



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**PERİYODİK GÜRÜLTÜLERİN GİDERİLMESİNDE İSTATİSTİKİ
VE DERİN ÖĞRENME YÖNTEMLERİNİN BİRLİKTE
KULLANILMASI**

YÜKSEK LİSANS TEZİ

Murat ALTUNOK

Danışman: Doç. Dr. Bülent TURAN

TOKAT- 2024

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre, Doç. Dr. Bülent TURAN danışmanlığında hazırlamış olduğum “Periyodik Gürültülerin Giderilmesinde İstatistiki ve Derin Öğrenme Yöntemlerinin Birlikte Kullanılması” adlı Yüksek Lisans tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

.../.../...

Murat ALTUNOK

ÖZSÖZ

Tez konusunun belirlenmesinden çalışmanın tamamlanmasına kadar yürütülen bütün süreçte bana yol gösteren ve hiçbir yardımını esirgemeyen tez danışmanım Doç. Dr. Bülent TURAN hocama, destekleriyle her zaman yanımda olan sevgili eşim ve kızıma sonsuz teşekkürlerimi sunarım.

Murat ALTUNOK



ÖZET

PERİYODİK GÜRÜLTÜLERİN GİDERİLMESİNDE İSTATİSTİKİ VE DERİN ÖĞRENME YÖNTEMLERİNİN BİRLİKTE KULLANILMASI

ALTUNOK, Murat

Yüksek Lisans, Eğitim Programları ve Öğretim Bilim Dalı

Tez Danışmanı: Doç. Dr. Bülent TURAN

Ağustos 2024, xii + 73 sayfa

Bu tez çalışmasında, dijital görüntülerde sıklıkla karşılaşılan periyodik gürültülerin giderilmesi amacıyla derin öğrenme yöntemleri kullanılarak iki aşamalı bir çözüm geliştirilmiştir. Çalışma, periyodik gürültülerin dijital görüntüleme sistemlerinde sıkça karşılaşılan bir problem olduğunu ve bu gürültülerin, görüntü kalitesini ciddi şekilde düşürerek analiz ve işlemeyi zorlaştırdığını vurgulamaktadır. Çalışmanın amacı, geleneksel yöntemlerin yetersiz kaldığı durumlarda derin öğrenme tekniklerini kullanarak daha etkili bir gürültü giderme çözümü sunmaktır. Bu kapsamda, DnCNN (Denoising Convolutional Neural Network) modeli ile frekans alanı filtreleme yöntemleri birleştirilerek iki aşamalı bir model geliştirilmiştir. Bu modelin performansı, farklı gürültü türleri ve çeşitli görüntü veri setleri üzerinde değerlendirilmiş ve geleneksel yöntemlere kıyasla üstün sonuçlar elde edilmiştir. Tezde, öncelikle gürültülerin tanımı ve türleri detaylı bir şekilde incelenmiş, ardından derin öğrenme yöntemlerinin temel prensipleri ve uygulama alanları açıklanmıştır. Sonuç olarak, geliştirilen iki aşamalı modelin periyodik gürültüleri etkin bir şekilde giderdiği ve görüntü kalitesini önemli ölçüde artırdığı gösterilmiştir.

Anahtar Kelimeler: Periyodik Gürültü, Gürültü Giderme Yöntemleri, Derin Öğrenme, DnCNN,

ABSTRACT

THE COMBINED USE OF STATISTICAL AND DEEP LEARNING METHODS IN THE REMOVAL OF PERIODIC NOISE

ALTUNOK, Murat

Master's Thesis, Division of Curriculum and Instruction

Advisor: Doç. Dr. Bülent TURAN

August 2024, xii + 73 pages

In this thesis, a two-stage solution has been developed using deep learning methods to remove periodic noise frequently encountered in digital images. The study emphasizes that periodic noise is a common problem in digital imaging systems and that this noise significantly degrades image quality, making analysis and processing difficult. The aim of the study is to provide a more effective noise reduction solution using deep learning techniques in situations where traditional methods are insufficient. In this context, a two-stage model has been developed by combining the DnCNN (Denoising Convolutional Neural Network) model with frequency domain filtering methods. The performance of this model has been evaluated on different types of noise and various image datasets, yielding superior results compared to traditional methods. The thesis first thoroughly examines the definition and types of noise, followed by an explanation of the fundamental principles and application areas of deep learning methods. In conclusion, it has been demonstrated that the developed two-stage model effectively removes periodic noise and significantly improves image quality.

Keywords: Periodic Noise, Noise Removal Methods, Deep Learning, DnCNN

İÇİNDEKİLER

ETİK SÖZLEŞME	ii
ÖZSÖZ.....	iii
ÖZET	iv
ABSTRACT.....	v
ŞEKİLLER.....	viii
TABLO LİSTESİ	xi
KISALTMALAR.....	xii
1. GİRİŞ	1
2. LİTERATÜR TARAMASI.....	3
3. GENEL BİLGİLER	10
3.1. Dijital Görüntülerdeki Gürültüler ve Gürültü Giderme Teknikleri	11
3.1.1. Gürültü Nedir?	11
3.1.2. Gürültü Tipleri	11
3.1.3. Gauss Gürültüsü	12
3.1.4. Tuz & Biber Gürültüsü	12
3.1.5. Benek Gürültüsü	13
3.1.6. Foton veya Poisson Gürültüsü	14
3.1.7. Periyodik Gürültü	15
3.1.8. Gürültü Giderme Teknikleri.....	24
3.1.9. Periyodik Gürültü Giderme Teknikleri ve Akademik Çalışmalar	29
3.2. Derin Öğrenme ve Derin Öğrenme ile Görüntülerdeki Gürültülerinin Giderilmesi.....	33
3.2.1. Derin Öğrenme	33
3.2.2. Evrişimli Sinir Ağları-ESA (Convolutional Neural Networks-CNN)	33
3.2.3. Derin Öğrenme ile Gürültü Giderme	41

3.2.4. Generative Discriminative Networks (GAN)	41
3.2.5. Denoising Convolutional Neural Networks (DnCNN)	42
3.2.6. FFDNet (Flexible and Fast Denoising Convolutional Neural Network).....	43
3.2.7. IRCNN (Iterative Residual Convolutional Neural Network)	43
3.2.8. MemNet (Multi-level MemNet)	43
4. MATERYAL VE YÖNTEM	45
4.1. Periyodik Gürültü Tespiti, Gürültünün Giderilmesi ve DnCNN Modeli ile İyileştirme	45
4.1.1. Veri Seti	52
4.1.2. Ön İşleme ve Model Eğitimi	54
5. SONUÇ VE ÖNERİLER.....	64
6. KAYNAKLAR.....	65

ŞEKİLLER

Şekil No	Sayfa
Şekil 3.1.Gürültüsüz görüntü, Gauss gürültüsü ve gürültü uygulanmış görüntü.....	12
Şekil 3.2.Tuz & Biber gürültüsü eklenmiş görüntü ve orijinal görüntü	13
Şekil 3.3.Benek gürültüsü ve gürültü eklenmiş görüntü.....	14
Şekil 3.4.Possion gürültüsü ve gürültü eklenmiş görüntü	15
Şekil 3.5. Periyodik gürültülü görüntü ve gürültünün frekans uzayındaki görünümü, ..	16
Şekil 3.6. Düşük frekans aralığına ait grafik	17
Şekil 3.7.Düşük frekansa sahip gürültü, 2 boyutlu frekans uzayında gürültünün tepe noktalarına ait görünümü ve 3 boyutlu frekans uzayındaki tepe noktalarına ait görüntü	18
Şekil 3.8.Düşük frekanslı periyodik gürültü eklenmiş kameraman görüntüsü ve gürültünün frekans uzayındaki görünümü.	18
Şekil 3.9.Yüksek frekans aralık grafiği	19
Şekil 3.10.Yüksek frekansa sahip periyodik gürültü, 2 boyutlu frekans uzayında gürültünün tepe noktalarına ait görünümü ve 3 boyutlu frekans uzayındaki tepe noktalarına ait görüntü	19
Şekil 3.11.Saf periyodik gürültü uygulanmış görüntüler ve frekans uzayında tepe noktalarının işaretli şekli. Çapraz, yatay ve dikey şekilde.....	21
Şekil 3.12.Yarı periyodik gürültü, gürültünün uygulanmış kameraman görüntüsü ve frekans uzayındaki tepe noktalarının görünümü.....	22
Şekil 3.13.Çok frekanslı periyodik gürültülü görüntü ve gürültünün frekans uzayındaki görünümü.....	23
Şekil 3.14.Periyodik yapıya sahip Şerit gürültüsü, gürültü eklenmiş görüntü ve gürültünün frekans uzayındaki görünümü.	24
Şekil 3.15.Yapay sinir ağı mimarisi (Amidi & Amidi, Stanford, 2023)	33
Şekil 3.16.Evrişimli Sinir Ağı mimarisi (Amidi & Amidi, Stanford, 2023).....	34
Şekil 3.17.LeNet ağına ait çalışma prensibini gösteren mimari yapı (Zhang, Lipton, Li, & Smola, 2023).....	35
Şekil 3.18.AlexNet mimarisi (Han, Zhong, Liqin, & Zhang, 2017).....	36
Şekil 3.19.ZFNet mimarisi (Olugboja ve ark., 2021)	37
Şekil 3.20.VGG mimarisi ve ağ yapısı (İnik & Turan, 2018).....	38

