

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**PET GÖRÜNTÜLERİNDE GÜRÜLTÜ AZALTICI DİFÜZYON OLASILIKSAL
MODELLER (DDPMs) İLE GÜRÜLTÜ AZALTMA**

YÜKSEK LİSANS TEZİ

Emine PACCİ

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği Programı

OCAK 2026

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**PET GÖRÜNTÜLERİNDE GÜRÜLTÜ AZALTICI DİFÜZYON OLASILIKSAL
MODELLER (DDPMs) İLE GÜRÜLTÜ AZALTMA**

YÜKSEK LİSANS TEZİ

**Emine PACCİ
(504201406)**

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Biyomedikal Mühendisliği Programı

Tez Danışmanı: Doç. Dr. İsa YILDIRIM

OCAK 2026

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**NOISE REDUCTION in PET IMAGES USING DENOISING DIFFUSION
PROBABILISTIC MODELS (DDPMs)**



M.Sc. THESIS

**Emine PACCI
(504201406)**

Department of Electronics and Communication Engineering

Biomedical Engineering Programme

Thesis Advisor: Assoc. Prof. Dr. İsa YILDIRIM

JANUARY 2026

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 504201406 numaralı Yüksek Lisans Öğrencisi Emine PACCİ, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “PET GÖRÜNTÜLERİNDE GÜRÜLTÜ AZALTICI DİFÜZYON OLASILIKSAL MODELLER (DDPMs) İLE GÜRÜLTÜ AZALTMA” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. İsa YILDIRIM**
İstanbul Teknik Üniversitesi

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

Doç. Dr. Metin ERTAŞ
Türk Hava Yolları

Teslim Tarihi : 19 Kasım 2025
Savunma Tarihi : 23 Ocak 2026





Aileme,



ÖNSÖZ

Tez çalışmam süresince göstermiş olduğu akademik rehberlik ve güler yüzü için saygıdeğer tez danışmanım Doç. Dr. İsa YILDIRIM'a teşekkürlerimi sunarım. Yüksek lisans eğitimim boyunca derslerini aldığım ve bilgi birikimleriyle akademik bakış açımı geliştiren değerli hocalarıma katkıları ve yol göstericilikleri için teşekkür ederim.

Yüksek lisans sürecimde TÜBİTAK 2210-A Genel Yurtiçi Yüksek Lisans Burs Programı kapsamında desteklenmiş olmaktan büyük onur duydum. Sağlanan maddi desteğin yanı sıra, TÜBİTAK bursiyeri olmanın verdiği motivasyon ve sorumluluk bilinciyle çalışmalarımı sürdürme imkânı buldum. Bu destek için TÜBİTAK'a teşekkürlerimi sunarım.

Bu süreçte her zaman yanımda olan, desteklerini ve inançlarını bir an olsun esirgemeyen sevgili aileme ise sonsuz teşekkür ve sevgilerimi sunarım.

Ocak 2026

Emine Pacci
(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 Pozitron Emisyon Tomografisi (PET)	1
1.2 Tıbbi Görüntülerde Gürültü ve Etkileri	2
1.3 PET’de Gürültü Tipleri	3
1.4 PET’de Gürültü Giderme Yöntemleri	4
1.5 Literatür Taraması	6
2. METOT	9
2.1 Denoising Diffusion Probabilistics Models (DDPMs)	9
2.2 PET Görüntülerinin DDPM ile Uyumu	12
2.3 Anscombe Dönüşümü	14
2.4 DDPM’de Anscombe Dönüşümü Uygulaması	15
3. UYGULAMA	17
3.1 Veriseti	17
3.2 Model Mimarisi ve Hazırlık Aşaması	17
3.3 Veri Ön-İşleme Süreci	20
3.4 Görüntü Hazırlık Süreci	22
3.5 Model Uygulaması	23
4. SONUÇLAR VE DEĞERLENDİRME	25
5. TARTIŞMA VE ÖNERİLER	31
KAYNAKLAR	33
ÖZGEÇMİŞ	37



KISALTMALAR

2B	: 2 Boyutlu
3B	: 3 Boyutlu
AI	: Yapay Zeka (Artificial Intelligence)
ALARA	: Mmkn Olan En Dk Seviye (As Low As Reasonably Achievable)
BT	: Bilgisayarlı Tomografi
CNN	: Evriimsel Sinir Ađı (Convolutional Neural Network)
CNR	: Kontrast/Grlt Oranı
DDPM	: Grlt Giderme Yayılımı Olasılıksal Modeli (Denoising Diffusion Probabilistic Model)
DICOM	: Tıbbi Grntleme ve İletiim Dijital Sistemi (Digital Imaging and Communications in Medicine)
DL	: Derin đrenme (Deep Learning)
EMA	: stel Hareketli Ortalama (Exponential Moving Average)
FDG	: Florodeoksiglukoz
GAN	: retken ekimeli Ađ (Generative Adversarial Network)
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
ML	: Makine đrenmesi (Machine Learning)
MRG	: Manyetik Rezonans Grntleme
MMSE	: En Kk Ortalama Kare Hatası (Minimum Mean Square Error)
PET	: Pozitron Emisyon Tomografisi (Positron Emission Tomography)
PSNR	: Tepe Sinyal Grlt Oranı (Peak Signal to Noise Ratio)
SSIM	: Yapısal Benzerlik İndeks ls (Structural Similarity Index Measure)
SNR	: Sinyal/Grlt Oranı
RMSE	: Karekk Ortalama Hata (Root Mean Square Error)
TV	: Total Varyasyon (Total Variation)



SEMBOLLER

x_0	: Temiz görüntü
x_t	: t zaman adımıdaki gürültülü görüntü
$\widehat{x}_0$	: Model tarafından tahmin edilen temiz görüntü
ϵ	: Eklenen Gaussian gürültü
ϵ_θ	: Model tarafından tahmin edilen gürültü
y	: Poisson gürültülü gözlem
$\hat{y}$	: Gürültüsü giderilmiş görüntü
I	: Görüntü yoğunluk değeri
A	: Anscombe Dönüşümü
λ	: Poisson gürültü dağılımının ortalama parametresi
$\text{Var}(X)$	: Varyans
$\mathbb{E}[X]$	: Beklenen değer
β_t	: t. adımıdaki gürültü katsayısı
θ	: Model parametreleri
$\mathcal{L}_{\text{simple}}$	: Gürültü tahminine dayalı basitleştirilmiş DDPM kaybı



ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1 : Temel mimari ve difüzyon parametreleri	20
Çizelge 4.1 : Model başarısını değerlendirmede kullanılan metrik ve detayları.	26
Çizelge 4.2 : Test sonucu metrik hesapları.....	27





ŞEKİL LİSTESİ

Sayfa

Şekil 1.1 : PET görüntü örneği.	1
Şekil 1.2 : PET görüntüleme aşaması.	2
Şekil 2.1 : DDPM yayılma süreci (ileri süreç).	11
Şekil 2.2 : DDPM ters süreç (reverse process)	11
Şekil 2.3 : Dönüştürülmüş Poisson rastgele değişkeninin ortalamaya bağlı bir fonksiyon olarak standart sapması	15
Şekil 3.1 : Gürültü giderme süreci akış diyagramı	18
Şekil 3.2 : DDPM tabanlı U-Net model mimarisi	19
Şekil 4.1 : DDPM ve TV model görsel çıktıları	25
Şekil 4.2 : DDPM modele ait eğitim(training) ve doğrulama (validation) eğrileri. ..	28



PET GÖRÜNTÜLERİNDE GÜRÜLTÜ AZALTICI DİFÜZYON OLASILIKSAL MODELLER (DDPMs) İLE GÜRÜLTÜ AZALTMA

ÖZET

Pozitron Emisyon Tomografisi (PET), özellikle onkolojik hastalıklarda tümörlü dokunun saptanması, hastalığın evrelendirilmesi ve tedavi yanıtının izlenmesi gibi klinik uygulamalarda yaygın olarak kullanılan bir nükleer tıp görüntüleme yöntemidir. PET görüntüleme sürecinde hastaya radyoizleyici madde enjekte edilmekte ve bu madde aracılığıyla vücuttaki metabolik aktivitenin dağılımı görüntülenmektedir. Ancak hastaların tanı ve tedavi sürecinde PET çekimlerine tekrarlı olarak maruz kalması, alınan radyasyon dozunun artmasına neden olmakta ve bu durum hasta güvenliği açısından önemli bir kısıt oluşturmaktadır. Radyasyon dozunu azaltmak amacıyla düşük dozlu radyoizleyici kullanımı veya daha kısa tarama süreleri tercih edilmekte, ancak bu yaklaşımlar PET görüntülerinin doğası gereği düşük sinyal-gürültü oranına sahip olmasına ve görüntü kalitesinin belirgin biçimde düşmesine yol açmaktadır.

Bu tez çalışmasında, PET görüntülerinde gürültü giderme problemine yönelik olarak, son yıllarda görüntü işleme alanında öne çıkan difüzyon tabanlı derin öğrenme yaklaşımlarından biri olan Denoising Diffusion Probabilistic Model (DDPM) yöntemi ele alınmıştır. Çalışmada, gerçek klinik PET verilerinden oluşan bir veri seti kullanılmıştır. Klinik verilerde doğrudan temiz ve gürültülü görüntü çiftlerinin bulunmaması nedeniyle, PET görüntüleme sistemlerinin fiziksel ölçüm sürecini yansıtan Poisson dağılımına dayalı sentetik gürültü ekleme yaklaşımı benimsenmiştir. Poisson gürültüsünün Gaussian varsayımına dayalı difüzyon modelleriyle daha uyumlu hâle getirilmesi amacıyla Anscombe dönüşümü uygulanmış ve bu sayede DDPM tabanlı gürültü giderme sürecinin daha etkin biçimde gerçekleştirilmesi hedeflenmiştir. Model, farklı gürültü koşullarını temsil edecek şekilde birden fazla gürültü seviyesinde eğitilmiş ve test edilmiştir. Bu yaklaşım, modelin yalnızca belirli bir gürültü düzeyine uyum sağlamasını engelleyerek, değişken gürültü senaryolarında genelleme yeteneğinin değerlendirilmesine olanak tanımıştır. Model performansı, eğitim aralığı içerisinde yer alan gürültü seviyelerinin yanı sıra, eğitim sırasında görülmeyen daha yüksek bir gürültü seviyesi için de analiz edilmiştir. Performans değerlendirmesi PSNR, SSIM, RMSE ve MAE metrikleri kullanılarak gerçekleştirilmiş olup sonuçlar ortalama $\pm$ standart sapma biçiminde raporlanmıştır. Standart sapma değerlerinin tüm gürültü seviyelerinde benzer aralıklarda seyretmesi, modelin farklı görüntüler üzerinde kararlı bir performans sergilediğini göstermektedir.

Önerilen DDPM tabanlı modelin performansı, toplam varyasyon (TV) tabanlı yöntem ile karşılaştırmalı olarak incelenmiştir. Nicel sonuçlar, DDPM modelinin özellikle yapısal benzerlik ve hata temelli metrikler açısından daha dengeli ve tutarlı sonuçlar ürettiğini göstermektedir. Artan gürültü seviyelerinde TV yönteminde daha belirgin bir düzleştirme etkisi gözlemlenirken, DDPM yaklaşımının gürültü bastırma ile yapısal bilgi koruma arasında daha uygun bir denge sağladığı belirlenmiştir. Görsel

değerlendirmeler, PET görüntülerinin düşük kontrast yapısı nedeniyle yöntemler arasındaki farkların her zaman açık biçimde ayırt edilemeyebileceğini ortaya koymuş, bu nedenle nicel analizlerin önemini desteklemiştir. Elde edilen bulgular, difüzyon tabanlı DDPM yaklaşımının PET görüntülerinde gürültü giderme problemine yönelik etkili ve genellenebilir bir çözüm sunduğunu göstermektedir. Bu çalışma, PET görüntü iyileştirme alanında difüzyon temelli modellerin potansiyelini ortaya koymakta ve daha geniş veri setleri ile üç boyutlu hacimsel uygulamalara yönelik gelecekteki çalışmalar için bir temel oluşturmaktadır.



