca piksel düzeyinde doğruluk değil, aynı zamanda yapısal bütünlük ve insan algısına uygunluk açısından da model performansını değerlendirmede güvenilir bir yöntem sunar.

Sonuç olarak, SSIM, görüntü işleme alanında model performansını analiz etmek ve optimize etmek için güçlü ve yaygın bir araçtır. Bu çalışma kapsamında, mikrodalga görüntülerin kalitesini iyileştirme ve yapısal özelliklerini koruma başarısını değerlendirmede önemli bir rol oynamıştır.

Autoencoder mimarisi uygulandığında orijinal görüntü ve tahmin edilen görüntü arasındaki SSIM değeri 0,9419 şeklinde bulunmuştur. Bu sonuç görsellerin birbirlerine oldukça yakın olduğunu belirtmektedir. Bu çıkarım ise çıkan sonucun 1'e yakın olmasından dolayı yapılabilmektedir.



Şekil 2.16 : Autoencoder Mimarisinin SSIM Raporu.

2.6 U-Net Mimarisinin Oluşturulması

Bu çalışmada geliştirilen U-Net tabanlı derin öğrenme modeli, 64×64 piksel boyutunda ve sahte renk (pseudocolor) formatında (3 kanallı) mikrodalga görüntüleri üzerinde eğitilmiştir. Modelin temel amacı, bozulmuş (gürültülü) giriş görüntülerinden orijinal (ground-truth) görüntüleri yeniden inşa ederek görsel kaliteyi iyileştirmek ve anlamlı sonuçlar üretmektir. Bu bağlamda, özellikle tıbbi görüntü işleme alanında yüksek doğruluk ve düşük kayıp değerleriyle öne çıkan U-Net mimarisi tercih edilmiştir.

U-Net Model Mimarisi: U-Net modeli, kodlayıcı (encoder) ve çözücü (decoder) olmak üzere iki ana bölümden oluşan simetrik bir yapıya sahiptir. Kodlayıcı kısmı, görüntüdeki düşük seviyeli özellikleri (kenarlar, dokular vb.) daha soyut özelliklere dönüştürmeyi amaçlarken, çözücü kısmı bu temsilleri kullanarak yüksek çözünürlüklü yeni bir görüntü üretir. Modelin yapısı şu şekilde detaylandırılabilir:

- 1- Kodlayıcı (Encoder) Yapısı: Kodlayıcı bölümü, her biri iki adet konvolüsyon katmanı (Conv2D) ve bir adet maksimum havuzlama katmanı (MaxPooling2D) içeren bloklardan oluşur. Bu yapı, uzamsal boyutları kademeli olarak azaltırken kanal sayısını artırarak daha karmaşık ve derin özelliklerin öğrenilmesini sağlar. Kodlayıcı kısmının detayları şöyledir:

Giriş Katmanı: 64 filtreli iki adet Conv2D katmanı ile başlar. Bu katmanlar, görüntüdeki temel yapıları öğrenir. Her konvolüsyon katmanından sonra Batch Normalization ve ReLU aktivasyon fonksiyonu uygulanır.

Havuzlama: Uzamsal boyutları yarıya indirmek için 2×2 boyutunda bir MaxPooling2D katmanı kullanılır. Bu işlem, verinin daha derin katmanlara aktarılmasını sağlar.

İlerleyen Bloklar: Kodlayıcı, sırasıyla 128, 256 ve 512 filtreli konvolüsyon bloklarıyla devam eder. Her blok, iki Conv2D katmanı, Batch Normalization, ReLU ve MaxPooling içerir. Bu yapı, farklı çözünürlük seviyelerindeki özellikleri öğrenmeyi mümkün kılar.

- 2- Geçiş Bloğu (Bottleneck): Kodlayıcı ve çözücü arasındaki bağlantıyı sağlayan geçiş bloğu, 1024 filtreli iki Conv2D katmanından oluşur. Bu bölüm, modelin en soyut ve yoğun özelliklerin öğrenildiği alandır. Batch Normalization ve ReLU burada da kullanılarak öğrenme süreci stabilize edilir.