Şekil 3.21.GoogLeNet mimarisi (Ajith ve ark., 2021)	39
Şekil 3.22.CNN mimarileri ve ILSVRC'deki hata oranı sonucu (Chowanda & Sutoyo, 2019)	40
Şekil 3.23.ResNet mimarisi görünümü (Reith & Wandell, 2019)	41
Şekil 3.24.GAN ağının mimari yapısı (Zhu ve ark., 2022)	42
Şekil 3.25.DnCNN Ağ Mimarisi (Alawode ve ark., 2021).....	43
Şekil 4.1. Saf Çapraz periyodik gürültü eklenmiş görüntü ve fouier dönüşümü sonrasında frekans uzayındaki işaretlenmiş tepe noktaları	46
Şekil 4.2. Saf Dikey periyodik gürültü eklenmiş görüntü ve fouier dönüşümü sonrasında frekans uzayındaki işaretlenmiş tepe noktaları	46
Şekil 4.3. Saf Yatay periyodik gürültü eklenmiş görüntü ve fouier dönüşümü sonrasında frekans uzayındaki işaretlenmiş tepe noktaları	46
Şekil 4.4. Yarı periyodik gürültü eklenmiş görüntü ve fouier dönüşümü sonrasında frekans uzayındaki işaretlenmiş tepe noktaları.....	47
Şekil 4.5. Düşük Frekanslı periyodik gürültü eklenmiş görüntü ve fouier dönüşümü sonrasında frekans uzayındaki işaretlenmiş tepe noktaları.....	47
Şekil 4.6.Yüksek Frekanslı periyodik gürültü eklenmiş görüntü ve fouier dönüşümü sonrasında frekans uzayındaki işaretlenmiş tepe noktaları.....	47
Şekil 4.7. Çok Frekanslı (multi) periyodik gürültü eklenmiş görüntü ve fouier dönüşümü sonrasında frekans uzayındaki işaretlenmiş tepe noktaları.....	48
Şekil 4.8. Python programlama dili ile PSNR değeri hesaplama yöntemi	50
Şekil 4.9. Python programlama dili ile SSIM hesaplama yöntemi	51
Şekil 4.10. Veri setinde kullanılan periyodik gürültülü görüntülere ait bir kesit.....	54
Şekil 4. 11. Hazırlanan DnCNN modeline ait mimari görünümü.....	56
Şekil 4.12. a) Orijinal görüntü b) Düşük frekans periyodik gürültü eklenmiş görüntü c) İstatistiksel temizleme (Çentik filtre) yöntemi ile temizlenmiş gürültülü görüntü, d) Eğitilmiş DnCNN (Denoising Convolutional Neural Network) modeli ile temizlenmiş görüntü.	58
Şekil 4.13. a) Orijinal görüntü b) Yüksek frekans periyodik gürültü eklenmiş görüntü c) İstatistiksel temizleme (Çentik filtre) yöntemi ile temizlenmiş gürültülü görüntü d) Eğitilmiş DnCNN (Denoising Convolutional Neural Network) modeli ile temizlenmiş görüntü.	59

Şekil 4.14. a) Orijinal görüntü b) Çok frekanslı (multi) periyodik gürültü eklenmiş görüntü c) İstatistiksel temizleme (Çentik filtre) yöntemi ile temizlenmiş gürültülü görüntü d) Eğitilmiş DnCNN (Denoising Convolutional Neural Network) modeli ile temizlenmiş görüntü.	59
Şekil 4. 15. a) Orijinal görüntü b) Yarı periyodik (quasi) gürültü eklenmiş görüntü c) İstatistiksel temizleme (Çentik filtre) yöntemi ile temizlenmiş gürültülü görüntü d) Eğitilmiş DnCNN (Denoising Convolutional Neural Network) modeli ile temizlenmiş görüntü.	60
Şekil 4. 16. a) Orijinal görüntü b) Saf çapraz periyodik gürültü eklenmiş görüntü c) İstatistiksel temizleme (Ortanca filtre) yöntemi ile temizlenmiş gürültülü görüntü d) Eğitilmiş DnCNN (Denoising Convolutional Neural Network) modeli ile temizlenmiş görüntü.	61
Şekil 4.17. a) Orijinal görüntü b) Saf dikey periyodik gürültü eklenmiş görüntü c) İstatistiksel temizleme (Ortanca filtre) yöntemi ile temizlenmiş gürültülü görüntü, d) Eğitilmiş DnCNN (Denoising Convolutional Neural Network) modeli ile temizlenmiş görüntü.	61
Şekil 4.18. a) Orijinal görüntü b) Saf yatay periyodik gürültü eklenmiş görüntü c) İstatistiksel temizleme (Ortanca filtre) yöntemi ile temizlenmiş gürültülü görüntü d) Eğitilmiş DnCNN (Denoising Convolutional Neural Network) modeli ile temizlenmiş görüntü.	62

TABLO LİSTESİ

Tablo No	Sayfa
Tablo 1. Basketbol oynayanlara ait gürültülü görüntülerin istatistiksel olarak temizlenmesi sonrasında ve DnCNN modeli ile iyileştirilmesi sonrasında PSNR ve SSIM değerleri	62
Tablo 2. Kameraman görüntüsüne ait gürültülü görüntülerin istatistiksel olarak temizlenmesi sonrasında ve DnCNN modeli ile iyileştirilmesi sonrasında PSNR ve SSIM değerleri	63



KISALTMALAR

- 2DFFT - 2-D fast Fourier transform (iki boyutlu Hızlı Fourier Dönüşümleri)
- AWGN - Additive White Gaussian Noise
- BSDS68 - Berkeley Segmentation Dataset and Benchmark 68 Test
- CNN - Convolutional Neural Networks
- DCB - Dynamic Convolutional Block
- DeCNN - Deconvolutional Neural Network
- DnCNN - Denoising Convolutional Neural Network
- ESA - ILSVRC - ImageNet Large Scale Visual Recognition Challenge
- FACD - Fourier-Assisted Correlative Denoising (Fourier Destekli Korelatif Gürültü Giderme)
- FFDNet - Flexible and Fast Denoising Convolutional Neural Network
- GPU - Graphics Processing Unit
- IRCNN - Iterative Residual Convolutional Neural Network
- MemNet - Multi-Level MemNet
- NIN - Network in Network
- PMSDNet - Progressive Multi-scale Deraining Network
- PSNR - Peak signal-to-noise ratio (Tepe sinyal-gürültü oranı)
- RB - Residual Block
- RFPCM - Rough-Fuzzy Possibilistic C-Means
- RVIN - Random-Valued Impulse Noise (Rastgele Değerli Darbe Gürültüsü)
- SAR - Sentetik Açıklıklı Radar
- SISR - Single Image Super-Resolution
- SSIM - Structural Similarity Index Measure (Yapısal benzerlik İndeksi)
- TV - Total Variation (Toplam Varyasyon)
- VGG - Very Deep Convolutional Networks
- WEB - Wavelet Transform and Enhancement Blocks

1. GİRİŞ

Gürültüler görüntünün elde edilmesi, saklanması, aktarılması veya dijital ortama taşınması esnasında çeşitli bozulmalara maruz kalır. Bu bozulmalar çoğunlukla görüntüler üzerinde belirgin gürültüler bırakır.