NOISE REDUCTION in PET IMAGES USING DENOISING DIFFUSION PROBABILISTIC MODELS (DDPMs)

SUMMARY

Positron Emission Tomography (PET) is a functional nuclear medicine imaging modality that enables non-invasive visualization of metabolic processes within the human body. Unlike purely anatomical imaging techniques, PET provides physiological and biochemical information by detecting gamma photons generated during positron–electron annihilation events. In clinical oncology, PET plays a crucial role in tumor detection, staging, treatment planning, and therapy response monitoring. By administering radiotracers such as ^{18}F -fluorodeoxyglucose (FDG), regions with elevated glucose metabolism—commonly associated with malignant tissues—can be identified and quantified.

Despite its clinical value, PET imaging is inherently limited by low spatial resolution and high noise levels. The primary source of noise arises from the stochastic nature of radioactive decay and photon detection. PET systems rely on photon counting, a fundamentally probabilistic process governed by Poisson statistics. The number of detected photons fluctuates randomly, and the variance of the signal is proportional to its mean. As a result, PET images exhibit signal-dependent (heteroscedastic) noise characteristics. In low-count conditions—such as low-dose acquisitions or shortened scan times—the relative noise increases significantly, leading to reduced signal-to-noise ratio (SNR) and contrast-to-noise ratio (CNR).

The clinical motivation for reducing noise in PET images is twofold. First, excessive noise can obscure small lesions or subtle metabolic variations, potentially compromising diagnostic accuracy. Second, radiation safety principles such as ALARA (As Low As Reasonably Achievable) advocate minimizing patient radiation exposure. Lowering injected radiotracer dose or reducing acquisition time decreases radiation burden but inevitably increases image noise. Therefore, advanced post-processing algorithms capable of restoring image quality from low-dose PET acquisitions are of substantial clinical importance. Effective denoising techniques may allow safer imaging protocols without sacrificing diagnostic reliability.

Traditional denoising approaches—including Gaussian filtering, median filtering, and Total Variation (TV) regularization—aim to suppress noise by smoothing local intensity variations. However, these methods often struggle with the complex, signal-dependent noise distribution present in PET images. Excessive smoothing can lead to loss of structural details and attenuation of clinically relevant metabolic gradients. Moreover, deterministic filtering techniques lack the capacity to model the underlying data distribution of PET images.

Deep learning methods such as Convolutional Neural Networks (CNNs) and Generative Adversarial Networks (GANs) have demonstrated promising results in medical image restoration. Nevertheless, GAN-based approaches may generate

artificial structures or hallucinated details, raising concerns regarding diagnostic reliability. In medical imaging, the preservation of anatomical and functional integrity is critical; artificially synthesized details may mislead clinical interpretation. To address these limitations, this study proposes the use of Denoising Diffusion Probabilistic Models (DDPMs) for PET image denoising. Diffusion models are probabilistic generative frameworks that progressively transform structured data into noise through a forward diffusion process and then learn to reverse this process step by step. Instead of directly mapping noisy images to clean outputs, DDPMs estimate the noise component at each diffusion timestep and iteratively remove it. This formulation provides stable training dynamics and reduces the risk of hallucinated content generation, as the model learns a principled probabilistic representation of the data distribution.

A fundamental challenge in applying DDPMs to PET imaging lies in the mismatch between noise assumptions. Standard DDPM formulations are based on additive Gaussian noise with constant variance, whereas PET images are predominantly affected by Poisson-distributed noise with signal-dependent variance. This discrepancy can degrade model performance if not properly addressed.

To overcome this incompatibility, the Anscombe transformation was employed as a variance-stabilizing technique. The Anscombe transform converts Poisson-distributed data into approximately Gaussian-distributed data with near-constant variance. By stabilizing the variance, the transformed images become more compatible with the Gaussian diffusion process assumed by DDPMs. After denoising in the transformed domain, the inverse Anscombe transform was applied to restore the data to its original PET intensity space. This strategy allowed the use of a standard DDPM architecture without modifying its probabilistic formulation while ensuring theoretical consistency with PET noise characteristics.

The dataset used in this study consists of clinical FDG-PET images obtained from a publicly available cancer imaging repository. Since clean-noisy image pairs are not directly available in clinical practice, synthetic Poisson noise was introduced to simulate realistic photon-count variability. Multiple noise levels were applied to represent different acquisition conditions, including low, moderate, and high noise scenarios. By training the model on images corrupted with varying noise intensities, the network was encouraged to generalize across heterogeneous noise conditions rather than overfitting to a single noise level.

The DDPM backbone architecture was implemented using a U-Net-based encoder-decoder structure with skip connections. Time embedding mechanisms were incorporated to condition the model on diffusion timesteps. A cosine noise schedule was employed over 200 diffusion steps. The network was trained to predict the noise component (ϵ -prediction) rather than the clean image directly, a strategy known to enhance training stability. Exponential Moving Average (EMA) weights were utilized during evaluation to reduce variance in predictions.

Performance evaluation was conducted using quantitative metrics including Peak Signal-to-Noise Ratio (PSNR), Structural Similarity Index Measure (SSIM), Root Mean Square Error (RMSE), and Mean Absolute Error (MAE). Results were reported as mean $\pm$ standard deviation across test slices to assess both average performance and robustness. The inclusion of standard deviation values provides insight into model consistency across different anatomical slices and noise conditions.

Experimental findings demonstrate that the proposed DDPM-based approach achieves stable denoising performance across all evaluated noise levels. PSNR values remained consistently high, and SSIM scores indicated strong structural preservation. Importantly, RMSE and MAE values exhibited limited increase as noise intensity grew, suggesting resilience to high-noise scenarios. Standard deviation values across test samples remained within a narrow range, indicating consistent behavior and reduced performance variability.

For comparative analysis, results were evaluated against a Total Variation (TV)-based denoising method. While TV filtering achieved moderate noise suppression, it introduced noticeable smoothing effects, particularly at higher noise levels. This smoothing led to homogenization of metabolic gradients and partial loss of subtle structural variations. In contrast, the DDPM approach maintained a more balanced trade-off between noise suppression and detail preservation. Quantitative metrics consistently favored the diffusion-based model, especially in terms of structural similarity and error reduction under moderate-to-high noise conditions.

Visual assessment of representative slices further supported these quantitative observations. Although differences were not always striking due to the intrinsically low resolution of PET images, the DDPM outputs better preserved intensity transitions and regional heterogeneity compared to the TV method. These findings highlight the importance of combining visual and quantitative evaluations in medical image restoration tasks.

Despite promising results, certain limitations should be acknowledged. The study was conducted on two-dimensional PET slices rather than full three-dimensional volumes. Incorporating 3D diffusion models may improve spatial consistency and contextual modeling. Additionally, noise was synthetically generated rather than obtained from true low-dose acquisitions. Future studies should validate the approach using real low-dose clinical datasets. Expanding the dataset size and exploring multi-modal conditioning (e.g., PET/CT or PET/MR) may further enhance generalization capability.


In conclusion, this study demonstrates that Denoising Diffusion Probabilistic Models, combined with variance stabilization via the Anscombe transformation, provide an effective and theoretically consistent framework for PET image denoising. The proposed approach successfully addresses the signal-dependent noise characteristics of PET imaging while preserving structural and metabolic information. By enabling robust noise suppression across varying noise levels, diffusion-based models hold strong potential for improving low-dose PET imaging and supporting safer clinical protocols.



1. GİRİŞ

1.1 Pozitron Emisyon Tomografisi (PET)


Pozitron Emisyon Tomografisi (PET), pozitron bozulumu sonucu pozitron yayan radyoizleyicilere dayalı, canlının fizyolojik işlevlerini girişimsel olmayacak şekilde görüntülemeyi sağlayan nükleer tıp tabanlı bir görüntüleme tekniğidir. PET görüntüleme özellikle kanserli hastalarda tümörlü dokuyu belirleme, kanser evresini belirleme, tedavi takibi gibi süreçlerde önemli rol oynamaktadır. Şekil 1.1’de örnek bir PET görüntüsü verilmiştir [1].



Şekil 1.1 : PET görüntü örneği.

İnsan vücudu nefes alma, kan dolaşımı, sindirim, vücut sıcaklığını düzenleme, konuşma gibi temel fonksiyonları gerçekleştirmek için enerji tüketir. Bu gibi fonksiyonları yerine getirmek üzere çalışan sağlıklı hücreler karbonhidrat, yağ ve proteinleri enerjiye dönüştürmek için kendine özgü bir metabolik sürece sahiptir. 1920’li yıllarda Otto Warburg tarafından; aynı fonksiyonu yerine getirmek için çalışan sağlıklı ve kanserli hücreler kıyaslandığında kanserli hücrelerin sağlıklı hücrelere göre enerji üretirken daha fazla glikoza ihtiyaç duyduğu tespit edilmiştir. Buna Warburg Etkisi denir ve bu durum PET görüntüleme yönteminin teorik temelini

oluşturmaktadır. PET görüntülemesinde hastaya öncelikle görüntülenmek istenen fizyolojiye uygun radyoizotopla işaretlenmiş biyomolekül (çoğunlukla Florodeoksiglukoz veya FDG olarak tanımlanan ^{18}F) enjekte edilir. Vücut içerisinde kararsız yapıda bulunan radyoizleyici madde, pozitron bozulumu yaparak daha düşük enerjiye sahip kararlı bir yapıya geçmeye çalışır. Pozitron bozulumu sırasında ortaya çıkan pozitron parçacığı elektronun antimaddesidir. Vücut içerisinde açığa çıkan bir pozitron parçacığı çevresindeki atomlardan herhangi birine ait elektronlardan biriyle çarpışarak yok olurlar. Bu olaya yokolım (annihilation) denir. Bu yokolım sonucunda zıt yönde ilerleyen iki adet gama ışını ortaya çıkar. Oluşan gama ışınları PET dedektörleri tarafından tespit edilir. PET görüntüleme aşamasına ait görsel Şekil 1.2’de verilmiştir [2]. Anormal yapılı hücrelerde daha fazla radyoizleyici bulunmakta ve dolayısıyla bu hücrelerde daha fazla radyoaktif bozunum gerçekleşmesi beklenmektedir. Bu bölgeler, daha az radyoaktif bozunum gerçekleşen hücrelerin bulundukları bölgelere göre daha parlak şekilde görüntülenir. Böylelikle PET görüntüleme sayesinde vücuttaki radyoaktif bozunumların tespiti ile vücuttaki radyoizleyicilerin haritalanması sağlanır ve kanserli dokunun konumu, boyutu gibi bilgiler elde edilmiş olur [3] [4].



Şekil 1.2 : PET görüntüleme aşaması.

1.2 Tıbbi Görüntülerde Gürültü ve Etkileri

Tıbbi görüntülerde gürültü, görüntüdeki piksel veya voksel değerlerinin rastgele sapmalar göstermesiyle ortaya çıkan, anatomik ve fonksiyonel bilgilerin

yorumlanmasını zorlaştıran bir artefakt türüdür. Gürültü, sinyal-gürültü oranını (SNR) ve kontrast-gürültü oranını (CNR) olumsuz etkileyerek tanısal doğruluğun düşmesine yol açar [5].

PET görüntülerindeki gürültü, çok sayıda faktörden etkilenir. Bunlar arasında enjekte edilen radyoaktif maddenin miktarı, tarama süresi, hastanın vücut ağırlığı, detektör teknolojisi ve cihaz çözünürlüğü, hasta hareketleri gibi etkenler yer alır. Kısa süreli taramalar ya da düşük doz uygulaması, hasta konforu ve radyasyon maruziyeti açısından avantaj sağlar. Ancak bu durumda detektöre ulaşan toplam foton sayısı azalır ve dolayısıyla görüntünün gürültü seviyesi artar. Gürültü seviyesi yüksek görüntüler, küçük ya da düşük metabolik aktiviteye sahip lezyonların saptanmasını zorlaştırır, bu da tanısal hatalara ve yanlış tedavi kararlarına neden olabilir. Yüksek dozda radyoaktif madde verilmesi veya uzun süreli taramalar görünüş kalitesini arttırabilir ancak bu durum radyasyon maruziyetini arttırma, uzun süreli çekimden dolayı hasta kaynaklı artefakt ve dolayısıyla klinik maliyeti arttırma gibi riskler barındırır [6].