- 3- Çözücü (Decoder) Yapısı: Çözücü kısmı, kodlayıcıdan gelen sıkıştırılmış özellikleri orijinal görüntü boyutuna geri döndürmeyi amaçlar. Bu süreçte:

Transpoze Konvolüsyon: Uzamsal boyutları büyötmek için Conv2DTranspose katmanları kullanılır. Her UpSampling adımından sonra bir Conv2D katmanı ile detaylar yeniden yapılandırılır.

Atlama Bağlantıları (Skip Connections): Kodlayıcı katmanlarından gelen ara çıktıları, çözücü katmanlarına kopyalanarak birleştirilir. Bu bağlantılar, düşük seviyeli detayların korunmasını sağlayarak bilgi kaybını önler. Çözücü, sırasıyla 512, 256, 128 ve 64 filtreli konvolüsyon bloklarıyla ilerler. Her blokta, kodlayıcıdan gelen özellik haritalarıyla birleştirme yapılır.

Çıkış Katmanı: Modelin son katmanı, sahte renk (pseudocolor) kanallarını temsil eden 3 filtreli bir Conv2D katmanı ve sigmoid aktivasyon fonksiyonundan oluşur. Sigmoid, piksel değerlerini [0, 1] aralığına normalize ederek doğal görüntü çıktıları üretir.

Eğitim Süreci ve Kayıp Fonksiyonu: Model, binary_crossentropy kayıp fonksiyonu kullanılarak eğitilmiştir. Bu fonksiyon, piksel bazlı görevlerde etkili sonuçlar sunar. Eğitim, 50 epoch boyunca, 32'lik bir batch size ile gerçekleştirilmiş ve her epoch'ta doğrulama verileri üzerinde model performansı izlenmiştir. Ayrıca, EarlyStopping, ReduceLROnPlateau ve ModelCheckpoint gibi callback yöntemleri kullanılarak eğitim süreci optimize edilmiştir.


Performans Değerlendirmesi: Modelin başarımı, doğruluk (accuracy) metriğinin yanı sıra Yapısal Benzerlik İndeksi (SSIM) ile değerlendirilmiştir. SSIM, insan görsel algısına daha yakın bir ölçüt sunarak, modelin görsel kalite açısından performansını doğru bir şekilde yansıtır. Bu metrik, piksel bazlı doğrulukla birlikte yapısal bütünlüğü de dikkate alarak modelin başarısını ölçer.

Avantajlar ve Sonuçlar: U-Net mimarisinin en önemli avantajı, kodlayıcıdan çözücüye aktarılan atlama bağlantıları sayesinde düşük ve yüksek seviyeli özelliklerin birleştirilmesidir. Bu yapı, klasik kodlayıcı-çözücü modellerinde sıkça görölen bilgi kaybını azaltır ve daha hassas segmentasyon sağlar. Ayrıca,

farklı çözünürlük seviyelerindeki bilgileri entegre ederek daha derin ve anlamlı analizler yapılmasına olanak tanır.

Sonuç olarak, geliştirilen U-Net modeli, mikrodalga görüntülerin iyileştirilmesi ve segmentasyonunda başarılı sonuçlar vermiştir. Gürültülü giriş görüntülerini, orijinal görüntülere yakın, net ve yapısal olarak tutarlı çıktılara dönüştürmüştür. Bu yaklaşım, özellikle tıbbi görüntüleme gibi yüksek hassasiyet gerektiren alanlarda önemli bir potansiyel taşımaktadır.


U Net mimarisi;



Şekil 2.17 : Tezde Kullanılan U-Net Mimarisi.

Mimari tasarlanırken oluşturulan katmanların görsel üzerindeki etkilerini görüntülemek için bir girdi verildi ve katmanlarda elde edilen sonuçlar görüntülendi.


Girdi olarak verilen görüntü;




Şekil 2.18 : U-Net Mimarisinin Katman Çıktılarını Görüntülemek İçin Verilen Girdi Görüntü.

U-Net senaryosunda her katmanın görsel sonuçları şu şekildedir:


Encoder kısmı katman çıktıları;




Şekil 2.19 : Conv1_1 Katmanının Görsel Üzerindeki Etkileri.