Dijital görüntülerde karşılaşılan temel gürültü türleri arasında Gaussian gürültüsü, beyaz gürültü, Brownian (fraktal) gürültüsü, tuz-biber gürültüsü (salt&pepper), periyodik gürültü, kuantizasyon gürültüsü, speckle gürültüsü, foton gürültüsü (Poisson gürültüsü), Poisson-Gaussian gürültüsü gibi gürültüler bulunmaktadır (Boyat & Brijendra, 2015) (Altunok & Turan, 2022). Bu gürültüler, görüntü edinim cihazlarının etrafındaki gürültü kaynaklarından, hatalı bellek konumlarından, görüntü edinim cihazlarının eksikliklerinden veya atmosferdeki olumsuz koşullardan kaynaklanabilir. Gürültünün bu çeşitliliği dijital görüntülerdeki gürültüyü anlamanın ve modellerini tanımlamanın önemini vurgular. Bu bilgi etkili gürültü azaltma tekniklerinin seçimi ve uygulanması için temel oluşturur.

Görüntülerdeki gürültünün anlaşılması, modellerinin belirlenmesi ve bu gürültülerin etkili bir şekilde azaltılması, görüntü işleme ve analizinde karşılaşılan temel zorluklardan biridir. Gürültüyü azaltmak daha temiz, net ve bilgilendirici görüntülerin elde edilmesine olanak tanır ve bu da çeşitli uygulama alanlarında görüntü kalitesinin iyileştirilmesine katkıda bulunur. Gürültü tiplerinin ve kaynaklarının kapsamlı bir şekilde incelenmesi bu alandaki araştırmacılara gürültü azaltma tekniklerinin seçimi ve uygulamasında önemli bir rehberlik sağlar. Bu durum görüntü işleme alanında sürekli bir araştırma ve geliştirme ihtiyacını doğurur, böylece daha etkili gürültü azaltma stratejileri geliştirilebilir (Gonzalez & Woods, 2008).

Gürültülerin azaltılması veya giderilmesi gürültünün tipine göre değişiklik göstermektedir. Dijital görüntü işleme alanındaki araştırmalar görüntü kalitesini bozan çeşitli gürültü türlerine yönelik etkili çözümler geliştirmeye odaklanmıştır. Bu süreçte, gürültü modelinin doğru tanımlanması ve anlaşılması çeşitli gürültü azaltma tekniklerinin temelini oluşturur. Ortanca filtreleme, Gauss filtreleme, dalga dönüşümü tabanlı teknikler ve derin öğrenme tabanlı yaklaşımlar gibi çeşitli yöntemler, belirli gürültü türleri ve görüntü özelliklerine göre optimize edilmiştir. Örneğin, rastgele gürültüler için etkili olan ortanca filtre, tuz-biber gürültüsü gibi gürültüleri azaltırken görüntünün kenarlarını

koruyabilir. Bununla birlikte periyodik gürültü gibi daha düzenli yapıdaki gürültülerin giderilmesinde gürültünün frekans bileşenlerini görüntünün geri kalanından ayırma ve ardından bu bileşenleri filtreleyerek gürültüyü azaltma yeteneği sunan Fourier dönüşümü gibi frekans alanı teknikleri sıklıkla kullanılır. Bu yaklaşım periyodik gürültüyü etkili bir şekilde azaltırken görüntünün temel yapısını ve detaylarını koruyabilir. Geleneksel yöntemlerle birlikte derin öğrenme tekniklerinin ortaya çıkışı bu iki temel kategoride incelenebilecek bir alan yaratmıştır. Bu tezde her iki konu da ele alınacak gürültüler önce istatistiksel olarak giderilip ardından derin öğrenme modeli kullanılarak temizlenmesi sağlanacaktır.



2. LİTERATÜR TARAMASI

Literatür taraması konusuna girmeden önce şunu belirtmekte fayda görülmektedir. Yapılan taramalar neticesinde periyodik gürültünün giderilmesinde istatistiki yöntemlerin dışına çıkılmamış ve derin öğrenme yöntemleri kullanılmamıştır. Diğer gürültü tiplerine spesifik olarak yapılan çalışmalar ve tip gözetmeksizin genele yönelik derin öğrenme modelleri mevcuttur. Ancak genele yönelik gürültü giderme yöntemleri incelendiğinde periyodik gürültüye cevap vermemektedir. Literatür taraması, öncelikle periyodik gürültünün giderilmesiyle ilgili çalışmaları ele alıp, ardından derin öğrenme kullanılarak yapılan gürültü azaltma ve görüntü iyileştirme araştırmalarıyla devam edecektir.

Aizenberg ve Butakoff (2002), periyodik ve yarı periyodik gürültülerin dijital görüntülerden temizlenmesi için frekans alanında medyan benzeri bir filtre geliştirmişlerdir. Bu filtre, frekans alanında yapılan işlemlerin, özellikle görüntü spektrumunda oluşan belirgin tepe noktalarının tespit edip giderme konusunda, uzamsal alanda yapılan bulanıklaştırmalara göre daha etkili olduğunu göstermiştir. Yöntem, görüntü spektrumunun genliğini yerel bir pencere kullanarak analiz eder ve her spektral katsayının filtrelemeye ihtiyaç duyup duymadığını kontrol eder. Gerektiğinde, bu katsayıyı yerel pencereden alınan medyan değeri ile değiştirir. Tepe noktalarının tespit etmek için mevcut genlik değerinin medyan değere oranı kullanılır ve bu oran bozulmamış spektral katsayılar için frekans bağımsız olarak sabittir.

Gonzalez ve Woods (2008), görüntülerdeki periyodik gürültünün frekans alanı filtrelemesi yoluyla önemli ölçüde azaltılabileceğini belirtmişlerdir. Bu yöntem özellikle elektriksel veya elektromekanik müdahalelerden kaynaklanan gürültüler için etkili bir çözüm sunmaktadır. Yazarlar, frekans alanında gürültünün karakteristik izlerini tespit ederek ve bu izlere odaklanan filtreler uygulayarak gürültünün giderilebileceğini vurgulamışlardır.

Dutta ve ark., (2014), tarafından yapılan çalışmada, görüntülerdeki periyodik gürültüyü tespit etmek ve filtrelemek için Rough-Fuzzy Possibilistic C-Means (RFPCM) kümeleme yöntemi kullanılmıştır. Bu yöntem Fourier genlik alanında periyodik gürültü piklerini tespit etmek için kullanılmış ve geleneksel frekans alanı filtreleme yöntemleriyle karşılaştırmalı bir analiz sunulmuştur. Sonuç olarak elde edilen görüntülerin Peak signal-

to-noise ratio (Tepe sinyal-gürültü oranı) PSNR değerleri, filtreleme kalitesi olarak ele alınmış ve bu değerlere göre bir karşılaştırma analizi yapılmıştır.

Moallem ve ark., (2015), tarafından yapılan çalışmada, dijital görüntülerde periyodik gürültüyü azaltmak için adaptif bir Gauss çentik filtresi önerilmiştir. Yöntem, gürültülü görüntünün spektral bandına bir segmentasyon algoritması uygulayarak ve adaptif bir eşik değeri kullanarak gürültüye karşılık gelen frekans bölgelerini belirler. Ardından, her bir periyodik gürültü bileşeninin bant genişliğini ayrı ayrı belirlemek için bir bölge büyütme algoritması kullanılmıştır.

Erol ve ark., (2016), çalışmasında, video görüntülerindeki periyodik gürültülerin yok edilmesi için frekans uzayında çalışan bir filtreleme yöntemi önerilmiştir. Bu yöntem, periyodik ve yarı periyodik gürültülerin frekans uzayındaki tepe noktalarını medyan süzgeç ile otomatik olarak bulur ve gürültü yok etme işlemi, algılanan gürültü içeriğine göre uyarlanan Butterworth çoklu-çentik süzgeçle gerçekleştirilmiştir.

Varghese (2016), çalışmada, periyodik gürültüyle bozulmuş dijital görüntülerin restorasyonu için adaptif eşik tabanlı bir frekans alanı filtresi önerilmiş. Algoritma, görüntüyü uzaysal alandan frekans alanına dönüştürmek amacıyla ileriye doğru orijin kaydırma ve Fourier dönüşümünü kullanmış. Önerilen algoritma, frekans alanındaki gürültülü tepe noktalarını belirlemek için adaptif bir eşik fonksiyonu tanımlamış. Belirlenen gürültülü frekanslar, frekans alanındaki görüntülerin etkili bir şekilde restorasyonu için minimum filtre ile yayılmış. Restore edilen frekans alanı görüntüsü, uzaysal alanda nihai restore edilmiş görüntüyü yeniden oluşturmak amacıyla Fourier dönüşümünün ve kaydırma işlemlerinin tersine uygulanmış.