Bugüne kadar PET/CT ya da PET/MR taramalarında kullanılan radyasyon dozlarının, doğrudan birey düzeyinde kanıtlanmış bir zarara yol açtığına dair herhangi bir nedensellik ilişkisi kurulamamıştır. Ancak iyonlaştırıcı radyasyonun biyolojik etkileri bilinmektedir. Bu nedenle "zararsız" değil, "çok düşük riskli" olarak kabul edilir. Uluslararası radyasyon koruma kuruluşları (ICRP, UNSCEAR), düşük doz PET görüntülemenin faydalarının risklerden çok daha büyük olduğunu ifade eder. Bununla birlikte, ALARA (As Low As Reasonably Achievable) ilkesi çerçevesinde, uygulanan dozun en düşük seviyede tutulması önerilir. Yeni nesil PET sistemleri, derin öğrenme tabanlı yöntemler kullanarak düşük doz ve kısa süreli taramalı görüntülerde görüntü kalitesinin arttırılması mümkündür [7].

1.3 PET’de Gürültü Tipleri

PET görüntülerinde radyoaktif izotopların bozunması sonucu yayılan fotonlar ve dedektör sistemlerinin elektronik gürültüleri gibi görüntü kalitesini olumsuz etkileyen bazı faktörler vardır. PET görüntüleme sistemi radyoaktif izotopların pozitron bozulumu yapması sonucu ortaya çıkan pozitron parçacığının vücut içerisinde elektronla çarpışması sonucu ortaya çıkan fotonları algılayan detektörlere sahiptir. Oluşan bu fotonların tespiti sayım (count) esasına dayanır ve bu işlem doğası gereği rastlantısal (stokastik) bir süreçtir. Her ölçümde foton sayısı sabit değildir ve

değişkenlik gösterir. Bu değişkenlik istatistiksel olarak Poisson dağılımı ile modellenir. Sinyal ile birlikte gelen gürültü, onu getiren sinyalin büyüklüğüne bağlıdır (çarpımsal gürültü). Özellikle düşük doz PET çekimlerinde veya kısa tarama sürelerinde sayılan foton sayısı azalır ve bu da gürültü düzeyinin orantısız şekilde artmasına neden olur. Bu durum PET görüntülerinde homojen olmayan (non-uniform) ve sinyale bağlı gürültü yapısının ortaya çıkmasına neden olur. Ayrıca detektör sistemlerinden kaynaklanan elektronik gürültüler ve fotonların etkileşime girmeden sapması gibi fiziksel faktörler de Gauss tipi katkısız gürültüye neden olur. Sonuç olarak PET görüntüleri farklı yapıda birden fazla gürültü tipini barındıran karma yapıya sahiptir. Yapay zekâ temelli iyileştirme teknikleri ile bu gürültülerin etkisi minimize edildiğinde daha düşük dozlu çekimlerde ve kısa süreli taramalarda görüntü kalitesi artırılarak hastaların daha az radyasyona maruz kalması sağlanır ve hekimlere daha güçlü veriler sunularak teşhis kolaylığı sunulmuş olur [8].

1.4 PET’de Gürültü Giderme Yöntemleri

Medikal görüntülerde gürültü gidermek için literatürde klasik ve yapay zekâyla gelişen birçok yöntem bulunmaktadır. Gelişen donanım ve yazılım teknolojileri sayesinde, görüntü kalitesini artırmaya yönelik çeşitli yöntemler geliştirilmiştir. Bu yeni yaklaşımlar üç temel başlık altında incelenebilir: TOF (Time-of-Flight) teknolojisi, PSF (Point Spread Function) modellemeleri ve yapay zekâ (AI) tabanlı rekonstrüksiyon algoritmaları. TOF teknolojisi, pozitronların yayılımı (anihilasyon) sonucu yayımladığı iki gama fotonunun detektörlere ulaşma süresindeki farkı hesaplayarak, olayın olduğu yeri daha hassas şekilde belirler. Bu teknoloji Sinyal-Gürültü Oranını (SNR) artırır, görüntüdeki uzamsal bulanıklığı azaltır, özellikle büyük vücut kütlelerine sahip hastalarda görüntü kalitesini iyileştirir. PSF, sistemin uzaysal çözünürlüğünü etkileyen optik yayılma özelliklerini modelleyen matematiksel bir tekniktir. PSF düzeltilmesi ile, lezyon kenarlarının netliği artırılır, özellikle küçük lezyonların tespiti iyileştirilir, kantitatif ölçümlerde (SUV vb.) doğruluk artar. Bu yöntemlerin yanında son yıllarda görüntü iyileştirmede özellikle yapay zekâ algoritmaları ön plana çıkmaktadır. Yapay zekâ algoritmalarıyla görüntüler rekonstrüksiyon öncesi sinogram alanında veri işlenerek ham veri üzerinden artefakt oluşumu minimize edilerek gürültüyü kaynağından temizlemek mümkündür. Rekonstrüksiyon sonrası CNN, GAN vb. yöntemlerle gürültü gidermek de

mümkündür. Özellikle Transfer Learning ve GAN (Generative Adversarial Network) modeller ile düşük dozda çekilen görüntüler yüksek dozda çekilen görüntülerin kalitesine çıkarılabilir [9] [10].

Tıp alanında yapay zekâ; daha odaklı kararlar alma, kalıpları belirleme ve büyük miktarda veri analizi sağlama gibi işleri yaparak hekimlere destek olabilir. Yapay zekâyla birlikte tıbbi görüntüler analiz edilip tedavi planlaması yapılabilir ve tedavinin sonucu değerlendirilebilir. Yapay zekâ (Artificial Intelligence, AI), insan zekâsına özgü öğrenme, akıl yürütme ve problem çözme yeteneklerini taklit etmeyi amaçlayan bir bilim alanıdır. Yapay zekânın bir alt dalı olan makine öğrenmesi (Machine Learning, ML), sistemlerin açık kurallarla programlanmadan, verilerden öğrenerek tahmin veya sınıflandırma yapabilmesini sağlar. Makine öğrenmesinin bir alt kolu olan derin öğrenme (Deep Learning, DL) ise çok katmanlı yapay sinir ağlarını kullanarak veriden otomatik olarak özellik çıkarımı ve yüksek düzeyde temsil öğrenimi gerçekleştirir. Günümüzde derin öğrenme yöntemleri, özellikle görüntü işleme ve tıbbi görüntü iyileştirme gibi alanlarda yüksek doğruluk ve genelleme kabiliyeti nedeniyle yaygın şekilde kullanılmaktadır.

PET görüntüleri hem yapısal hem de istatistiksel gürültüleri içeren karmaşık bir yapı olduğu için Gaussian filtre, Median filtre gibi klasik yöntemler, PET görüntülerindeki karmaşık gürültüyü gidermekte yetersiz kalmakla birlikte detay kaybına yol açabilmektedir. Geleneksel GAN veya CNN tabanlı yöntemler ise yapay detaylar üretme eğilimindedir. Antun ve arkadaşlarının yapmış olduğu çalışmada MR gibi modalitelerde görüntü yeniden yapılandırılırken GAN gibi derin öğrenme tabanlı yapıların görüntüdeki tanısal güvenilirliği bozacak şekilde yapay detay ürettiği gösterilmiştir [11]. Bu gibi sınırlamaları aşmak için bu çalışmada Denoising Diffusion Probabilistic Models (DDPM) önerilmiştir. DDPM, önce görüntüye gürültü ekleyerek bozar ve sonrasında bu süreci tersine çevirerek orijinal görüntüyü adım adım geri üretme temeline dayanır. Bu yöntem özellikle PET görüntülerinde olduğu gibi karmaşık ve sinyale bağlı (non-uniform) gürültülü yapılarda başarılı sonuç vermektedir [12].

DDPM modeli yapısı gereği görüntüye Gaussian gürültü ekler ve sonrasında ters dönüşüm uygulayarak orijinal görüntüye ulaşmaya çalışır. PET görüntüleri yapısı gereği Poisson gürültü ağırlıklıdır. Bu çalışmada Poisson gürültü eklenmiş olan PET

görüntülerinin ve bu görüntülere Anscombe Dönüşümü uygulanarak model başarısı değerlendirilmiştir.

1.5 Literatür Taraması

Diffusion modelleri, son yıllarda tıbbi görüntüleme alanında farklı görüntüleme sistemlerinde başarılı bir şekilde uygulanmıştır. Örneğin, Hung ve arkadaşları MRG (Manyetik Rezonans Görüntüleme) süper çözünürlüğü, X-ray görüntülerinde gürültü giderme ve ultrason görüntü tamamlaması gibi görevlerde difüzyon tabanlı modellerin etkili sonuçlar verdiğini göstermiştir [13]. Ayrıca Hein ve ekibi tarafından yapılan kapsamlı bir derlemede, difüzyon tabanlı modellerinin BT (Bilgisayarlı Tomografi), MRG, PET ve ultrason gibi birçok sistemde hem görüntü iyileştirme hem de yeniden yapılandırma görevlerinde yüksek başarı sağladığı vurgulanmıştır [14]. Dalmaz ve arkadaşları ise multi-kontrast MRG görüntülerinin (T1, T2, FLAIR) sentezlenmesinde DDPM modellerinin etkinliğini göstermiştir [15]. Bilgisayarlı Tomografi (BT) alanında, Webber ve Reader düşük doz BT görüntülerinde gürültü azaltımı ve görüntü kalitesinin iyileştirilmesi için difüzyon modellerini başarıyla kullanmıştır [16]. Ayrıca, Wu ve arkadaşları az sayıda dilimle 3B (3 Boyutlu) BT görüntü yeniden yapılandırması için aşamalı bir difüzyon modeli önererek sınırlı veri ile yüksek kaliteli görüntüler üretmeyi başarmıştır [17]. Bu başarılar, difüzyon modellerinin medikal görüntüleme alanında genel bir gürültü giderme ve yeniden yapılandırma standardı olabileceğini göstermektedir. Ayrıca yapılan son çalışmalarda DDPM modelin sadece gürültü gidermek için değil, görüntüden klinik kararları etkileyen kinetik veya anatomik parametreleri çıkarmak için de kullanılmaktadır. Bunu yaparken metin açıklamaları, MR eşleşmeleri, izleyici sayımı gibi ek koşullama bilgileri kullanılmış ve daha kontrollü ve anlamlı sonuçlar elde edilmiştir.

Boxiao Yu ve arkadaşlarının “Metin Kılavuzlu Difüzyon Modelleri Kullanarak PET Görüntüleme Gürültü Giderme (2025)” çalışmasında model tıbbi görüntüleri metin yönlendirmeleriyle (tarama protokolleri, yeniden yapılandırma parametreleri ve hasta bilgileri gibi) alınır. Bu metin yönlendirmelerini DDPM çıktısını yönlendirmek için Karşıt Dil Görüntü Ön Eğitim (CLIP) modeli kullanılır. DDPM’in, bu bilgilere dayanarak temiz görüntü üretimi yaparak koşullu ve daha kontrollü gürültü giderdiğini gösterilmiştir. Metin yönlendirmesi sayesinde giriş görüntüsünde hangi alana odaklanılması gerektiği belirlenmiş olur ve model o bölge üzerine yoğunlaşır.

Çalışmada PET sayım verileri dikkate alınarak düşük doz görüntüler ve kısa taramalı görüntülerle çalışılmıştır. U-Net ve klasik DDPM modellerin aynı görseller üzerindeki gürültü giderme başarılarıyla kıyaslanarak önerilen yöntemin başarısı gösterilmiştir [18].

Yanis Djebra ve arkadaşlarının “Dinamik Beyin PET'inde Üretken Derin Öğrenme Modelleri Kullanılarak Kinetik Parametrelerin Bayesçi Arka Dağılım Tahmini (2025)” adlı çalışmasında, Alzheimer gibi hastalıkların tanısında kullanılan PET görüntülerinden elde edilen kinetik parametrelerin (örneğin: p-tau yoğunluğu, beyin kan akışı) daha doğru ve hızlı bir şekilde hesaplanmasını hedeflenmiştir. Bu parametreler zamana bağlı olarak hesaplandığı için dinamik PET görüntüleri kullanılmıştır. PET görüntüleri doğası gereği yüksek gürültü içerdiğinden dolayı bu parametrelerin güvenli tahmini zorlaşmaktadır. Çalışmada iDDPM modeli önerilerek görüntülerin her bir vokselindeki parametrenin dağılımı belirlenmiştir. Çalışma başarısı CVAE-DD, WGAN-GP, MCMC modelleri ile kıyaslanarak kanıtlanmıştır [19].