Şekil 2.20 : Conv1_2 Katmanının Görsel Üzerindeki Etkileri.




Şekil 2.21 : Conv2_1 Katmanının Görsel Üzerindeki Etkileri.




Şekil 2.22 : Conv2_2 Katmanının Görsel Üzerindeki Etkileri.




Şekil 2.23 : Conv3_1 Katmanının Görsel Üzerindeki Etkileri.



Şekil 2.24 : Conv3_2 Katmanının Görsel Üzerindeki Etkileri.



Şekil 2.25 : Conv4_1 Katmanının Görsel Üzerindeki Etkileri.



Şekil 2.26 : Conv4_2 Katmanının Görsel Üzerindeki Etkileri.




Şekil 2.27 : Conv4_2 Katmanının Görsel Üzerindeki Etkileri.

Bottleneck kısmı katman çıktıları;



Şekil 2.28 : Conv5_2 Katmanının Görsel Üzerindeki Etkileri.




Şekil 2.29 : Conv5_2 Katmanının Görsel Üzerindeki Etkileri.


Decoder kısmı katman çıktıları;




Şekil 2.30 : Conv6_1 Katmanının Görsel Üzerindeki Etkileri.




Şekil 2.31 : Conv6_2 Katmanının Görsel Üzerindeki Etkileri.




Şekil 2.32 : Conv6_2 Katmanının Görsel Üzerindeki Etkileri.




Şekil 2.33 : Conv7_1 Katmanının Görsel Üzerindeki Etkileri.



Şekil 2.34 : Conv7_2 Katmanının Görsel Üzerindeki Etkileri.




Şekil 2.35 : Conv2d_Transpose_2 Katmanının Görsel Üzerindeki Etkileri.




Şekil 2.36 : Conv8_1 Katmanının Görsel Üzerindeki Etkileri.




Şekil 2.37 : Conv8_2 Katmanının Görsel Üzerindeki Etkileri.



Şekil 2.38 : Conv2d_Transpose_3 Katmanının Görsel Üzerindeki Etkileri.




Şekil 2.39 : Conv9_1 Katmanının Görsel Üzerindeki Etkileri.




Şekil 2.40 : Conv9_2 Katmanının Görsel Üzerindeki Etkileri.

Bütün işlemlerin uygulanmasından sonra elde edilen çıktılar;




Şekil 2.41 : U-Net Mimarisine Ait Bütün İşlemlerin Uygulanmasından Sonra Elde Edilen Çıktılar.

U net mimarisinin mikrodalga görüntülere uyarlanması ile elde edilen eğitim ve doğrulama kayıp grafiği;




Şekil 2.42 : U-Net Mimarisinin Eğitim ve Doğrulama Kayıp Grafiği.

Eğitim sürecinde yer almayan, modelin daha önce görmediği test görüntüleri üzerinde U-Net mimarisi kullanılarak tahminler gerçekleştirilmiştir. Tahminler şu şekildedir;



Şekil 2.43 : U-Net Mimarisinin Mikrodalga Görüntüler Üzerindeki Tahmin Sonuçları.

U-Net mimarisi uygulandığında orijinal görüntü ve tahmin edilen görüntü arasındaki SSIM değeri 0,9627 şeklinde bulunmuştur. Bu sonuç görsellerin birbirlerine oldukça yakın olduğunu belirtmektedir. Bu çıkarım ise çıkan sonucun 1 sayısına yakın olmasından dolayı yapılabilmektedir.



Şekil 2.44 : U-Net Mimarisi SSIM Skoru Grafiği.

2.7 Eğitim Aşaması

Yapay zekâ sistemlerinin eğitilmesi, bir modelin belirli bir görevi doğru, etkin ve verimli bir şekilde gerçekleştirebilmesi için temel bir süreçtir. Yapay zekâ sistemlerinin eğitim süreci, modelin veri setlerinden öğrenmesini sağlayarak, bu öğrenmeyi genelleştirme yeteneği kazandırır ve modelin daha önce karşılaşmadığı durumlara uyarlanabilir çözümler üretmesine olanak tanır. Bu süreçte model, görevle ilgili örüntüleri ve ilişkileri veri setlerinden çıkararak öğrenir. Burada temel amaç, modelin verileri ezberlemesi değil, verilerdeki anlamlı yapıları ve ilişkileri kavrayarak, yeni ve görülmemiş veri örnekleri üzerinde doğru tahminler veya çıktılar üretebilmesidir.