Ketenci ve Gangal (2017), dijital görüntülerde periyodik gürültünün otomatik olarak azaltılması için adaptif Gauss yıldız filtresi kullanan bir yöntem geliştirmişlerdir. Bu yöntem, gürültü koordinatlarını tahmin etmek ve her gürültü yayılım alanını belirlemek için frekans alanında bölge büyütme algoritması kullanılmıştır.

Chen ve ark., (2017), uzaktan algılama görüntülerindeki şerit periyodik gürültünün kaldırılması için toplam varyasyon düzenlemesi ve grup seyrekliği kısıtlamasına dayanan yeni bir yöntem önermiştir. Bu yöntem şerit gürültüsünün ve görüntü özelliklerinin içsel özelliklerini dikkate alarak, görüntü bozulmasını önlemeyi amaçladığı ifade edilmiştir.

Varghese ve ark., (2020), dijital görüntülerdeki periyodik gürültünün giderilmesi için Fourier dönüşümü alanında çalışan yeni bir adaptif Gauss çentik filtresi geliştirmişlerdir. Önerilen yöntem, periyodik, yarı-periyodik ve Moiré desenli gürültülerle kirlenmiş görüntüleri etkili bir şekilde restore etmek için tasarlanmıştır. Bu çalışma, gürültülü piksel alanlarını belirlemek ve gürültülü bölgeleri adaptif boyutlarda Gauss çentik filtresi kullanarak dağıtmak için frekans alanındaki tepe noktaları tespiti gerçekleştirilmiştir.

Alibabaie ve Latif (2021), dijital görüntülerde periyodik gürültünün adaptif bir şekilde azaltılmasını sağlayan bir yöntem geliştirmişlerdir. Bu yöntem, bulanık dönüşüm temelli bir yaklaşım kullanarak periyodik gürültü tepe noktalarını tanımlar ve azaltır. Periyodik gürültünün tepe noktalarını tespit etmek için spektrumun doğrudan ve ters bulanık dönüşümünü kullanılmıştır. İkinci olarak, spektral yumuşatma ve orijinal görüntüyü periyodik gürültü bileşenlerinden ayırmak için bulanık dönüşüm tabanlı bir çentik filtresi önerilmiştir.

Yapıcı ve Akcayol (2022), görüntülerdeki gürültü azaltma yöntemleri üzerine kapsamlı bir inceleme yapmışlardır. Çalışmalarında, derin öğrenme yöntemlerinin geleneksel yöntemlere kıyasla daha başarılı sonuçlar elde ettiğini belirtmişlerdir. Özellikle, derin öğrenme tabanlı yöntemlerin değişik gürültü seviyelerine ve türlerine karşı daha esnek olduğunu ve yüksek seviyede gürültüyle karşılaştıklarında dahi başarılı sonuçlar verebildiğini vurgulamışlardır.

Novikov ve ark., (2022), periyodik gürültü filtrelemesi için kenar dedektörü kullanımı üzerine bir yöntem önermişlerdir. Bu yöntem, iki boyutlu Fourier dönüşümünün katsayılarını, periyodik gürültüyü içermeyecek şekilde dönüştürerek çalışmaktadır. Amplitüd spektrumunun yerel maksimumlarını ve çevrelerini kenar dedektörü kullanarak tespit edip bu bölgeleri maskelemek suretiyle periyodik gürültülerin frekanslarını kestiği ifade edilmiştir.

Chen ve Li (2023), kızılötesi doğrusal dizi detektörlerinde elektro-mekanik müdahalelerden kaynaklanan periyodik çizgi gürültüsüyle mücadele için Fourier Destekli Korelatif Gürültü Giderme (FACD) yöntemini tanıtmıştır. Bu yöntem, gürültünün frekans alanı özelliklerini kullanarak ve görüntüyü segmentlere ayırarak, her segmentteki gürültü profiline dayalı mekânsal alan gürültü giderimi gerçekleştirilmiştir.

Li ve ark., (2024), tarafından yürütülen çalışmada, yüksek çözünürlüklü kızılötesi çizgi tarama görüntülerinde periyodik gürültü azaltma yöntemleri için nöral ağ tabanlı bir araştırma yapılmıştır. Bu çalışmada, iki boyutlu görüntülerin bir boyutlu sinyallere dönüştürülmesi sağlanarak tüm görüntünün işlenmesi gereksinimi ortadan kaldırılmıştır. Düşük frekanslı periyodik gürültüye odaklanarak bir boyutlu sinyalden gürültüyü çıkarmak için bir nöral ağ kullanılması ve frekans alanındaki gürültü tahminine yönelik ayrık Fourier dönüşümlerinin kullanılması önerilmiştir.

Abu-Ein (2013), çalışmasında, dijital görüntülerden periyodik gürültünün iki boyutlu Hızlı Fourier Dönüşümleri (2DFFT) kullanılarak kaldırılması için yeni bir yöntem önermiştir. Yazar, renkli görüntülerin griye dönüştürülmesini, ardından 2DFFT'nin uygulanmasını ve elde edilen büyüklük matrisinin analiz edilerek periyodik filtre maskesinin hazırlanmasını içeren bir süreç geliştirmiştir. Bu filtre, daha sonra gürültüsüz gri tonlamalı görüntü elde etmek için açılı matrisi ile kullanılmıştır.

Fan ve ark. (2019), görüntülerden katkılı beyaz Gauss gürültüsünü (AWGN) azaltmaya yönelik bir çalışma yapmışlardır. AWGN, görüntülerin her bir piksel değerini bağımsız ve aynı dağılıma sahip rastgele değerlerle değiştiren ve yaygın olarak karşılaşılan bir gürültü türüdür. Gürültü azaltma yöntemlerinin geliştirilmesi ve değerlendirilmesinde AWGN modellemesi sıkça kullanılır. Ancak, gerçek dünya gürültülerinin bu modelden daha karmaşık olabileceği ve bu nedenle farklı gürültü türlerine karşı yöntemlerin test edilmesi gerektiği vurgulanmıştır.

Aghajarian ve ark., (2020), gri tonlamalı ve renkli görüntüler için geniş bir gürültü seviyesi aralığında Gauss gürültüsünü kaldırabilen bir derin öğrenme algoritması geliştirmişlerdir. Bu yöntem, düşük ve yüksek gürültü seviyeleri için sadece iki model kullanarak, her gürültü seviyesi için ayrı model eğitme gereksinimini ortadan kaldırır. Eğitim süreci, sınıflandırıcı eğitimi, gürültü giderici ağ ile gürültünün azaltılması ve kod çözücü ile piksellere dönüştürme adımlarından oluşmaktadır. Berkeley segmentasyon veri seti (BSDS68) ve 12 yaygın kullanılan görüntü üzerinde testler yapıldığı ifade edilmiştir.

Alolaiwy ve ark., (2021), tarafından geliştirilen çalışmada, dijital görüntülerde gürültü azaltımı için güçlendirme öğrenmesi (Q-learning) kullanılarak adaptif filtre tasarımı önerilmektedir. Çalışmada, farklı gürültü türlerine (tuz ve biber gürültüsü, Poisson ve

beyaz gürültü gibi) uyarlanabilen filtrelerin tasarlanabilmesi için evrişimli sinir ağlarına (CNN) dayanan bir yöntem kullanılmıştır.

Tian ve ark., (2022), çok aşamalı görüntü gürültüsü giderme çalışmalarında dalgacık dönüşümünü kullanarak yeni bir derin evrişimli sinir ağı (CNN) modeli önermiştir. Bu model, dinamik evrişim bloğu (DCB), iki ardışık dalgacık dönüşümü ve geliştirme blokları (WEB) ve bir artık blok (RB) olmak üzere üç aşamadan oluşmaktadır. DCB, çeşitli evrişimlerin parametrelerini dinamik olarak ayarlayarak gürültü giderme performansı ile hesaplama maliyetleri arasında bir denge kurmayı amaçlamıştır. WEB ise sinyal işleme tekniklerini (yani dalgacık dönüşümü) ve ayırt edici öğrenmeyi birleştirerek gürültüyü bastırmak ve görüntü gürültüsü gidermede daha fazla detay bilgisi elde etmeyi hedeflemiştir. RB, gereksiz özellikleri daha da azaltmak için kullanılır ve geliştirilmiş artık yoğun mimariler aracılığıyla temiz görüntüleri yeniden yapılandırmayı amaçlamıştır.