Ziyun Zhou ve arkadaşlarının “Çapraz İzleyici PET Gürültüsünü Gidermek İçin Maskeli Görüntü Eğitimine Sahip Genelleştirilebilir Bir Difüzyon Transformatörü (2025)” adlı çalışmasında Difüzyon Dönüştürücüler (DiT) modeli sunularak PET görüntülerindeki gürültü giderilmeye çalışılmıştır. Bu model klasik DDPM'den farklı olarak girdiyi küçük parçalara böler ve bunları bir dizi belirteç haline getirir ve bunları yinelemeli iyileştirmeler yapmak için kullanır. Modelin genelleştirebilme kabiliyetini arttırmak ve izleyiciler arasında çalışmasını sağlamak adına yeni bir maskeli görüntü eğitim çerçevesi tasarlanmıştır. Veri seti için 20 kişiden, ayrı ayrı üç farklı radyoizleyicinin kullanıldığı görüntüler elde edilmiştir. Aynı zamanda T1 ağırlıklı MRG görüntüleri de ek koşul olarak çalışmaya dahil edilmiştir. Çapraz izleyici doğrulaması için tasarlanan yeni bir maskeli görüntü eğitim yaklaşımıyla belirteçli koşullu girdilere sahip koşullu bir difüzyon dönüştürücü modeli önerilmiştir. Elde edilen sonuçların umut vadettiği düşünülmektedir [20].

Xuato Guo ve arkadaşlarının “Alzheimer Hastalığı Tanısında MRI Olmadan AV45 PET Miktar Tayini İçin Yapıyı Koruyan Gürültü Giderici Difüzyon Modeli (2025)” adlı çalışmasında; AV45 PET taramasıyla tespit edilen ve Alzheimer hastalığının erken teşhisinde kesin belirteç olan serebral korteste amiloid- β ($A\beta$) birikiminin tespiti ele alınmıştır. Klinik olarak AV45 PET taramalarının doğru şekilde ölçülmesi

T1 MRG görüntülerini gerektirir. Bu durum da artan maliyetlere ve hasta yüküne yol açmaktadır. Bu çalışmada bu problemlere çözüm olarak AV45 PET görüntülerinden difüzyon tabanlı bir model olan SP-DDPM modeli kullanılarak T1 görüntüleri sentezlenir. Model eğitiminde segmentasyona dayalı ön bilgiler ve T1 görüntülerinden yapısal ayrıntılar kullanılarak modelin hedeflenen bölge için anatomik doğruluğun artırılması hedeflenmiştir. 667 hastanın dahil edildiği bu çalışmada ADNI ve SILCODE adlı iki ayrı veri seti kullanılmıştır. Çalışma sonucunda ADNI veri seti için 0.018, SILCODE için 0.041 ortalama mutlak hata elde edilmiş olup mevcut çalışmalardan daha başarılı sonuçlar elde edildiği bildirilmiştir. Alzheimer hastalığının teşhisi için klinik iş verimliliğini arttıran ve kolaylaştıran bir yöntem olduğu belirtilmiştir [21].



2. METOT

2.1 Denoising Diffusion Probabilistics Models (DDPMs)

Denoising Diffusion Probabilistic Models (DDPMs), ilk olarak doğal görüntü sentezinde kullanılmak üzere önerilmiş, daha sonra tıbbi görüntüleme gibi karmaşık alanlara adapte edilmiş generatif modellerdir. Bu modeller, bir görüntüye kademeli olarak rastgele gürültü ekler ve sonra bu gürültüyü yine kademeli olarak temizlemeyerek orijinal veya iyileştirilmiş görüntüye ulaşmayı hedefler. İleri Difüzyon Süreci (Forward Process) ve Geriye Dönük Gürültü Giderme (Reverse Process) aşamalarından oluşan bu süreç Markov Zinciri ile modellenmektedir. Özellikle son yıllarda DDPM modelin tıbbi görüntülerde klinik kullanımı artmış olup modelin başarısı çeşitli çalışmalarla kanıtlanmıştır.


Aguila ve arkadaşları tarafından, klasik Denoising Diffusion Modellerinin ötesine geçerek hem başlangıç hem de hedef görüntüye koşullandırılmış bir öğrenme yöntemi olan Denoising Diffusion Bridge Model (DDBM) önerilmiştir. Bu model sayesinde, hastalıklı görüntülerden anatomik olarak tutarlı ve sağlıklı karşıt örnekler üretilbilmiş, segmentasyon ve anomali tespiti gibi görevlerde önceki yöntemlere kıyasla üstün performans elde edilmiştir. Çalışmada DDBM modelin, özellikle patolojik bölgelerin hedefe yönelik tespit edilmesi sağlanırken, bireye özgü anatomik detaylar korunarak yapay zekâ destekli görüntü iyileştirmede başarılı bir yaklaşım sunulmuştur. DDPM model gürültülü giriş görüntüsü ile çalışırken DDBM giriş görüntüsü ve hedef görüntü (bu çalışma için sentetik patolojik görüntü) üzerinden öğrenme yapar. Modele hastalıklı olan dokunun sağlıklı hali gösterilmiş olup bu görüntüler üzerinden öğrenme sağlanmış olur. Çalışmada ilgili model Supervised CNN ve Klasik DDPM modeller ile kıyaslanarak DDBM'in hastaya özel anatomiye koruyarak patolojik bölgelerin başarılı bir şekilde tespit edebildiği kanıtlanmıştır [22].

Safari ve arkadaşları tarafından, beyin MR görüntülerinde hareket kaynaklı artefaktları düzeltmek üzere Residual-Guided Diffusion modeli olan Res-MoCoDiff geliştirilmiştir. Res-MoCoDiff, süreci klasik piksel tabanlı değil, residual haritalar

üzerinden gerçekleştirerek modelin hem bozulma yerini hem düzeltme ihtiyacını daha isabetli belirlemesini sağlamaktadır. Bu model, Swin Transformer tabanlı mimarisi ve hareket bilgisine dayalı residual yönlendirmesi ile klasik GAN ve DDPM yöntemlerine kıyasla yüksek PSNR ve SSIM değerleri elde etmiştir. Önerilen model, segmentasyon öncesi düzeltmelerde doğruluğu artırarak klinik kullanıma entegre edilebilecek nitelikte bir yapı sunmuştur [23].

Zhang ve arkadaşları tarafından, CT projeksiyon verilerinin bozulduğu ya da yetersiz olduğu durumlar için, geleneksel rekonstrüksiyon tekniklerini Denoising Diffusion Probabilistic Models (DDPM) ile birleştiren hibrit bir sistem olan PHIRF geliştirilmiştir. Önerilen bu yöntem iki aşamadan oluşmaktadır. Bunlardan ilki eksik veya bozuk projeksiyon verilerinden klasik CT algoritmaları kullanarak kaba görüntüler elde edilen Ön Rekonstrüksiyon (Preliminary Stage); ikincisi ise elde edilen yapıların DDPM'in ters sürecine koşullayıcı veri olarak entegre edildiği Koşullu Difüzyon (Conditional DDPM) sürecidir. Bu model yapısı sayesinde hem öğrenilmiş istatistiksel dağılımları hem de fiziksel görüntüleme modellerinden gelen yapısal bilgiler birlikte kullanılarak artefaktlar başarılı bir şekilde giderilirken anatomik yapı detayları korunmuş yüksek çözünürlüklü tomografik görüntüler elde edilmiştir. CNN, GAN ve klasik DDPM modeller ile kıyaslama yapılarak model başarısı kanıtlanmıştır [24].

Denoising Diffusion Probabilistic Models (DDPM), iki aşamadan oluşan üretken bir modeldir. Modelin ilk aşamasında giriş görüntüsüne sistematik olarak Gauss gürültü eklenerek görüntünün orijinallikten uzaklaşması sağlanır. DDPM'nin ilk aşaması olan bu sürece Yayılma Süreci (Diffusion Process) denir. Şekil 2.1'de modelin ilk aşamasını daha açıklayıcı hale getirirsek, giriş görüntüsünde görselin açıkça anlaşıldığı, ancak DDPM'in ilk aşamasından sonra görüntünün tamamıyla gürültüye dönüştüğünü ve orijinallikten uzaklaştığı görülmüş olur.




Şekil 2.1 : DDPM yayılma süreci (ileri süreç).

İleri süreci anlatan eşitlik, denklem (2.1)'de verilmiştir. Burada x_0 temiz görüntüyü, x_t ise t . adımda gürültü eklenmiş görüntüyü temsil eder.

$$q(x_t | x_{t-1}) = \mathcal{N}(x_t; \sqrt{1 - \beta_t} x_{t-1}, \beta_t I) \quad (2.1)$$

Bu denklemde $\beta_t \in (0, 1)$ t . adımdaki gürültü seviyesini belirleyen katsayıdır ve I birim matrisidir.

DDPM'in ikinci aşamasında ise model, Yayılma Sürecinde eklemiş olduğu gürültüyü kademeli olarak görüntüden temizleyerek orijinal görüntüyü yeniden üretmeyi öğrenir. Bu sürece Ters Süreç (Reverse Process) denir. Ters Süreç ile ilgili işleyiş Şekil 2.2'de görselleştirilmiştir.



Şekil 2.2 : DDPM ters süreç (reverse process).

Ters süreci anlatan eşitlik (2.2)'de amaç, x_t verilmişken x_{t-1} 'i üreten süreci öğrenmektir. Bu süreç, parametrelili bir Gauss dağılımı ile modellenir.

$$p_{\theta}(x_{t-1} | x_t) = \mathcal{N}(x_{t-1}; \mu_{\theta}(x_t, t), \sum \theta(x_t, t)) \quad (2.2)$$

Pratikte birçok DDPM uygulamasında model doğrudan μ_{θ} yerine görüntüye eklenen gürültü bileşenini tahmin edecek şekilde eğitilir. Bu çalışmada da model $\epsilon_{\theta}(x_t, t)$ ile gürültüyü tahmin ederek gürültü temizleme işlemini gerçekleştirir.

Model eğitimi rastgele seçilen bir zaman adımı t için modelin tahmin ettiği gürültü $\epsilon_{\theta}(x_t, t)$ ile gerçek gürültü ϵ arasındaki farkı minimize eder. (2.3)

$$\mathcal{L}_{\text{simple}}(\theta) = \mathbb{E}_{x_0, t, \epsilon} \left[\|\epsilon - \epsilon_{\theta}(x_t, t)\|_2^2 \right] \quad (2.3)$$

Bu kayıp fonksiyonu sayesinde model, farklı gürültü seviyelerinde bozulmuş görüntülerden gürültü bileşenini öğrenerek ters difüzyon adımlarında görüntüyü kademeli biçimde iyileştirebilmektedir.

Son zamanlarda DDPM, görüntü oluşturma, metinden görüntü oluşturma, görüntü düzenleme, süper çözünürlük, görüntü iyileştirme ve gürültü temizleme gibi birçok alanda kullanımı artan bir modeldir.

Bu çalışmada DDPM mimarisi olarak U-Net tabanlı bir gürültü giderici kullanılmıştır. U-Net hem yerel hem de global yapıları algılayabilen encoder-decoder yapısıyla görüntüdeki gürültüleri temizleme görevini üstlenir. Modelde zaman bağımlılığını sağlamak için her adımda zaman adımı (t) modele girdi olarak entegre edilmiştir. Bu yapıyla birlikte model, düşük gürültü seviyelerinde ince detayları ve yüksek gürültü seviyelerinde yapısal bütünlüğü koruyabilmektedir [25].