Eğitim sürecinde model, veri setlerinde bulunan gürültü veya alakasız bilgilere takılmadan, hedeflenen örüntülere ve yapılar odaklanmayı öğrenir. Bu odaklanma, modelin performansını optimize ederken hata oranını en aza indirmede kritik bir rol oynar. Dolayısıyla, eğitim süreci, modelin görevini yüksek doğrulukla yerine getirebilmesi için vazgeçilmez bir aşama olarak öne çıkar. Eğitim, yalnızca verilerin tanınmasını değil, aynı zamanda modelin görev odaklı bilgiyle donatılmasını ve bu bilgiyi pratik problemlere uygulayabilmesini sağlar.

Eğitim sürecinin temel bileşenleri; veri hazırlığı, model mimarisinin tasarımı ve hiperparametre optimizasyonu olarak sıralanabilir. Veri hazırlığı, modelin öğrenme sürecinin başarısını doğrudan etkileyen bir aşamadır ve verinin temizlenmesi, normalleştirilmesi ve uygun şekilde yapılandırılmasını içerir. Model mimarisi, görevin gereksinimlerine uygun bir yapay sinir ağı veya başka bir öğrenme modeli tasarlanmasını ifade eder. Hiperparametre ayarları ise modelin öğrenme sürecini optimize etmek için kullanılan yapılandırma parametrelerinin dikkatle belirlenmesini kapsar.

Eğitim süreci, bir yapay zekâ sisteminin işlevsel hale gelmesi ve hedeflenen problemde etkin bir şekilde çalışabilmesi için kritik bir öneme sahiptir. Yetersiz veya hatalı bir eğitim süreci, modelin genelleme yapamamasına, düşük performans sergilemesine ve beklenen sonuçları üretememesine yol açabilir. Bu nedenle, eğitim sürecinin titizlikle planlanması, uygulanması ve değerlendirilmesi, yapay zekâ sistemlerinin başarısı için hayati bir öneme sahiptir.

Autoencoder mimarisi hiperparametreleri;

Epochs	150
Learning rate	0.001
Batch Size	16
Optimization	Adam


Şekil 2.45 : Autoencoder Mimarisi Hiperparametreleri.

U-Net mimarisi hiperparametreleri;

Epochs	50
Learning rate	0.001
Batch Size	32
Optimization	Adam

Şekil 2.46 : U-Net Mimarisi Hiperparametreleri.

2.8 Autoencoder ve U-Net Mimarisinin Karşılaştırılması



Şekil 2.47 : Autoencoder ve U-Net Mimarisinin Karşılaştırılması.

Bu çalışmada gerçekleştirilen deneysel analizde, mikrodalga görüntü işleme alanında kullanılan iki farklı derin öğrenme mimarisi, Autoencoder ve U-Net modeli, performans açısından karşılaştırılmıştır. Değerlendirme ölçütü olarak Yapısal Benzerlik İndeksi (SSIM) kullanılmış ve her iki modelin görüntü iyileştirme yetkinlikleri nesnel bir şekilde analiz edilmiştir.

Deney sonuçlarına göre, Autoencoder modeli ortalama 0,9419 SSIM değerine ulaşırken, U-Net modeli 0,9627 SSIM değeri elde etmiştir. Bu sonuçlar, U-Net mimarisinin Autoencoder'a kıyasla yaklaşık %2,21 daha yüksek yapısal benzerlik sunduğunu göstermektedir. Her iki modelin de yüksek SSIM değerleri, orijinal (ground-truth) görüntülere yakın çıktılar ürettiğini ortaya koymakla birlikte, U-Net modeli, detayların korunması ve görsel kalitenin iyileştirilmesi açısından belirgin bir üstünlük sağlamıştır.