Aghajarian ve McInroy (2022), gri tonlamalı görüntülerdeki rasgele değerli darbe gürültüsünün (RVIN) tespiti ve giderilmesi için yerel istatistiklere dayalı etkili bir üç adımlı yöntem önermişlerdir. Çalışmalarında, mevcut çoğu gürültü azaltma algoritmasının aksine, yöntemlerinin ilk adımda gürültü yoğunluğunu tahmin ettiğini, ikinci adımda tahmini gürültü yoğunluğuna dayalı bir gürültü dedektörü ile bozulmuş pikselleri tespit ettiğini ve son olarak da değiştirilmiş ağırlıklı ortalama filtresini kullanarak tespit edilen gürültülü pikselleri geri yüklediklerini belirtmişlerdir.

Latifi ve Raie (2022), belirli bir gürültü seviyesine sahip bozulmuş fotoğraflardan gürültüyü gidermek için genişletilmiş ve düzenli evrişimlerin karışımını kullanan yeni bir görüntü gürültüsü azaltma modeli sunmuşlardır. Önerilen model BSD68 veri setinde değerlendirilmiş ve tüm gürültü seviyelerinde DnCNN ve FFDNet gibi modellere kıyasla daha iyi performans sergilediği bulunmuştur. Ayrıca, makalede gürültü azaltma (denoising) işlemlerinin, bilinmeyen gürültü seviyeleriyle, JPEG görüntü blok giderme (deblocking) ve Süper Çözünürlük için Tekil Görüntü Yeniden Yapılandırma (SISR-Single Image Super-Resolution) gibi diğer görüntü restorasyon görevlerinde de uygulanabileceği belirtilmiştir.

Ko ve Lee'nin (2023), çalışmasında önerilen Self2Self+ yöntemi hem sentetik hem de gerçek dünya gürültüsü içeren görüntüler için etkili bir gürültü azaltma performansı

sergilediği belirtilmiştir. Sentetik gürültü olarak, belirli gürültü seviyelerine sahip Additive White Gaussian Noise (AWGN) kullanılmıştır. Gerçek dünya gürültüsü açısından ise, çalışma çeşitli gerçek dünya koşullarından elde edilen gürültülü görüntü veri setleri üzerinde test edilmiştir. Bu nedenle, Self2Self+ yöntemi AWGN gibi yaygın sentetik gürültü tiplerinin yanı sıra, gerçek dünya koşullarında karşılaşılan daha karmaşık ve belirsiz gürültü dağılımları için de uygun olabileceği ifade edilmiştir. Ancak, spesifik gürültü tipleri (örneğin tuz-biber gürültüsü, periyodik gürültü vb.) üzerindeki performansı doğrudan belirtilmemiştir, bu yüzden bu tür özelleşmiş gürültü tipleri için metodun etkinliği konusunda ek testler yapılması gerekebilir.

Chen ve ark., (2023), görüntü gürültüsü azaltma modellerinin genelleştirme kabiliyetini artırmak için maskeleye eğitimi yöntemini sunmuşlardır. Geliştirdikleri yöntemde, giriş görüntüsünün rastgele pikselleri maskeleyerek ve eğitim sürecinde bu eksik bilgileri yeniden yapılandırarak, ağların görüntü içeriğini öğrenmesi hedeflenmiştir. Özellikle Transformer tabanlı modellerde, kendiliğinden dikkat katmanlarında özellikleri maskeleyerek, eğitim-test tutarsızlığını azaltmaya yönelik bu yaklaşımın, çeşitli gürültü türlerinde önemli performans iyileştirmeleri sağladığı ve diğer derin öğrenme modellerine göre daha iyi bir genelleştirme yeteneği sergilediği ifade edilmiştir.

Zeyu Li (2023), tarafından yürütülen çalışma, derin öğrenme tabanlı DnCNN modelini kullanarak görüntü gürültüsü azaltmayı ele almaktadır. Bu yöntem, özellikle yüksek gürültülü ortamlarda, gürültülü görüntülerden gürültüyü etkin bir şekilde ayırabilme kapasitesine sahiptir. Çalışma, geleneksel yöntemlere kıyasla daha karmaşık koşullar altında bile görüntüler üzerinde daha iyi sonuçlar elde edebilen yeni yöntemlerin etkinliğini vurgulamaktadır.

Fajardo-Delgado ve ark., (2024), renkli dijital görüntülerdeki dürtü gürültüsünü gidermek için genetik programlama tabanlı yeni bir filtre önermişlerdir. Bu yöntem, gürültülü pikselleri belirleyip düzeltirken renk kanalları arasındaki ilişkileri kullanır. Deneyler, önerilen filtre modelinin çeşitli gürültü türlerine karşı etkili olduğunu göstermiştir. Çalışma, genetik programlamanın adaptasyon kabiliyetini vurgulamakta ve gelecek çalışmalar için alternatif makine öğrenimi tekniklerinin entegrasyonuna işaret etmektedir.

Deng ve Hu (2024), tarafından geliştirilen ilerlemeli çok ölçekli evrişimli sinir ağı (CNN) tabanlı yöntem, Progressive Multi-scale Deraining Network (PMSDNet), görüntülerdeki

gürültüyü azaltmayı amaçlamaktadır. Çalışma, kör olmayan sentetik gürültü, kör sentetik gürültü ve gerçek dünya gürültüsü olmak üzere çeşitli gürültü türlerinin başarıyla azaltılabildiğini göstermiştir. Ancak, yöntemin etkili uygulanabilmesi için yüksek performanslı GPU donanımına ihtiyaç duyulması gibi potansiyel bir eksiklik bulunmaktadır.



3. GENEL BİLGİLER

Bu tezin amacı, görüntü işleme alanında sıkça karşılaşılan periyodik gürültünün etkili bir şekilde giderilmesi için istatistikî ve derin öğrenme yöntemlerini kullanarak bir çözüm geliştirmektir. Geleneksel yöntemlerin tek başına yetersiz kaldığı durumlarda, derin öğrenme algoritmalarının avantajlarından faydalanarak periyodik gürültünün etkin bir şekilde azaltılması hedeflenmektedir.

Bu tez kapsamında aşağıdaki ana hedefler belirlenmiştir:

- **Gürültü Problemi:** Gürültünün tanımı, tipleri ve gürültülerin giderilmesi üzerine tekniklerin incelenmesi yapılacaktır.
- **Periyodik Gürültünün Tanımlanması:** İlk olarak, farklı kaynaklardan gelen ve görüntüler üzerinde periyodik gürültü oluşturan faktörlerin detaylı bir şekilde incelenmesi ve analiz edilmesi planlanmaktadır. Bu adım, gürültünün özelliklerinin anlaşılmasına ve etkili bir giderme yöntemi geliştirmeye temel oluşturacaktır.
- **Derin Öğrenme Yöntemlerinin İncelenmesi:** Derin öğrenme, karmaşık veri yapılarını analiz etme ve örüntüleri tanıma konusunda önemli avantajlar sunmaktadır. Bu adımda, derin öğrenme yöntemlerinin temel prensipleri ve uygulama alanları detaylı olarak incelenecek, özellikle gürültü azaltma ve iyileştirme modelleri incelenecektir.
- **Çalışma Tasarımı:** Geleneksel görüntü işleme tekniklerinin derin öğrenme yöntemleriyle birleştirildiği ikili bir çalışma tasarlanacaktır. Bu tasarım, periyodik gürültünün etkili bir şekilde azaltılmasını sağlayacak ve hem gürültüyü giderme performansını artıracak hem de işlem verimliliğini iyileştirecektir.
- **Performans Değerlendirmesi ve Karşılaştırmalı Analiz:** Geliştirilen yöntemin etkinliği, geleneksel yöntemlerle karşılaştırmalı olarak değerlendirilecektir. Bu değerlendirme, farklı tipteki periyodik gürültüler ve çeşitli görüntü veri setleri üzerinde gerçekleştirilecek ve ikili bir yöntemin avantajları ortaya konacaktır.

Bu tez çalışması, periyodik gürültüyü etkili bir şekilde azaltmak için derin öğrenme yöntemlerinin kullanımının avantajlarını göstererek, görüntü işleme alanında pratik bir katkı sağlamayı amaçlamaktadır.