2.2 PET Görüntülerinin DDPM ile Uyumu

DDPM modelleri yapısal olarak Gaussian tipi gürültü modelleri üzerine kuruludur. Ancak giriş bölümünde de bahsedildiği üzere PET görüntüleri doğası gereği hem Poisson hem de Gaussian gürültüye sahip görüntülerdir. Gerçek hayatta PET görüntüleri ağırlıklı olarak Poisson gürültüye sahip olduğu için modelin bu görüntülere uyumlu çalışması güçleşmektedir. Gürültü varyansı, altta yatan gerçek sinyalin beklenen değerine eşit olduğundan, Poisson gürültüsü sinyale bağlıdır. Bu da Poisson

gürültüsü gidermenin dayanağını, sinyal işleme filtreleri tarafından genellikle varsayılan sabit varyansa sahip ek beyaz Gauss gürültüsünden çok farklı kılar.

Makitalo ve arkadaşlarının yapmış olduğu çalışmada, Poisson gürültüsüne sahip verilerde Anscombe dönüşümünün uygulanması ile varyans stabilize edilerek, klasik Gauss gürültü giderme algoritmalarının etkin biçimde kullanılabileceği gösterilmiştir. Bununla birlikte, dönüşüm sonrası uygulanan ters dönüşüm fonksiyonunun gürültü gidermedeki öneminden bahsedilmiş olup Klasik Ters Dönüşüm, Tam Tarafsız Ters Dönüşüm (Exact Unbiased Inverse), MMSE (Minimum Mean Square Error) Dönüşüm yöntemlerini BM3D algoritmasıyla deneyerek bu yöntemlerin gürültü gidermedeki etkinliği tartışılmıştır. Özellikle düşük sayım seviyelerinde, klasik yaklaşık ters dönüşüm yerine kullanılan Tam Tarafsız Ters Dönüşümün (Exact Unbiased Inverse) hem yapısal bilgi korunumu hem de metriksel başarı açısından anlamlı iyileşme sağladığı belirtilmiştir [26].

Mansoor ve arkadaşlarının yapmış olduğu çalışmada PET görüntülerinde sinyale bağımlı gürültüyü bastırmak amacıyla Poisson-Gauss karışımı modellemeye uygun Genelleştirilmiş Anscombe Dönüşümünü (GAT) uygulanmış ve Kenar Korumalı Trilateral Filtreleme ile birleştirmiştir. GAT, sinyalin varyansını stabilize ederek, klasik Gauss gürültü giderme yöntemlerine zemin hazırlamaktadır. Çalışmanın sonuçlarında, düşük doz PET görüntülerinde bile yapısal bütünlüğün ve SUV temelli kantitatif ölçümlerin başarıyla korunduğunu gösterilmektedir. Bu da Anscombe dönüşümünün PET gibi klinik önemi yüksek görüntülerde hem görsel hem sayısal güvenilirlik açısından kritik bir rol oynadığını ortaya koymaktadır [27].

Eckert ve arkadaşlarının yapmış olduğu çalışmada, doğası gereği Poisson gürültüye sahip olan Mamografi görüntülerinde gürültü giderme yöntemi geliştirilmiştir. Poisson gürültüler ait olduğu sinyale bağımlı olduğu için klasik CNN (Convolutional Neural Network) modeller tarafından doğru bir şekilde işlenemez. Sinyal ve model arasında meydana gelen bu uyumsuzluğu ortadan kaldırmak için Anscombe Dönüşümü uygulanarak yaklaşık olarak sabit varyanslı Gauss gürültüsüne dönüştürülmüş olup veriler CNN modelde işlenmek üzere hazır hale getirilmiştir. Modelde temiz görüntü oluşturmak yerine gürültü tahmini yapılarak giriş görüntüsünden, tahmin edilen gürültü çıkarılarak temiz görüntü tahmin edilmeye çalışılır. Çalışmada simüle görüntülerin yanında gerçek görüntüler de kullanılmıştır. BM3D ve DnCNN (Deep CNN for Gaussian Denoising) modeller kullanılarak görüntü kalitesi kıyaslanmıştır.

Anscombe Dönüşümünün katkılarıyla, özellikle düşük foton sayımı altında elde edilen görüntülerde keskinlik, kenar korunumu ve kontrastın iyileştiği ve klinik açıdan güvenilir veriler oluşturulduğu gözlemlenmiştir [28].

Bu çalışmada, ilgili problemi ortadan kaldırmak amacıyla Poisson gürültüyü Gaussian benzeri bir gürültüye dönüştürerek görüntüleri modele uyumlu hale getirmek için Anscombe Dönüşümü önerilmektedir. Bu dönüşümle birlikte görüntülerin DDPM modele teorik olarak uyumluluğu artırılarak eğitim sırasında gürültü modelinin doğruluğunu arttırmak hedeflenmektedir.

2.3 Anscombe Dönüşümü

PET görüntülerinde Poisson dağılımına sahip gürültüye sıklıkla rastlanır. Poisson dağılımının karakteristik özelliği ortalama ve varyansın birbirine eşit olmasıdır. Bu eşitlik denklem 2.4’de verilmiştir.

$$E[X] = \lambda, \quad \text{Var}(X) = \lambda \quad (2.4)$$


Bu özellik, düşük sayım seviyelerinde yüksek göreceli gürültü oluşmasına neden olur. Bunun sonucunda PET görüntüleri, özellikle düşük doz durumlarında non-uniform, çarpımsal gürültü içerir. Poisson dağılımlı veriler, özellikle düşük değerli sayımlarda varyansı değişken olan bir yapı sergiler. Bu durum, sabit varyans varsayımı yapan modeller (örneğin DDPM) için uyumsuzluk oluşturur. Francis Anscombe’un adını taşıyan Anscombe Dönüşümü, literatürde Poisson dağılımına sahip sinyal/görüntüyü Gauss dağılımlı hale dönüştürmek için kullanılan varyans sabitleyici bir dönüşümdür. Bu yöntem kullanılarak Poisson gürültüye sahip veriler Gauss gürültülü hale getirilir. Bu işlem denklem 2.5’de gösterilmiştir. Dönüşüm sonrasında görüntü yaklaşık olarak birim varyanslı ($\text{Var}(X) \approx 1$) hale gelir. Yeni oluşan görüntüye Gauss gürültüsü çerçevesi için tasarlanmış gürültü giderme algoritmaları kullanılır ve sonrasında Ters Anscombe dönüşümü uygulanarak nihai sonuca ulaşılır. Ters Anscombe dönüşümüyle alakalı işlem eşitlik 2.6’te gösterilmiştir. Anscombe Dönüşümü sayesinde DDPM,

model mimarisi değiştirilmeden Poisson gürültüye sahip görüntüler için etkin bir şekilde çalışılabilir hale getirilmiş olur [29].

$$A: X \rightarrow 2 \sqrt{X + \frac{3}{8}} \quad (2.5)$$

$$A^{-1}: Y \rightarrow \left(\frac{Y}{2}\right)^2 - \frac{1}{8} \quad (2.6)$$

Denklemlerde kullanılan X, orijinal Poisson gürültülü görüntüyü temsil etmektedir [30].



Şekil 2.3 : Dönüştürülmüş Poisson rastgele değişkeninin ortalamaya bağlı bir fonksiyon olarak standart sapması.

2.4 DDPM’de Anscombe Dönüşümü Uygulaması

PET görüntülerinde, sistemin yapısı ve doğası gereği yüksek oranda Poisson gürültüsü içermektedir. DDPM modeli ise Gaussian gürültüyle eğitilmek üzere tasarlanmıştır. Giriş görüntüsündeki ve model yapısındaki bu yapısal farklılığı gidermek adına Anscombe Dönüşümü kullanılmıştır. Model eğitimi öncesinde Poisson karakterli verilere Anscombe dönüşümü uygulanarak varyansları stabilize edilmiş ve yaklaşık olarak Gaussian yapıya dönüştürülmüştür. Bu işlem sayesinde model ve giriş verileri arasındaki uyumsuzluk giderilerek model, teorik olarak hedeflediği dağılım varsayımıyla uyumlu veri üzerinden eğitilmiştir. Bu dönüşümle birlikte Eğitim aşaması 3 adımdan oluşmuştur: Giriş verisinin Gaussian uyumlu forma getirilmesi, her

zaman adımımda uygun gürültü düzeyine göre örneklenmiş DDPM eğitimi, eğitim sonrası giriş verisinin yeniden gerçek veri uzayına dönüşümü. Böylelikle klasik DDPM mimarisinin değiştirilmesine gerek kalmadan modelin Poisson dağılımlı PET görüntüleriyle çalışabilmesi sağlanmıştır.



3. UYGULAMA


3.1 Veriseti

Bu çalışmada kullanılan görüntüleme verileri, The Cancer Imaging Archive (TCIA) platformunda yer alan ACRIN 6668 / RTOG 0235 çalışmasına ait FDG-PET görüntülerinden oluşmaktadır. Bu çok merkezli klinik çalışma, 2005–2009 yılları arasında 37 farklı kurumda yürütülmüş ve toplamda 250 hasta kaydedilmiştir. Veriseti için FDG-PET taraması kullanılmıştır. Hastaların tedavi öncesi ve sonrasında boyundan femura kadar vücut bölgesi görüntülenmiş olup görüntüler DICOM formatında arşivlenmiştir. Çalışmada bu görüntülere ait klinik metrikler ve değerlendirmeler kullanılmayıp görüntülerin 2 boyutlu dilimlere ayrılmış halleri kullanılmıştır [31].

3.2 Model Mimarisi ve Hazırlık Aşaması

Bu çalışmada önerilen gürültü giderme süreci, veri ön işleme, ileri yönlü difüzyon (forward process) ve ters yönlü iyileştirme (reverse process) olmak üzere üç temel aşamadan oluşmaktadır. Süreç, ham PET görüntülerinin (x_0) sisteme girişi ile başlar. İlk aşamada, görüntü üzerindeki parlaklığı yüksek olan piksel değerlerini dengelemek amacıyla %99,5 oranında yoğunluk kırpma (intensity clipping) işlemi uygulanmış ve veriler $[0, 1]$ aralığına normalize edilmiştir. PET görüntüleme gerçekçi bir gürültü modellemesi yapabilmek adına, normalize edilen görüntülere Poisson dağılımlı gürültü eklenmiştir. Ardından, sinyal-bağımlı olan Poisson gürültüsünü, DDPM modelinin daha etkin çalıştığı Gaussian dağılımına yaklaştırmak amacıyla İleri Anscombe Dönüşümü uygulanarak gürültülü girdi (x_t) elde edilmiştir. İyileştirme aşamasında ise, eğitilen DDPM modeli tarafından tahmin edilen gürültü bileşenleri (ϵ_θ), yinelemeli örnekleme stratejisi ile görüntüden kademeli olarak arındırılır. Model çıktısı Gaussian uzayında olduğu için, elde edilen temizlenmiş veriye Ters Anscombe Dönüşümü (Inverse Anscombe Transform) uygulanarak verinin tekrar orijinal PET sinyal uzayına dönmesi sağlanır. Son aşamada uygulanan dinamik aralık kırpma (post-


processing) işlemi ile iyileştirilmiş PET görüntüsü ($\hat{x}_0$) elde edilir. Gürültü giderme süreci Şekil 3.1’de akış diyagramı olarak gösterilmiştir.



Şekil 3.1 : Gürültü giderme süreci akış diyagramı.