3. SONUÇLAR

Bu çalışmada, mikrodalga görüntüleme yöntemi ile elde edilen görüntüler kullanılarak tümörlü dokuların segmentasyonu amaçlanmıştır. Sentetik olarak üretilmiş görüntüler RTM (Reverse Time Migration) yöntemiyle mikrodalga görüntülere dönüştürülmüş, ardından bu görüntüler karşılık geldikleri segmentasyon haritalarıyla eşleştirilerek Autoencoder ve U-Net tabanlı derin öğrenme mimarileriyle eğitilmiştir.

Her iki mimari de düşük kaliteli ve gürültülü mikrodalga görüntülerden, tümörlü bölgeleri belirgin hale getiren segmentasyon çıktıları üretme konusunda başarılı sonuçlar vermiştir. Ancak model karşılaştırmaları sonucunda, U-Net mimarisinin tümörlü dokuların yapısal detaylarını daha iyi koruduğu ve hedef segmentasyon haritalarına Autoencoder'a kıyasla daha yakın çıktılar sunduğu gözlemlenmiştir. Autoencoder mimarisi ise sade yapısına rağmen genel görüntü yapısını başarılı şekilde yeniden inşa etmiş, ancak tümör sınırlarında yeterli duyarlılığı her durumda sağlayamamıştır.

Elde edilen görsel ve nicel sonuçlar, mikrodalga görüntülerde tümörlü dokuların tespiti ve segmentasyonu açısından derin öğrenme tabanlı yaklaşımların etkili olduğunu, özellikle U-Net mimarisinin bu alanda klinik açıdan daha güvenilir çıktılar üretme potansiyeline sahip olduğunu göstermektedir.



KAYNAKLAR

- [1] **De Azevedo-Marques, P. M., Mencattini, A., Salmeri, M., & Rangayyan, R. M. (Eds.).** (2017). Medical image analysis and informatics: computer-aided diagnosis and therapy. CRC Press.
- [2] **Wang, Z., Lim, E. G., Tang, Y., & Leach, M.** (2014). Medical applications of microwave imaging. The Scientific World Journal, 2014.
- [3] **National Research Council.** (1994). Microwave processing of materials (Vol. 473). National Academies Press.
- [4] **Conceição, R. C., Mohr, J. J., & O'Halloran, M. (Eds.).** (2016). An introduction to microwave imaging for breast cancer detection. Basel, Switzerland:: Springer International Publishing.
- [5] **Semenov, S.** (2009). Microwave tomography: a review of the progress towards clinical applications. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, 367(1900), 3021- 3042.
- [6] **Aldhaeabi, M. A., Alzoubi, K., Almoneef, T. S., Bamatraf, S. M., Attia, H., & Ramahi, O. M.** (2020). Review of microwaves techniques for breast cancer detection. Sensors, 20(8), 2390.
- [7] **Lazebnik, M., Popovic, D., McCartney, L., Watkins, C. B., Lindstrom, M. J., Harter, J., ... & Hagness, S. C.** (2007). A large-scale study of the ultrawideband microwave dielectric properties of normal, benign, and malignant breast tissues obtained from cancer surgeries. Physics in medicine & biology, 52(20), 6093.
- [8] **Rangayyan, R.M., El-Faramawy, N.M., Desautels, J.L. and Alim, O.A.** (1997). Measures of acutance and shape for classification of breast tumors, IEEE Transactions on medical imaging, 16(6), 799–810.
- [9] **Dishali, M.J., Kumar, K.M. and Nawaz, S.M.** (2019). Design of microstrip patch antenna for brain cancer detection, Ictact Journal on Microelectronics, 5(1).
- [10] **Kırkgöz, H. and Kurt, O.** (2022). Distance Dependent Performance of Microstrip Patch Antenna for Breast Tumor Detection, International Congress of New Horizons in Sciences Proceedings Book, INCOHIS, pp.92–102.
- [11] **Url-1**, Breast cancer statistics and resources, <https://www.bcrf.org/breast-cancer-statistics-and-resources/>, date retrieved 15.10.2022.
- [12] **Slimi, M., Jmai, B., Mendes, P. and Gharsallah, A.** (2019). Breast cancer detection based on CPW antenna, 2019 IEEE 19th Mediterranean Microwave Symposium (MMS), pp.1–4.
- [13] **Dhah, P., Moghaddam, M.** (2017) Super Resolution For Microwave Imaging: A Deep Learning Approach, 2017 IEEE International Symposium on Antennas and Propagation & USNC/URSI National Radio Science Meeting.
- [14] **Ruiz, A.Y., Cavagnaro M. And Crocco L.** (2022) IEEE TRANSACTIONS ON ANTENNAS AND PROPAGATION, VOL. 70, NO. 8.
- [15] **He, Z., Chen, Z., Tan, M., Elingarami, S., Liu, Y., Li, T., Deng, Y., He, N., Li, S., Fu, J. et al.** (2020). A review on methods for diagnosis of breast cancer cells and tissues, Cell proliferation, 53(7), e12822.
- [16] **Jafari, S.H., Saadatpour, Z., Salmaninejad, A., Momeni, F., Mokhtari, M., Nahand, J.S., Rahmati, M., Mirzaei, H. and Kianmehr, M.** (2018). Breast cancer diagnosis: Imaging techniques and biochemical markers, Journal of cellular physiology, 233(7), 5200–5213.