3.1. Dijital Görüntülerdeki Gürültüler ve Gürültü Giderme Teknikleri

3.1.1. Gürültü Nedir?

Gürültü, genellikle istenmeyen rastgele değişiklikler olarak tanımlanır ve bir görüntünün kalitesini düşürerek görsel algıyı zorlaştırarak ve analizini engeller. Görüntüde gürültü, çeşitli kaynaklardan oluşabilir ve farklı biçimlerde ortaya çıkabilir. Bu, görüntü yakalama, aktarma veya işleme aşamalarında meydana gelebilecek, piksel değerlerindeki rastgele değişikliklerden kaynaklanan istenmeyen bir etkidir. Gürültü, görüntü sensörünün termal gürültüsü, analog-dijital dönüştürme işlemi, ışık fotonlarının rastgele gelmesi, sensördeki hatalı pikseller, sinyal iletim hataları, elektriksel parazitler, görüntü sıkıştırma algoritmaları ve kamera veya nesnenin hareketi gibi birçok faktörden kaynaklanabilir. Bu faktörlerin her biri, görüntüde farklı gürültü türlerine yol açar ve bu türler görüntü kalitesini farklı şekillerde etkileyebilir.

Görüntülerde meydana gelebilecek gürültü, aşağıda 3.1’de belirtilen matematiksel modelle ifade edilebilir.

$$g(x, y) = f(x, y) + n(x, y) \quad (3.1)$$

Burada, n gürültü ögesini temsil ederken; g , gürültü içeren görüntüyü simgelemektedir. Temiz ya da diğer bir deyişle net gerçek görüntüyü f ile gösterilmektedir.

Bu kısım, görüntüleme sürecinde ortaya çıkabilecek çeşitli gürültü tiplerini ve bu gürültülerin karakteristik özelliklerini detaylandırmaktadır. Ayrıca gürültü gidermede kullanılan istatistiksel yöntemler ve derin öğrenme ile görüntülerdeki gürültüyü temizleme veya minimize etmeye yönelik metodolojiler incelenecektir.

3.1.2. Gürültü Tipleri

Görüntüleme süreçlerinde karşılaşılan gürültüler, birbirinden farklı karakteristiklere sahip çok çeşitli biçimlerde ortaya çıkabilir. Her gürültü türü, görüntüler üzerindeki etkisi açısından kendine özgü özellikler sergiler. Sıklıkla karşılaşılan bazı gürültü modelleri ile bu modellere ait olasılık yoğunluk fonksiyonları, görüntülerin analizi ve işlenmesi sırasında önem taşır. Dolayısıyla gürültü modellerini anlamak ve bu modellere dayanarak gürültü temizleme teknikleri geliştirmek, görüntü işleme ve analizi alanında kritik bir

öneme sahiptir. Aşağıda başlıca gürültü tipleri ve olasılık yoğunluk fonksiyonları verilmiştir.

3.1.3. Gauss Gürültüsü

Gauss gürültüsü, normal dağılımla aynı olasılık yoğunluk fonksiyonuna (PDF) sahip istatistiksel bir gürültüdür. Gauss dağılımı olarak bilinen eklemeli gürültü olarak da adlandırılır. Başka bir deyişle, piksellerin her biri belirli bir dağılıma göre değiştirildiği için gürültünün olası değerleri Gauss dağılımlıdır. Beyaz Gauss gürültüsü, zaman içinde herhangi iki noktadaki değerlerin eşit olarak dağıldığı ve istatistiksel olarak bağımsız (ilişkisiz) olduğu özel bir örnektir (Abdullah ve ark., 2021).

Gürültünün olasılık yoğunluk fonksiyonu (PDF), Gauss rastgele değişkeni z 'nin gri seviyesini temsil ettiği, μ ortalama gri değeri ve σ ise standart sapmayı belirttiği formülle hesaplanır. Bu formül 3.2'de yer almaktadır.

$$P(z) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-(z-\mu)^2/2\sigma^2} \quad (3.2)$$

Gauss gürültüsüne ilişkin gürültü ve gürültü eklenmiş görüntü Şekil 3.1' de yer almaktadır.



Şekil 3.1. Gürültüsüz görüntü, Gauss gürültüsü ve gürültü uygulanmış görüntü

3.1.4. Tuz & Biber Gürültüsü

Tuz & Biber (salt&paper) gürültü bazen dürtüsel gürültüsü veya spike gürültüsü olarak adlandırılır (Vyas ve ark., 2018). Tuz & Biber gürültüsü, beyaz zemin üzerinde siyah pikseller ile siyah zemin üzerinde beyaz pikseller şeklinde kendini gösterir. Bu gürültü formunda, siyah noktalar 0, beyaz noktalar ise 255 değerini almaktadır. Bu gürültü

türünün karakteristik bir özelliği, gürültüye maruz kalan pikselin yoğunluğunun veya değerinin, çevresindeki piksellerin renkleriyle herhangi bir ilişki taşımasıdır. Genellikle görüntünün sınırlı sayıda pikselini etkileyen bu gürültü, görsel olarak siyah ve beyaz noktalara benzetilebilir ve sıklıkla veri iletim hataları sonucunda meydana gelir. Tuz & Biber gürültüsünün kaynakları arasında hatalı hafıza alanları, kamera yüzeyindeki toz partikülleri veya arızalanmış donanım bileşenleri sayılabilir (Küpeli & Bulut, 2020).

Tuz & Biber gürültüsü uygulanmış görüntü Şekil 3.2’de görülmektedir.



Şekil 3.2. Tuz & Biber gürültüsü eklenmiş görüntü ve orijinal görüntü

3.1.5. Benek Gürültüsü

Benek Gürültüsü, çarpan etkisi altında meydana gelen ve görüntüler üzerinde tanecikli bir yapı oluşturan bir gürültü çeşididir. Bu tür gürültü, özellikle aktif görüntüleme sistemleri olan aktif radar ve sentetik açıklıklı radar (SAR) cihazları tarafından elde edilen görüntülerde kalite kaybına yol açar. Geleneksel radar sistemlerinde, tek bir görüntü işleme elemanı boyutundan küçük bir nesneden alınan dönüş sinyalindeki rastgele dalgalanmalar sonucu benek gürültüsü oluşmaktadır. Bu durum görüntülerin yerel gri seviye ortalamasının artmasına neden olur. SAR görüntülerinde, benek gürültüsü görüntü yorumlamasını güçleştirir. Temel olarak, çoklu dağılmış hedeflerden gelen ve tutarlı bir şekilde işlenen geri saçılan sinyallerden kaynaklanır (Saadia & Rashdi, 2018).

Benek gürültüsünün matematiksel ifadesi ($P = I + n * I$) şeklinde olup, burada (P) benek gürültüsü içeren görüntüyü, (I) orijinal giriş görüntüsünü ve (n) ortalama değeri sıfır ve belirli bir varyansa sahip olan tekdüze bir gürültüyü temsil eder. Bu ifade, benek gürültüsünün görüntü üzerindeki çarpımsal etkisini ve görüntü pikselleri üzerindeki

doğrudan etkisini açıkça ortaya koyar (Maity ve ark., 2015). Şekil 3.3'te Benek gürültüsü ve gürültü eklenmiş kameraman görüntüsü yer almaktadır.





Şekil 3.3. Benek gürültüsü ve gürültü eklenmiş görüntü

3.1.6. Foton veya Poisson Gürültüsü

Foton veya Poisson gürültüsü, özellikle düşük ışık koşullarında veya yüksek hassasiyetli sensörler kullanıldığında dijital görüntülerde görülen ışık yoğunluğuna bağlı olarak değişen istatistiksel bir gürültü türüdür. Bu gürültü tipi foton sayımı istatistiklerine dayanır ve piksel başına düşen foton sayısı ideal olarak Poisson dağılımını takip eder (Le ve ark., 2017). Matematiksel olarak, bir pikselin içindeki foton sayısının Poisson dağılımına uyması beklenir. Eğer u ideal, gürültüsüz görüntüyü ve f ise gözlemlenen, gürültülü görüntüyü temsil ederse, Poisson gürültü modeline göre f her bir pikselde aşağıdaki olasılık yoğunluk fonksiyonu ile modellenir:

$$P(f(x)|u) = \frac{e^{-u(x)} u(x)^{f(x)}}{f(x)!} \quad (3.3)$$

Burada $f(x)$ olayının $u(x)$ parametresine bağlı olarak gerçekleşme olasılığını hesaplar. Formülde, $f(x)$ gözlenen değer veya olay sayısını, $u(x)$ ise beklenen değer veya olay sayısını (ortalama) temsil eder. Foton gürültüsüne ait gürültü ve görüntü eklenmiş görüntü Şekil 3.4'te yer almaktadır.



Şekil 3.4. Possion gürültüsü ve gürültü eklenmiş görüntü

Görüntüler üzerindeki Foton gürültüsünün azaltılması, düzenleyici terimlerin ve veri uyumluluğunun dengelenmesi yoluyla yapılır, bu sayede düşük yoğunluklu bölgelerdeki detaylar korunurken gürültü azaltılır. Gürültü yoğunluğa bağlı olarak gürültüyü azaltacak şekilde otomatik olarak uyarlanan algoritmalarla işlenir, bu da düşük ve yüksek yoğunluklu alanlardaki özelliklerin korunmasını sağlar.