Bu çalışmada kullanılan DDPM mimarisi (Şekil 3.2), temel olarak U-Net tabanlı bir omurga (backbone) üzerine inşa edilmiştir. Model, kodlayıcı (encoder), dar boğaz (bottleneck) ve kod çözücü (decoder) olmak üzere üç ana bölümden oluşmaktadır. Kodlayıcı bölümünde, giriş PET görüntüsü ardışık evrimsel katmanlar ve aşağı örnekleme (downsampling) blokları aracılığıyla çok ölçekli özellik temsillerine dönüştürülmektedir. Bu aşamada, mekânsal çözünürlük kademeli olarak azaltılırken, kanal boyutu artırılarak daha soyut ve bağlamsal özelliklerin öğrenilmesi amaçlanmaktadır. Kodlayıcı boyunca kullanılan atlamalı bağlantılar (skip connections), düşük seviyeli uzamsal bilgilerin korunmasına katkı sağlamaktadır. Dar boğaz (bottleneck) katmanı, modelin en yüksek soyutlama düzeyine ulaştığı bölümdür. Bu aşamada elde edilen özellikler hem yerel hem de küresel bağlamı temsil edecek şekilde işlenerek, gürültü ile görüntü içeriği arasındaki ayrımın daha etkin yapılması hedeflenmektedir. Kod çözücü bölümünde ise, kodlayıcıdan aktarılan atlamalı bağlantılarla birlikte yukarı örnekleme (upsampling) işlemleri gerçekleştirilir. Bu sayede, düşük çözünürlükte öğrenilen soyut temsiller, özgün görüntü boyutuna kademeli olarak geri taşınır. Kod çözücü boyunca gerçekleştirilen bu yeniden yapılandırma süreci, görüntünün ince detaylarının ve anatomik yapılarının korunmasına yardımcı olur. Modelin zaman bağımlı yapısını temsil etmek amacıyla, her bir difüzyon adımı için zaman gömme (time embedding) mekanizması kullanılmaktadır. Bu mekanizma, modelin farklı gürültü seviyelerine karşı uyumlu tepkiler vermesini sağlayarak, ters difüzyon sürecinin kararlı biçimde ilerlemesine

katkı sunmaktadır. Son aşamada ağ, girdi görüntüsüne eklenmiş olan gürültüyü temsil eden bir tahmin (ϵ_θ) üretmektedir. Bu tahmin, ters difüzyon sürecinin temel bileşeni olarak kullanılarak, gürültünün iteratif biçimde giderilmesine olanak tanımaktadır.



Şekil 3.2 : DDPM tabanlı U-Net model mimarisi.

Şekil 3.2’de sunulan DDPM tabanlı U-Net mimarisi, Çizelge 3.1’de özetlenen temel mimari ve difüzyon parametreleri kullanılarak yapılandırılmıştır. Bu parametreler, temsil gücü ile hesaplama maliyeti arasında dengeli bir yapı sağlamak amacıyla belirlenmiştir. Seçilen ayarlar, PET görüntülerinin düşük sinyal-gürültü oranı ve sınırlı veri boyutu dikkate alınarak belirlenmiştir. Böylece modelin kararlı biçimde eğitilmesi ve farklı gürültü seviyelerinde genelleme yapabilmesi hedeflenmiştir.

Çizelge 3.1 : Temel mimari ve difüzyon parametreleri.

Parametre	Değer	Açıklama
Temel kanal sayısı (num_channels)	128	Görüntü özelliklerini temsil eden temel filtre boyutu. Düşük gürültülü PET verilerinde yeterli derinlik ve hesaplama dengesi sağlar.
Artırma oranı (channel_mult)	1, 2, 4, 8	Her alt katmanda kanal sayısının artış oranı. Derin katmanlarda yüksek düzeyli özellik çıkarımı sağlar.
Artık blok sayısı (num_res_blocks)	2	Her çözünürlük seviyesinde iki adet residual blok kullanılarak bilgi akışı güçlendirilmiştir.
Dropout oranı	0.1	Aşırı öğrenmeyi (overfitting) önlemek amacıyla belirlenmiştir. PET verilerinin sınırlı boyutuna uygundur.
Noise schedule	Cosine	Gürültü adımlarının doğrusal yerine kademeli artışını sağlar. Görsel olarak daha yumuşak sonuçlar üretir.
Diffusion steps	200	Toplam 200 zaman adımında gürültü ekleme ve çıkarma süreci gerçekleştirilmiştir.
Predict x₀ modu	False	Model doğrudan temiz görüntüyü değil, gürültü bileşenini (ϵ) tahmin eder. Bu yöntem daha kararlı öğrenme sağlar.

Eğitim sürecinde parametrelerin kararlı hale gelmesi ve ağırlık güncellemelerinden kaynaklanan ani dalgalanmaların önlenmesi için, modelin her güncelleme adımında EMA (Exponential Moving Average) ağırlıkları hesaplanmıştır. EMA modeli, değerlendirme aşamasında orijinal model yerine kullanılarak daha kararlı ve düşük varyanslı tahminler elde edilmiştir.

3.3 Veri Ön-İşleme Süreci

DICOM formatında olan PET görüntüleri model eğitime sunulmadan önce ön işleme sürecinden geçirilmiştir. DICOM verilerinde piksel değerlerin genellikle 16 bit tamsayı formatında saklanır. Ancak derin öğrenme modelleri bu formatla çalışmaya

uygun değildir. Piksel değerleri 3.1’de yer alan formül ile kayan noktalı sayılara çevrilir.

$$I(x, y) = \text{float32}(P(x, y)) \quad (3.1)$$

1.1 Bu dönüşüm sayesinde model, aktivasyon fonksiyonları tarafından küçük ölçekli gradyan değişimlerine daha duyarlı hale dönüştürülmüş olur.

PET görüntülerinde glukoz tüketimi yüksek olan dokular, (beyin, tümörlü doku vb.) geri kalan dokulara göre daha yüksek parlaklığa sahiptir. Görüntüde var olan farklı parlaklık seviyeleri, modelin öğrenme sürecinde gradyan dengesizliği ve aşırı öğrenme riskine yol açar. Bu nedenle görüntü değerleri 99.5 yoğunluk üzerinde kırılmıştır. Bu aralıkta yüksek değerler (örneğin 99.9) uç değerlerin eğitimde baskın olmasına neden olur ve görüntüdeki parlaklık seviye farkları devam etmiş olur. Düşük değerler (örneğin 95) klinik olarak anlamlı yüksek aktivitelerin kaybolmasına neden olabilir. Dolayısıyla literatürde tıbbi görüntü işlemede bu oran için %99-99.7 aralığı önerilmektedir. Veri setinde çok yüksek parlaklık seviyeleri bulunmadığı için yoğunluk değeri çok düşük tutulmadı. Düşük değerlerde var olan klinik anlamlı bilgilerin kaybolma riski olduğu için 99.5 değeri, yüksek sinyalleri korurken uç değerlerin etkisini azaltan dengeleyici bir eşik olarak tercih edilmiştir (3.2).

$$I_{clip}(x, y) = \min(I(x, y), \text{Perc}(I, 99.5)) \quad (3.2)$$

PET görüntüleri radyasyon sayımına dayalı olduğundan mutlak parlaklık, cihaz ve hasta bazında değişir. Görüntülerin dinamik aralığı [0,1] aralığına indirgenerek cihaz bağımlılığı bastırılmıştır. Derin öğrenme modellerinde özellikle sinir ağı katmanlarının ağırlıkları küçük rastgele değerlerle başlatıldığında girdi değerlerinin [0,1] arasında olması, gradyanların kararlı biçimde dağılmasını sağlamaktadır. Ayrıca bu aralık, kayıp fonksiyonlarının mutlak hata büyüklüklerini dengelemektedir (3.3).

$$I_{norm}(x, y) = \frac{I_{clip}(x, y) - \min(I_{clip})}{\max(I_{clip}) - \min(I_{clip}) + 10^{-8}} \quad (3.3)$$

Formülde bulunan 10^{-8} sayısı sıfıra bölme hatalarını önlemek için eklenmiştir.

PET görüntülerinin düşük sinyal-gürültü oranına sahip olması, özellikle düşük aktivite bölgelerinde detay kaybına sebep olabilmektedir. Bu durumu iyileştirmek için Gamma Dönüşümü kullanılmıştır (3.4).

$$I_{\text{gamma}}(\mathbf{x}, \mathbf{y}) = I_{\text{norm}}(\mathbf{x}, \mathbf{y})^\gamma \quad (3.4)$$

Bu formülde $\gamma = 0.9$ seçilmiştir. $\gamma < 1$ olduğunda düşük yoğunluklu bölgelerin parlaklığı artırılır ve dolayısıyla zayıf sinyallerin kontrastı güçlenir. $\gamma > 1$ değerleri yüksek parlaklık bölgelerini öne çıkarır, ancak PET verisinde bu, gürültü artışına neden olur. Literatürde PET ve düşük doz CT çalışmaları için önerilen aralık $\gamma \in [0.8, 1.1]$ 'dir (ör. Park et al., EJNMMI Physics, 2021). Bu nedenle 0.9 değeri, düşük doz PET'lerde kontrast kaybını en aza indirmek ve parlak bölgelerde doygunluğu önlemek için uygun görülmüştür.

Modelin simetrik öğrenme davranışını desteklemek amacıyla giriş verileri $[-1,1]$ aralığına ölçeklenmiştir. Bu ölçekleme, difüzyon tabanlı modellerde yaygın olarak tercih edilen bir yaklaşımdır. Bu yaklaşım, Ho et al. (2020) ve Nichol & Dhariwal (2021) tarafından tanımlanan DDPM çerçeveleriyle uyumludur.

Eğitim veri setinde tüm görüntüler 128x128 piksel çözünürlüğe ölçeklenmiştir. Daha büyük çözünürlük seviyesi GPU bellek tüketimini arttıracaktır. 64x64 gibi düşük çözünürlük seviyeleri de sinyal dağılımını fazla yumuşatan davranış göstermektedir.

Tüm ön işleme adımlarından sonra görüntülerin eğitime hazırlık aşamasına geçilir.

3.4 Görüntü Hazırlık Süreci

Bu çalışmada kullanılan PET veri seti, gerçek klinik görüntülerden oluşmakta olup, verilerde doğrudan “temiz” ve “gürültülü” olarak etiketlenmiş örnekler bulunmamaktadır. Ancak DDPM gibi difüzyon temelli gürültü giderme modelleri temel olarak bir görüntüye gürültü ekleme ve bu gürültüyü adım adım ortadan kaldırma prensibine dayanır. Dolayısıyla, modelin öğrenebilmesi için temiz görüntüler ve bunlardan türetilmiş gürültülü karşılıklarının oluşturulması gerekmektedir. Bu amaçla, orijinal PET görüntülerine Poisson dağılımına dayalı sentetik gürültü eklenmiştir. Poisson gürültüsü, PET gibi foton temelli ölçüm sistemlerinde gözlenen sayım (counting) istatistiksel belirsizlikleri modellemede gerçekçi bir yaklaşımdır. PET görüntülerinde foton tespiti olasılıksal bir süreç olduğundan, sinyalin sayım

oranına bağılı olarak rastlantısal dalgalanmalar meydana gelir. Bu nedenle, Poisson gürültüsü eklenmesi, verilerin gerçek fiziksel gürültü karakteristiğini taklit eder ve modelin klinik veriye daha iyi genelleşmesini sağlar. Gürültü ekleme işlemi sırasında, gürültü seviyesi λ parametresi 0.02 ile 0.08 aralığında farklı gürültü seviyelerini temsil edecek biçimde seçilmiştir. Bu aralık, hem düşük doz PET çekimlerinde görülen zayıf sinyalleri (0.02–0.04) hem de yüksek doz veya gürültülü çekimleri (0.06–0.08) temsil edecek biçimde deneysel olarak belirlenmiştir. Bu değerlerin seçimi, literatürde düşük ve yüksek gürültü seviyelerini modellemek için önerilen benzer Poisson parametre aralıklarıyla uyumludur (ör. Gong et al., Medical Physics, 2020; Huang et al., IEEE TMI, 2021).

Ek olarak, difüzyon modelinin başarısı büyük ölçüde veri çeşitliliğine bağlıdır. Modelin farklı gürültü koşullarında genelleme yapabilmesi için her bir temiz görüntüye dört farklı seviyede gürültü uygulanarak veri seti çeşitlendirilmiştir. Böylece model, aynı görüntü içeriğini farklı bozulma derecelerinde görerek daha esnek bir gürültü giderme kapasitesi kazanmıştır. Sonuç olarak, başlangıçta 306 eğitim ve 102 test olmak üzere toplam 408 dilim görüntüden oluşan veri seti, bu çoğaltma yöntemiyle dört kat artırılmış ve toplam 1224 adet eğitim örneğine ulaşılmıştır. Bu yaklaşım, modelin hem düşük hem de yüksek gürültü seviyelerinde öğrenmesini mümkün kılmış ve eğitim sürecinde gürültüye karşı dayanıklılığı önemli ölçüde artırmıştır.