- [17] **Wellings, E., Vassiliades, L. and Abdalla, R.** (2016). Breast cancer screening for high-risk patients of different ages and risk-which modality is most effective?, *Cureus*, 8(12).
- [18] **Alcantara, D., Leal, M.P., García-Bocanegra, I. and García-Martín, M.L.** (2014). Molecular imaging of breast cancer: present and future directions, *Frontiers in chemistry*, 2, 112.
- [19] **Mann, R.M., Kuhl, C.K., Kinkel, K. and Boetes, C.** (2008). Breast MRI: guidelines from the European society of breast imaging, *European radiology*, 18, 1307–1318.
- [20] **He, Z., Chen, Z., Tan, M., Elingarami, S., Liu, Y., Li, T., Deng, Y., He, N., Li, S., Fu, J. et al.** (2020). A review on methods for diagnosis of breast cancer cells and tissues, *Cell proliferation*, 53(7), e12822.
- [21] **Kadir Al-Nahyun, S.A., Mahbub, F., Islam, R., Akash, S.B., Hasan, R.R. and Rahman, M.A.** (2021). Performance Analysis of Microstrip Patch Antenna for the Diagnosis of Brain Cancer & Tumor using the Fifth-Generation Frequency Band, 2021 IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS), pp.1–6.
- [22] **Bland, K.I., Copeland, E.M., Klimberg, V.S. and Gradishar, W.J.** (2023). *The Breast-E-Book: Comprehensive Management of Benign and Malignant Diseases*, Elsevier Health Sciences.
- [23] **Gulich, R., Köhler, M., Lunkenheimer, P. and Loidl, A.** (2009). Dielectric spectroscopy on aqueous electrolytic solutions, *Radiation and environmental biophysics*, 48, 107–114.
- [24] **Gupta, A., Zhang, H. and Huang, J.** (2019). The recent research and care of benign breast fibroadenoma, *Yangtze Medicine*, 3(2), 135–141.
- [25] **Hasgall, P.A., Di Gennaro, F., Baumgartner, C., Neufeld, E., Lloyd, B., Gosselin, M., Payne, D., Klingenböck, A. and Kuster, N.** (2018). IT'IS Database for thermal and electromagnetic parameters of biological tissues, Version 4.0.
- [26] **Said Camilleri, J., Farrugia, L., Curto, S., Rodrigues, D.B., Farina, L., Caruana Dingli, G., Bonello, J., Farhat, I. and Sammut, C.V.** (2022). Review of thermal and physiological properties of human breast tissue, *Sensors*, 22(10), 3894.
- [27] **Janjic, A., Cayoren, M., Akduman, I., Yilmaz, T., Onemli, E., Bugdayci, O. and Aribal, M.E.** (2021). SAFE: A novel microwave imaging system design for breast cancer screening and early detection—Clinical evaluation, *Diagnostics*, 11(3), 533.
- [28] **Ohring, M. and Kasprzak, L.** (2014). *Reliability and failure of electronic materials and devices*, Academic Press.
- [29] **Cheng, Y. and Fu, M.** (2018). Dielectric properties for non-invasive detection of normal, benign, and malignant breast tissues using microwave theories, *Thoracic cancer*, 9(4), 459–465.
- [30] **Nikolova, N.K.** (2011). Microwave imaging for breast cancer, *IEEE microwave magazine*, 12(7), 78–94.
- [31] **Ren, Z.** (2022). The Advance of Generative Model and Variational Autoencoder, 2022 IEEE Conference on Telecommunications, Optics and Computer Science (TOCS).