3.1.7. Periyodik Gürültü

Periyodik gürültü, elektromanyetik ya da elektriksel parazitlerin etkisiyle görüntülerin oluşturulma veya aktarım aşamasında tekrar eden desenlerin oluşumuna yol açan ve görüntü kalitesini olumsuz yönde etkileyen yanıltıcı sinyaller olarak tanımlanmaktadır (Altunok & Turan, 2022). Bu tür sinyaller yanlış ayarlanmış sensörler ya da eksik veriler gibi çeşitli faktörlerden kaynaklanabilir. Örnek olarak veri aktarımı sırasında meydana gelen kesintiler, iletimi gerçekleştirilemeyen bölümlerde şeritlerin oluşmasına sebep olabilir ve bu şeritlerin periyodik olarak tekrarlanması periyodik gürültü fenomenini meydana getirir. Periyodik gürültü kavramı, ilk defa 1963 yılında Guttman ve Julesz tarafından bir sorun olarak dile getirilmiştir (Guttman & Julesz, 1963).

Periyodik gürültü, özellikle tıbbi görüntüleme (Wang & Liu, 2010) (Carvalho ve ark., 2018) (Xie ve ark., 2012), uzaktan algılama (Chen ve ark., 2017), mikroskopi (Wei ve ark., 2012) (Ionita & Coanda, 2017) ve video görüntüleme (Erol ve ark., 2016) gibi alanlar başta olmak üzere trafik izleme ve diğer gerçek zamanlı uygulamalarda sıkça karşılaşılan gürültü türlerinden biridir (Kang ve ark., 2011). Bu gürültü türü, görüntü kalitesini bozarak analiz ve yorumlamayı zorlaştırır ve dolayısıyla bu alandaki çalışmaların doğruluğu ve güvenilirliği üzerinde olumsuz etkiler yaratabilir.

Periyodik gürültü diğer gürültülerden farkı tekrar eden desenlerin oluşumuna yol açması ve bu desenlerin görüntü kalitesini düşürmesidir. Literatürde, bu gürültü türünün, frekans uzayında tepe noktaları olarak görünen benzer desenleri üst üste bindirerek görüntü kalitesini azalttığı belirtilmektedir (Varghase, 2016).

Şekil 3.5.'te, periyodik gürültüye sahip görüntü, bu gürültünün frekans uzayındaki görünümü ve tepe noktaları görülmektedir.




Şekil 3.5. Periyodik gürültülü görüntü ve gürültünün frekans uzayındaki görünümü,

Periyodik gürültüler, çeşitli formlarda karşımıza çıkmaktadır. Bu formlar aşağıda sıralanmıştır:

- Düşük frekanslı periyodik gürültü,
- Yüksek frekanslı periyodik gürültü,
- Saf periyodik gürültü,
 - Çapraz Saf Periyodik Gürültü
 - Dikey Saf Periyodik Gürültü
 - Yatay Saf Periyodik Gürültü
- Yarı periyodik gürültü,
- Çok frekanslı periyodik gürültü,
- Şerit gürültü,



3.1.7.1. Düşük Frekanslı Periyodik Gürültü

Düşük frekanslı periyodik gürültü, tek boyutlu sinyaller için genellikle 10 Hz ila 1000 Hz aralığında düşük frekanslı gürültü kabul edilebilir (Leventhall, 2009) (Rieken, 2011) (Alibaba & Latif, 2021). Düşük frekanslı dalga formunun grafiği Şekil 3.6'da gösterilmiştir.



Şekil 3.6. Düşük frekans aralığına ait grafik

Görüntülerde meydana gelen periyodik gürültüler, çözünürlükle ilişkilidir. Periyodik gürültünün frekansı, gürültünün görüntüdeki tekrar sayısını ifade eder. Dolayısıyla düşük frekanslı periyodik gürültüler, geniş aralıklara yayılan ve daha çok pikseli kapsayan frekansların neden olduğu gürültülerdir. Farklı çözünürlüklerdeki görüntülerde, aynı frekans değerlerine sahip gürültüler, düşük veya yüksek frekanslı periyodik gürültüler olarak tezahür edebilir. Şekil 3.7’de, sentetik olarak oluşturulan düşük frekanslı periyodik gürültünün frekans uzayında ani genlik değişikliklerine neden olduğunu göstermektedir.




Şekil 3.7.Düşük frekansa sahip gürültü, 2 boyutlu frekans uzayında gürültünün tepe noktalarına ait görünümü ve 3 boyutlu frekans uzayındaki tepe noktalarına ait görüntü

Aşağıdaki yer alan 3.4'te ki denklemi kullanılarak düşük frekanslı periyodik gürültü sentetik olarak oluşturulabilmektedir.

$$n(x, y) = 2 \times \sin \times \left(\frac{x}{28} + \frac{y}{16} \right) \quad (3.4)$$


Bu formülde, x ve y değişkenleri sırasıyla görüntünün genişlik ve yükseklik boyutlarını temsil eder. x ve y değerlerinin sırasıyla 28 ve 16 ile bölünmesi sonucu elde edilen toplam, sinüs fonksiyonuna argüman olarak verilir. Sinüs fonksiyonunun çıktısı, 2 ile çarpılarak son yoğunluk değeri elde edilir. Bu fonksiyon, görüntüdeki piksel yoğunluğunun x ve y konumlarına bağlı olarak periyodik bir dalgalanma göstermesini sağlar ve bu dalgalanmanın genliği 2'dir. Şekil 3.8'de, görüntüye düşük frekanslı periyodik gürültü eklendikten sonra oluşturulan gürültülü görüntüyü ve gürültünün frekans uzayında nasıl görüldüğünü göstermektedir. Gri tonlamalı dağılım nedeniyle tepe noktaları netlik sağlamak amacıyla kırmızı daire ile işaretlenmiştir.



Şekil 3.8.Düşük frekanslı periyodik gürültü eklenmiş kameraman görüntüsü ve gürültünün frekans uzayındaki görünümü.

3.1.7.2. Yüksek Frekanslı Periyodik Gürültü

Yüksek frekanslı periyodik gürültüler, düşük frekanslı olanların aksine daha dar aralıklara sahip frekansların görüntü üzerinde oluşturduğu gürültülerdir. 1000 Hz'in üzerindeki frekanslar yüksek frekans olarak kabul edilir (Leventhall, 2009) (Rieken, 2011). Yüksek frekanslı dalga formunun grafiği Şekil 3.9'da gösterilmiştir.




Şekil 3.9.Yüksek frekans aralık grafiği

Aşağıda 3.5’te verilen denklem ile yüksek frekanslı periyodik gürültü elde edilebilir.


$$n(x,y) = 2 \times \sin \times \left(\frac{x}{3.5} + \frac{y}{2}\right) \quad (3.5)$$

Bu formülde, x ve y değişkenleri sırasıyla görüntünün genişlik ve yükseklik boyutlarını temsil eder. x ve y değerlerinin 3.5 ve 2 ile bölünmesi sonucu elde edilen toplam, sinüs fonksiyonuna argüman olarak verilir. Sinüs fonksiyonunun çıktısı, 2 ile çarpılarak son yoğunluk değeri elde edilir. Bu fonksiyon, görüntüdeki piksel yoğunluğunun x ve y konumlarına bağlı olarak periyodik bir dalgalanma göstermesini sağlar ve bu dalgalanmanın genliği 2’dir. Şekil 3.10’da sentetik olarak oluşturulan yüksek frekanslı periyodik gürültü, frekans uzayında tepe noktalarının görünümü ve 3 boyutlu frekans uzayındaki tepe noktalarına ait görüntü yer almaktadır.



Şekil 3.10.Yüksek frekansa sahip periyodik gürültü, 2 boyutlu frekans uzayında gürültünün tepe noktalarına ait görünümü ve 3 boyutlu frekans uzayındaki tepe noktalarına ait görüntü

Frekans alanındaki dalga boylarının kısalması neticesinde, gürültünün frekans uzayındaki tepe noktaları, merkeze göre daha uzak bir konumda görülmektedir (Alibabaie & Latif, 2021).



Şekil 3. 11. Yüksek frekanslı periyodik gürültü eklenmiş kameraman görüntüsü ve gürültünün frekans uzayındaki görünümü.