3.5 Model Uygulaması

Giriş görüntüsüne Poisson gürültü eklenirken foton sayısı kullanılarak gürültü seviyesi belirlenmiştir. Foton sayısı, görüntülerde her bir pikselin aldığı foton miktarını ifade etmektedir. Bu çalışmada gürültü seviyesini belirlemek için farklı gürültü seviyelerinde görüntüler elde edilip değerlendirilmiştir. Her bir gürültü seviyesi, klinik uygulamalarda farklı radyasyon dozlarını ve buna bağılı olarak ortaya çıkan farklı gürültü seviyelerini temsil etmektedir.

$$\hat{x} = \lambda \cdot x \quad (3.5)$$


Denklem 3.5'te yer alan λ parametresi gürültü seviyesini temsil etmektedir. Gong ve arkadaşlarının IEEE de yayımlanan Medical physics çalışmasında λ parametresi için

0.02-0.04 aralığının zayıf sinyaller, 0.06-0.08 için yüksek doz veya gürültülü çekimleri temsil ettiği belirtilmiştir. Bu kapsamda, çalışmamızda λ parametresi için 0.02, 0.04, 0.06 ve 0.08 gürültü seviyeleri seçilerek düşük, orta ve yüksek gürültü koşulları temsil edilmiştir. Her bir gürültü seviyesi için modelin gürültü giderme performansı ayrı ayrı değerlendirilmiştir. Bu yaklaşımla birlikte modelin belirli bir gürültü seviyesine aşırı uyum sağlamadan, farklı gürültü koşullarında genelleme yeteneğini inceleme amaçlanmıştır.

Önerilen modelin gürültü giderme performansını bağlamsal olarak değerlendirebilmek amacıyla, sonuçlar literatürde yaygın olarak kullanılan klasik gürültü giderme yöntemlerinden biri olan TV (Toplam Varyasyon) yöntemi ile karşılaştırılmıştır. TV tabanlı yöntemler, görüntüdeki toplam gradyan büyüklüğünü sınırlandırarak gürültüyü azaltmayı ve kenar yapılarını korumayı amaçlayan düzenleştirme yaklaşımlarıdır. Tıbbi görüntü işlemede, özellikle kenar korunumu gerektiren uygulamalarda yaygın olarak kullanılmaktadır.

4. SONUÇLAR VE DEĞERLENDİRME

Şekil 4.1’de örnek bir PET görüntüsü için farklı gürültü seviyelerinde elde edilen sonuçlar sunulmaktadır. Görsel düzenlemede her satır farklı bir gürültü seviyesini ($\sigma = 0.03, 0.07$ ve 0.12), her sütun ise sırasıyla orijinal görüntüyü, gürültü eklenmiş görüntüyü, önerilen DDPM modelinin çıktısını ve TV tabanlı yöntemin sonucunu göstermektedir.



Şekil 4.1 : DDPM ve TV model görsel çıktıları.

Düşük gürültü seviyesinde ($\sigma = 0.03$) her iki yöntemin de gürültüyü belirli ölçüde bastırdığı gözlemlenmektedir. Bununla birlikte, DDPM çıktısında yapısal detayların ve metabolik aktivite dağılımının daha net biçimde korunduğu görülmektedir. TV yöntemi ise gürültü azaltımı sağlamakla birlikte görüntüde belirgin bir yumuşatma

etkisi oluşturarak kenar geçişlerinde ve yüksek aktivite bölgelerinde detay kaybına neden olmaktadır.

Gürültü seviyesi arttıkça TV yönteminin düzleştirici etkisi daha belirgin hâle gelmekte ve özellikle düşük kontrastlı bölgelerde yapısal ayrıntıların kaybolduğu görülmektedir. Buna karşılık, DDPM modeli yüksek gürültü koşullarında dahi görüntüdeki anatomik ve metabolik yapıyı daha dengeli biçimde korumakta, gürültü baskılama ile detay muhafazası arasında daha uygun bir denge sunmaktadır. Özellikle $\sigma = 0.12$ seviyesinde, TV yöntemi belirgin bir homojenleşme etkisi gösterirken, DDPM çıktısında bölgesel yoğunluk farklılıklarının ve sınır geçişlerinin daha iyi muhafaza edildiği gözlemlenmektedir. Bu durum, nicel metriklerde elde edilen sonuçlarla da tutarlıdır ve önerilen modelin değişken gürültü seviyelerinde daha kararlı bir gürültü giderme davranışı sergilediğini desteklemektedir.

Test sonucunda modelin performansı temel metrikler olan PSNR (Peak Signal-to-Noise Ratio), RMSE (Root Mean Square Error), MAE (Mean Absolute Error) ve SSIM (Structural Similarity Index Measure) kullanılarak değerlendirilmiştir. Bu metriklerin detayları Çizelge 4.1’de yer almaktadır.

Çizelge 4.1 : Model başarısını değerlendirmede kullanılan metrikler ve detayları.

Metrik	Açıklama
PSNR (Peak Signal-to-Noise Ratio)	Gürültü düzeyine karşı duyarlıdır; yüksek PSNR değeri daha yüksek görüntü kalitesini ifade eder.
SSIM (Structural Similarity Index Measure)	Görüntülerin yapısal benzerliğini değerlendirir; 1’e yaklaştıkça daha yüksek yapısal sadakat anlamına gelir.
RMSE (Root Mean Square Error)	Piksel bazlı hata büyüklüğünü ölçer; düşük değerler daha başarılı rekonstrüksiyonu gösterir.
MAE (Mean Absolute Error)	Ortalama mutlak farkı temsil eder; gürültü giderme başarısını doğrudan yansıtır.

Çizelge 4.2’de farklı gürültü seviyelerinde önerilen DDPM modeli ile TV tabanlı yönteme ait nicel performans sonuçları ortalama $\pm$ standart sapma biçiminde sunulmuştur. Sonuçlar, her gürültü seviyesi için test görüntüleri üzerinden hesaplanan metrik dağılımlarını yansıtmaktadır.

Çizelge 4.2 : Test sonucu metrik hesapları.

Gürültü Seviyesi	PSNR DDPM	PSNR TV	SSIM DDPM	SSIM TV	RMSE DDPM	RMSE TV	MAE DDPM	MAE TV
0.03	33.30 ± 1.10	33.65 ± 1.40	0.9510 ± 0.0035	0.9324 ±0.0053	0.0216 ± 0.0018	0.0210 ±0.0021	0.0082 ±0.0009	0.0091 ±0.0010
0.05	33.30 ± 1.15	33.58 ± 1.80	0.9484 ± 0.0046	0.9216 ±0.0062	0.0224 ± 0.0023	0.0211 ±0.0026	0.0084 ±0.0008	0.0095 ±0.0012
0.07	33.96 ± 1.20	33.33 ± 1.60	0.9534 ± 0.0045	0.9048 ±0.0086	0.0200 ± 0.0024	0.0217 ±0.0033	0.0076 ±0.0012	0.0100 ±0.0015
0.09	34.15 ± 1.10	33.17 ± 1.50	0.9506 ± 0.0042	0.8906 ±0.0095	0.0196 ± 0.0021	0.0221 ±0.0036	0.0076 ±0.0014	0.0105 ±0.0018
0.12	33.92 ± 1.30	33.02 ± 1.70	0.9434 ± 0.0048	0.8714 ±0.0101	0.0201 ± 0.0027	0.0225 ±0.0038	0.0079 ±0.0013	0.0110 ±0.0021

PSNR değerleri incelendiğinde, düşük gürültü seviyesinde ($\sigma = 0.03$) iki yöntemin benzer performans sergilediği görülmektedir. Ancak gürültü seviyesi arttıkça DDPM modelinin PSNR değerlerinin daha kararlı bir artış eğilimi gösterdiği ve özellikle orta–yüksek gürültü koşullarında TV yöntemine kıyasla daha yüksek değerlere ulaştığı gözlemlenmektedir. Standart sapma değerlerinin tüm gürültü seviyelerinde benzer aralıklarda kalması, DDPM modelinin farklı görüntüler üzerinde istikrarlı sonuçlar ürettiğini göstermektedir.


SSIM sonuçları yapısal benzerlik açısından değerlendirildiğinde, DDPM modelinin tüm gürültü seviyelerinde TV yöntemine göre daha yüksek benzerlik değerleri sağladığı görülmektedir. Bu durum, özellikle metabolik dağılımın ve bölgesel yoğunluk farklılıklarının korunması açısından DDPM yaklaşımının daha dengeli bir performans sunduğunu göstermektedir. TV yöntemi ise gürültü baskılama sağlamakla birlikte, artan gürültü seviyelerinde yapısal detay kaybına daha yatkın bir davranış sergilemektedir.

Hata temelli metrikler olan RMSE ve MAE incelendiğinde de benzer bir eğilim gözlemlenmektedir. DDPM modelinin tüm gürültü seviyelerinde daha düşük hata değerleri ürettiği ve özellikle yüksek gürültü koşullarında hata artışını sınırlı tuttuğu görülmektedir. TV yönteminde ise gürültü seviyesi arttıkça hata değerlerinde daha belirgin bir artış eğilimi ortaya çıkmaktadır.

Genel olarak değerlendirildiğinde, DDPM modeli gürültü azaltma ile yapısal bilgi koruma arasında daha dengeli bir performans sunmakta ve değişken gürültü

koşullarında daha kararlı sonuçlar üretmektedir. Bu bulgular, difüzyon tabanlı yaklaşımın PET görüntülerinde gürültü giderme problemi için etkili ve genellenebilir bir çözüm sunduğunu desteklemektedir.

Derin öğrenme tabanlı modellerde eğitim sürecinin sağlıklı ilerleyip ilerlemediğini değerlendirmek için en temel araçlardan biri eğitim (training) ve doğrulama (validation) kayıp eğrileridir. Kayıp (loss) değeri, modelin ürettiği çıktının hedef değerlerden ne kadar saptığını nicel olarak ifade eder. Eğitim kaybı, modelin öğrenme sürecinde kullandığı veri üzerinde hesaplanırken; doğrulama kaybı, modelin daha önce görmediği ayrı bir veri alt kümesi üzerinde hesaplanır ve genelleme yeteneğini değerlendirmek için kullanılır. Eğitim sürecinde ideal olarak beklenen davranış, eğitim kaybının epoch'lar boyunca kademeli olarak azalmasıdır. Bu durum, model parametrelerinin optimize edildiğini ve veri üzerindeki örüntülerin öğrenildiğini gösterir. Ancak tek başına eğitim kaybının azalması yeterli değildir. Modelin gerçek performansı, daha önce görmediği veriler üzerindeki başarısı ile değerlendirilir. Bu nedenle doğrulama kaybının seyri kritik öneme sahiptir. Şekil 4.2'de önerilen modele ait eğitim ve doğrulama eğrileri verilmiştir.



Şekil 4.2 : DDPM modele ait eğitim(training) ve doğrulama(validation) eğrileri.

Eđitim s¼reci 120. epoch sonrasında ek 50 epoch boyunca devam ettirilmiş ve bu s¼reçte eđitim ile dođrulama kayıpları birlikte izlenmiştir. Kayıp deđerlerinin genel olarak azalma eđiliminde olması, modelin ¼đrenme kapasitesinin s¼rd¼đ¼n¼ göstermektedir. İlerleyen epoch'larda kayıp eđrisinin eđimi belirgin biçimde azalmış ve eđri daha yatay bir davranış sergilemeye başlamıştır. Bu durum, optimizasyon s¼recinin daha d¼ř¼k gradyan b¼y¼kl¼kleri ile ilerlediđini ve modelin yakınsama rejimine, yani optimum seviyeye yaklaştıđını d¼ř¼nd¼rmektedir. Bu nedenle model seğıimi, dođrulama kaybının minimum olduđu epoch temel alınarak yapılmış ve eđitim s¼resi genelleme performansı ağıısından izlenebilir biçimde gerekçelendirilmiştir.