- [32] **Ronneberger, O., Fischer P., and Brox T.** (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation, Medical Image Computing and Computer-Assisted Intervention (MICCAI), 2015, pp. 234–241.
- [33] **Kaelin, B., & Guitton, A.** (2006). Imaging condition for reverse time migration. In SEG Technical Program Expanded Abstracts 2006 (pp. 2594-2598). Society of Exploration Geophysicists.
- [34] **Bilgin, E., Çayören, M., Joof, S., Cansız, G., Yılmaz, T., & Akduman, İ.** (2022). Single-slice microwave imaging of breast cancer by reverse time migration. *Medical Physics*.
- [35] **Kumar, B., Kumar, S. B., & Kumar, C.** (2013). Development of improved SSIM quality index for compressed medical images. In *Proceedings of the 2013 IEEE Second International Conference on Image Information Processing (ICIIP-2013)*.
- [36] **Meng, S., Haddar, H. and Cakoni, F.** (2014). The factorization method for a cavity in an inhomogeneous medium, *Inverse Problems*, 30(4), 045008.
- [37] **S. Russell and P. Norvig**, *Artificial Intelligence: A Modern Approach*, 3rd ed. Upper Saddle River, NJ, USA: Prentice Hall, 2016.
- [38] **Cakoni F, Colton D.A**, Qualitative Approach to Inverse Scattering Theory. Springer; 2014.
- [39] **Çayören M, Akduman İ**, Continuous monitoring of hemorrhagic strokes via differential microwave imaging. In: Crocco L, Karanasiou I, James ML, Conceição RC, eds. *Emerging Electromagnetic Technologies for Brain Diseases Diagnostics, Monitoring and Therapy*. Springer International Publishing; 2018:37–57.
- [40] **Chen J, Chen Z, Huang G**, Reverse time migration for extended obstacles: acoustic waves. *Inverse Probl.* 2013;29:085005.
- [41] **Danelakis, A., Theoharis, T. and Verganelakis, D.A.** (2018). Survey of automated multiple sclerosis lesion segmentation techniques on magnetic resonance imaging, *Computerized Medical Imaging and Graphics*, 70, 83–100.
- [42] **Corbex, M., Burton, R. and Sancho-Garnier, H.** (2012). Breast cancer early detection methods for low and middle income countries, a review of the evidence, *The Breast*, 21(4), 428–434.
- [43] **Bezdek, J.C., Hall, L. and Clarke, L.** (1993). Review of MR image segmentation techniques using pattern recognition., *Medical physics*, 20(4), 1033–1048.
- [44] **Nasteski, V.** (2017). An overview of the supervised machine learning methods, *Horizons*. b, 4, 51–62.



ÖZGEÇMİŞ

Ad-Soyad : Özlem Bahar

ÖĞRENİM DURUMU:

- **Ön Lisans** : 2017, İstanbul Üniversitesi, TBMYO, Biyomedikal Cihaz Teknolojisi
- **Lisans** : 2022, İstanbul Yeni Yüzyıl Üniversitesi, Mimarlık ve Mühendislik Fakültesi, Biyomedikal Mühendisliği
- **Yüksek Lisans** : 2025, İstanbul Teknik Üniversitesi, Elektrik Elektronik Mühendisliği Anabilim Dalı, Biyomedikal Mühendisliği Yüksek Lisans Programı

DİĞER YAYINLAR, SUNUMLAR VE PATENTLER:

- **Bahar Ö.**, Augmenting Microwave Imaging with Deep Learning: Preliminary Results with Auto-Encoders, International Graduate Research Symposium (IGRS'24)