5. TARTIŞMA VE ÖNERİLER

Bu çalışmada, Pozitron Emisyon Tomografisi (PET) görüntülerinde gürültü giderme problemine yönelik olarak difüzyon tabanlı olasılıksal modellerden biri olan Denoising Diffusion Probabilistic Model (DDPM) yaklaşımı ele alınmıştır. PET görüntülerinin doğası gereği düşük sinyal-gürültü oranına sahip olması, görüntü kalitesini ve klinik yorumlanabilirliği sınırlayan temel faktörlerden biridir. Bu nedenle, gürültünün etkin biçimde bastırılması ve aynı zamanda anatomik ve fonksiyonel detayların korunması, PET görüntü işleme çalışmalarında kritik bir öneme sahiptir.

Çalışma kapsamında gerçek klinik PET verilerinden oluşan bir veri seti kullanılmış ve temiz-gürültülü görüntü çiftlerinin doğrudan mevcut olmaması problemi, Poisson dağılımına dayalı sentetik gürültü ekleme yaklaşımı ile ele alınmıştır. Bu tercih, PET görüntüleme sistemlerinin fiziksel ölçüm sürecini yansıtan sayım istatistiklerini modellemesi açısından gerçekçi bir çözüm sunmaktadır. Model, farklı gürültü seviyelerini temsil edecek biçimde oluşturulan veri seti üzerinde eğitilmiş ve düşüktür yükseğe değişen gürültü koşullarında test edilmiştir. Böylece modelin yalnızca belirli bir gürültü düzeyine değil, değişken gürültü senaryolarına karşı genelleme yeteneği değerlendirilmiştir.

Nicel sonuçlar, önerilen DDPM tabanlı modelin tüm gürültü seviyelerinde kararlı bir gürültü giderme davranışı sergilediğini göstermektedir. Özellikle hata temelli metrikler olan RMSE ve MAE değerlerinin gürültü seviyesi arttıkça sınırlı değişim göstermesi, modelin yüksek gürültü koşullarına karşı dayanıklı bir yapı sunduğunu ortaya koymaktadır. Ayrıca performans metriklerinin ortalama $\pm$ standart sapma biçiminde raporlanması, modelin farklı test görüntüleri üzerindeki tutarlılığını değerlendirme imkânı sağlamıştır. Standart sapma değerlerinin tüm gürültü seviyelerinde benzer aralıklarda seyretmesi, modelin yalnızca ortalama performans açısından değil, görüntü bazında da istikrarlı sonuçlar ürettiğini göstermektedir.

TV tabanlı yöntemle yapılan karşılaştırmalı değerlendirmede, TV yaklaşımının gürültü baskılama konusunda belirli düzeyde başarı sağladığı, ancak artan gürültü seviyelerinde görüntüde daha belirgin bir yumuşatma etkisi oluşturduğu

gözlemlenmiştir. Özellikle düşük kontrastlı ve yumuşak geçişli PET yapılarında, TV yönteminin düzenleme etkisinin bazı yapısal detayların silikleşmesine neden olabildiği görülmüştür. Buna karşılık DDPM modeli, gürültü azaltma ile yapısal bilgi koruma arasında daha dengeli bir performans sunmuş ve yapısal benzerlik metriklerinde daha yüksek değerler üretmiştir. Bu bulgular, difüzyon tabanlı modellerin karmaşık gürültü yapısına sahip tıbbi görüntülerde klasik düzenleme temelli yöntemlere kıyasla daha esnek bir öğrenme kapasitesine sahip olabileceğini göstermektedir.

Görsel değerlendirmeler, PET görüntülerinin sınırlı uzamsal çözünürlüğü ve düşük kontrast yapısı nedeniyle yöntemler arasındaki farkların her zaman çıplak gözle belirgin biçimde ayırt edilemeyebileceğini ortaya koymuştur. Bu durum, gürültü giderme performansının değerlendirilmesinde yalnızca görsel incelemelere dayanmanın yeterli olmadığını ve nicel metriklerle desteklenen bütüncül bir analiz yaklaşımının gerekliliğini vurgulamaktadır. Bu çalışmada kullanılan PSNR, SSIM, RMSE ve MAE metrikleri, model performansının daha nesnel ve karşılaştırılabilir biçimde değerlendirilmesine olanak tanımıştır.

Çalışmanın bazı sınırlılıkları bulunmaktadır. Kullanılan veri setinin boyutunun sınırlı olması ve eğitim sürecinde sentetik gürültü modellerine dayanılması, elde edilen sonuçların gerçek düşük doz klinik senaryolara genellenebilirliğini kısmen sınırlandırabilir. Ayrıca çalışma iki boyutlu PET dilimleri üzerinde gerçekleştirilmiş olup, üç boyutlu hacimsel bağlam doğrudan modele entegre edilmemiştir. Gelecekte yapılacak çalışmalarda, 3B difüzyon modellerinin kullanılması, daha geniş ve çok merkezli veri setleri ile modelin doğrulanması ve gerçek düşük doz protokollerle klinik değerlendirmelerin yapılması önerilmektedir.

Sonuç olarak, elde edilen bulgular difüzyon tabanlı DDPM yaklaşımının PET görüntülerinde gürültü giderme problemine yönelik etkili ve kararlı bir çözüm sunduğunu göstermektedir. Modelin farklı gürültü seviyelerinde dengeli performans sergilemesi, bu yaklaşımın tıbbi görüntü iyileştirme alanında daha ileri çalışmalar için güçlü bir temel oluşturduğunu ortaya koymaktadır.

KAYNAKLAR

- [1] Positron Emission Tomography in Neuroscience and Diabetes. (2014). Dartmouth Undergraduate Journal of Science.
- [2] **Rong, J., Haider, A., Jeppesen, T.E. et al.** (2023). Radiochemistry for positron emission tomography. Nature Communications
- [3] **Prasad, R.** (2025). Positron Emission Tomography (PET Scan). In: Understanding Medical Devices. Series in BioEngineering. Springer, Cham.
- [4] **Asyali, M.H., Kara S., Yılmaz B.** (2014). Nükleer Tıp ve Emisyon görüntüleme teknikleri. Biyomedikal Mühendisliğinin Temelleri (1. Basım), Syf. 739-772, Nobel Akademik Yayıncılık
- [5] **Boellaard, R.** (2009). Standards for PET image acquisition and quantitative data analysis. Journal of Nuclear Medicine, 50(Suppl 1), 11S–20S.
- [6] **Halpern, B.S. et al.** (2004). Impact of patient weight and emission scan duration on PET/CT image quality and lesion detectability. Journal of Nuclear Medicine, 45(5), 797–801.
- [7] **UNSCEAR.** (2008). Sources and Effects of Ionizing Radiation. UNSCEAR 2008 Report.
- [8] **Olivier Rousset, Arman Rahmim, Abass Alavi, Habib Zaidi.** (2007). Partial Volume Correction Strategies in PET. PET Clinics (2. Cilt, 2. Sayı), Syf 235-249
- [9] **Doss, K.K.M. et al.** (2024). Utilizing deep learning techniques to improve image quality and noise reduction in preclinical low-dose PET images in the sinogram domain. Medical Physics.
- [10] **Xing, Y. et al.** (2022). Deep learning-assisted PET imaging achieves fast scan/low-dose examination. EJNMMI Physics
- [11] **Vegard Antun, Francesco Renna, Clarice Poon, Anders C. Hansen** (2019). “On instabilities of deep learning in image reconstruction and the potential costs of AI”, PNAS
- [12] **Jonathan Ho, Ajay Jain, Pieter Abbeel** (2020) Denoising Diffusion Probabilistic Models. In Advances in Neural Information Processing Systems (NeurIPS)
- [13] **Hung, A. L., Zhao, K., Zheng, H., Yan, R., & Raman, S. S.** (2023). Med-cDiff: Conditional Medical Image Generation with Diffusion Models. Bioengineering, 10(11), 1258.
- [14] **Hein, D., Bozorgpour, A., Merhof, D., & Wang, G.** (2024). Physics-Inspired Generative Models in Medical Imaging: A Review. arXiv preprint arXiv:2407.10856.

- [15] **Dalmaz, O., et al.** (2023). Denoising diffusion adversarial models for unconditional medical image generation. *IEEE Transactions on Medical Imaging*.
- [16] **Webber, G., Reader, A. J.** (2024). Diffusion Models for Medical Image Reconstruction. *British Journal of Radiology AI*.
- [17] **Wu, W., et al.** (2024). Stage-by-stage wavelet optimization refinement diffusion model for sparse-view CT reconstruction. *IEEE Transactions on Medical Imaging*.
- [18] **Boxiao Yu, Savas Ozdemir, Jiong Wu, Yizhou Chen, Kuangyu Shi and Kuang Gong,** Haziran (2025). PET Imaging Denoising Using Text-Guided Diffusion Models. *The Journal of Nuclear Medicine (JNM)*
- [19] **Y. Djebra; X. Liu; T. Marin; A. Tiss; M. Dhaynaut; N. Guehl.** (2024) Diffusion-based Bayesian posterior distribution prediction of kinetic parameters in dynamic PET. *IEEE Nuclear Science Symposium (NSS)*
- [20] **Ziyuan Zhou, Tzu-an Song, Fan Yang, Bowen Lei ve Joyita Dutta.** (Haziran 2025) A generalizable diffusion transformer with masked image training for cross-tracer PET denoising. *The Journal of Nuclear Medicine (JNM)*
- [21] **Xutao Guo, Chenfei Ye, Mingkai Zhang, Xingyu Hao, Yanwu Yang, Yue Yu, Ting Ma, Ying Han** (2025). A Structure-Preserving Denoising Diffusion Model for AV45 PET Quantification Without MRI in Alzheimer's Disease Diagnosis. *Wiley Online Library*
- [22] **Aguila, A. L., Liu, P., Aguirre, M. C., & Iglesias, J. E.** (2025). Generating healthy counterfactuals with denoising diffusion bridge models
- [23] **Safari, M., Yang, X., et al.** (2025). Res-MoCoDiff: residual-guided diffusion models for motion artifact correction in brain MRI. *Physics in Medicine and Biology*
- [24] **Zhang, Z., et al.** (2025). A Framework for Guiding DDPM-Based Reconstruction of Damaged CT Projections Using Traditional Methods. *Journal of Imaging Informatics in Medicine*
- [25] **Karsten Kreis, Ruiqi Gao, Arash Vahdat.** (2022). Denoising Diffusion-based Generative Modeling: Foundations and Applications. *CVPR 2022*
- [26] **Makitalo, M., & Foi, A.** (2010). Optimal inversion of the Anscombe transformation in low-count Poisson image denoising. *IEEE Transactions on Image Processing*, 20(1), 99–109.
- [27] **Mansoor, A., Bagci, U., & Mollura, D. J.** (2014). Optimally Stabilized PET Image Denoising Using Trilateral Filtering. *arXiv preprint*.
- [28] **Eckert, D., Vesal, S., Ritschl, L., Kappler, S., & Maier, A.** (2019). Deep Learning-based Denoising of Mammographic Images using Physics-driven Data Augmentation. *arXiv preprint*.
- [29] **Anscombe, F. J.** (1948). The transformation of Poisson, binomial and negative-binomial data. *Biometrika*, 35(3/4), 246–254.
- [30] Wikipedia. (Ağustos 2024). Anscombe Transform.

- [31] **Kinahan, P., Muzi, M., Bialecki, B., Herman, B., & Coombs, L.** (2019). Data from the ACRIN 6668 Trial NSCLC-FDG-PET (Version 2) [Data set]. The Cancer Imaging Archive





ÖZGEÇMİŞ

Ad-Soyad : **Emine Pacci**

ÖĞRENİM DURUMU:

- **Lisans** : 2019, Pamukkale Üniversitesi, Teknoloji Fakültesi, Biyomedikal Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- TÜBİTAK 2210-A Genel Yurtiçi Yüksek Lisans Bursiyerliğine hak kazandı.
- 2023 yılından itibaren Dr. Ersin Arslan Eğitim ve Araştırma Hastanesi'nde Biyomedikal Mühendisi olarak görev yapmakta.

DİĞER YAYINLAR, SUNUMLAR VE PATENTLER:

- **Pacci E.**, Yıldırım İ., 2025, “PET Image Denoising Using Denoising Diffusion Probabilistic Models (DDPMs)”, IGRS’25- 4th International Graduate Research Symposium, 12-14 May 2025, Istanbul – Turkey