3.1.7.3. Saf Periyodik Gürültü

Periyodik gürültü, saf haliyle yalnızca periyot boyunca tek bir noktayı etkiler. Bu durumda, periyot süresince herhangi bir dağılma ya da dalgalanma meydana gelmez. Bu sebeple, Şekil 3.11’de görülebileceği gibi, görüntü üzerinde çizgiler halinde ne artan ne de azalan, sabit bir ölçekte ilerleyen bir yapı gözlemlenir. Frekans uzayında görüntü incelendiğinde birden fazla frekansın etkilendiği belirgindir (Alibabaie & Latif, 2021). Tepe noktaları incelendiğinde, merkez dışında toplamda sekiz tepe noktasının bulunduğu görülür. Saf gürültü oluşturmak amacıyla kullandığımız denklemde belirlediğimiz sekiz değer, bu tepe noktalarının sayısını ifade eder. Merkezden uzaklaştıkça frekansın arttığı ve ardışık bir yapıda peş peşe yükseldiği görülmektedir. Aşağıdaki denklemler (3.6,3.7, 3.8) ile saf periyodik gürültü oluşturmakta kullanılabilir.

$$n(x,y) = \begin{cases} y = 255, & \text{mod}(y + x, 8) = 0 \\ y = 0, & \text{mod}(y + x, 8) \neq 0 \end{cases} \quad (3.6)$$

Burada x ve y görüntünün genişlik ve yüksekliğini temsil eder. Bu formül, görüntüde her 8 pikselde bir beyaz (255) ve diğer tüm piksellerin siyah (0) olduğu çapraz periyodik bir desen oluşturur.


$$n(x,y) = \begin{cases} x = 255, & \text{mod}(x, 8) = 0 \\ x = 0, & \text{mod}(x, 8) \neq 0 \end{cases} \quad (3.7)$$

Burada görüntüde her 8 yatay pikselde bir beyaz piksel (255) ve diğer tüm piksellerin siyah (0) olduğu periyodik bir dikey çizgi deseni oluşturur.

$$n(x,y) = \begin{cases} y = 255, & \text{mod}(y, 8) = 0 \\ y = 0, & \text{mod}(y, 8) \neq 0 \end{cases} \quad (3.8)$$

Bu, görüntüde her 8 dikey pikselde bir beyaz piksel (255) ve diğer tüm piksellerin siyah (0) olduğu periyodik bir yatay çizgi deseni oluşturur.

Yukarıdaki formüller kullanılarak elde edilen sentetik saf periyodik gürültüler Şekil 3.11’ de kameraman görüntüsüne eklenip gösterilmiştir.



Şekil 3.11.Saf periyodik gürültü uygulanmış görüntüler ve frekans uzayında tepe noktalarının işaretli şekli. Çapraz, yatay ve dikey şekilde

3.1.7.4. Yarı Periyodik Gürültü

Diğer periyodik gürültü türlerinin frekans uzayında neden olduğu tepe noktaları oldukça dar ve belirgin büyüklüklere sahiptir. Bu da onların diğer spektral katsayılarından net bir şekilde ayrılmasını mümkün kılar. Periyodik gürültü durumunda, bu tepeler çıplak gözle bile fark edilebilirken, yarı-periyodik gürültüye ait tepe noktaları genellikle gizli kalır ve çoğu zaman belirli bir sayısal analiz yapılmaksızın tespit edilmeleri güçtür (Aizenberg & Butakoff, 2002) (Ketenci & Gangal, 2012). Sentetik olarak oluşturulmuş Yarı-periyodik gürültü, gürültü eklenmiş görüntü ve gürültünün gürültülü görüntü spektrumuna olan etkisi Şekil 3.12’de incelenebilir.



Şekil 3.12. Yarı periyodik gürültü, gürültünün uygulanmış kameraman görüntüsü ve frekans uzayındaki tepe noktalarının görünümü

Yarı-periyodik gürültüye frekans uzayında bakıldığı zaman merkez bileşeninin çevresinde dört yıldız şeklinde net bir şekilde görülebilen tepe noktaları bulunmakta ve yüksek frekans alanında daha iyi bir görünürlük elde etmek için manuel olarak işaretlenmiş en az sekiz adet çok küçük tepe noktası da mevcuttur. $M \times N$ ölçülerindeki bir görüntüye, sentetik olarak aşağıda yer alan 3.9'daki denklem kullanılarak yarı-periyodik gürültü eklenebilir.


$$n(x, y) = 50 \sin\left(\frac{2\pi p x}{X}\right) \sin\left(\frac{2\pi q y}{Y}\right) \quad (3.9)$$

Bu formülde $n(x, y)$, x ve y koordinatlarındaki gürültü değerini temsil ederken, $50 \sin$ gürültünün genlik katsayısını, p ve q sırasıyla x ve y eksenlerindeki gürültünün frekans bileşenlerini, X ve Y ise görüntünün boyutlarını ifade eder. Bu gürültü sinyali, görüntüde belirli periyotlarla tekrarlanan desenler oluşturarak yarı periyodik bir yapı sergiler ve Fourier dönüşümünde frekans uzayında belirgin tepe noktaları oluşturarak tanımlanabilir. (Sur & Grediac, 2015).

3.1.7.5. Çok Frekanslı Periyodik Gürültü

Çok frekanslı periyodik gürültü, birden fazla periyodik gürültünün aynı anda görülmesi, farklı gürültü kaynaklarından kaynaklanan çeşitli gürültülerin veya tek bir kaynaktan çıkan farklı gürültülerin görüntü üzerindeki birleşik etkisidir. Bu gürültüler, görüntü üzerinde iç içe geçmiş bir yapıda bulunabilir ve genellikle yapay olmayan görüntüler bu tür çok frekanslı periyodik gürültüler tarafından bozulur (Alibabae & Latif, 2021) (Leventhall, 2009). Şekil 3.13'te, birden fazla periyodik gürültünün görüntü üzerinde

oluşturduğu etki ve bu gürültülü görüntünün frekans alanındaki tepe noktalarının dağılımı gösterilmektedir.



Şekil 3.13.Çok frekanslı periyodik gürültülü görüntü ve gürültünün frekans uzayındaki görünümü.

Çok frekanslı periyodik gürültüyü sentetik olarak oluşturmak için aşağıda yer alan 3.10 denklemi kullanılabilir. Bu denklemde A değerinin 0,5 olarak alınmasıyla çoklu frekanslı periyodik gürültü elde edilebilir.

$$n(x, y) = A \times 255 \times (\sin(x + y) + \sin(3.8x + 1.8y) + \sin(2.2x + 2.2y) + \sin(3.8x - 1.8y) + \sin(x - y) + \sin(20.2x - 20.2y)) \quad (3.10)$$

Buna ek olarak, aşağıda verilen 3.11’de ki denklem ile de çoklu frekanslı gürültü oluşturulabilir:

$$n(x, y) = A \times 255 \times (\sin(3.1x + 10.1y) + \sin(3.5x) + \sin(3.5y) + \sin(3.1x - 1.1y)) \quad (3.11)$$

3.1.7.5. Şerit Periyodik Gürültü


Son dönemlerde, uzay ve hava kaynaklı uzaktan görüntüleme sistemleri, şehir planlaması, askeri izleme, çevresel gözetim gibi çeşitli disiplinlerde yaygın olarak kullanılmaktadır (Kang ve ark., 2012) (Acito ve ark., 2010) (Tsai & Chen, 2008) (Fehrenbach ve ark., 2012). Fakat, bu işlemler sırasında kullanılan farklı detektörler, foton etkileri, kalibrasyon hataları vb. sebeplerle, uzaktan algılama görüntüleri şerit gürültüsü ile kirlenmiş olabilmektedir. Uzaktan algılama görüntülerindeki bu şeritler, görüntülerin görsel kalitesini ciddi anlamda düşürmekle kalmayıp, görüntü karıştırma ve sınıflandırma gibi sonrasında gerçekleştirilen farklı işlemlerde de zorluklar yaratmaktadır (Cao ve ark., 2018).

Şerit gürültüsü, görüntü üzerinde yatay veya dikey ekseninde şerit şeklinde beliren gürültü türüdür. Bu gürültünün periyodik olarak birbirini takip eden şeritler şeklinde görülmesi onu periyodik gürültüler kategorisine sokar. Ancak şerit gürültüsü periyodik bir yapıya sahip olduğu gibi, periyodik olmayan yapıda da mevcut olabilir (Chen ve ark., 2017) (Cao ve ark., 2021).

Şerit gürültüsü, diğer gürültü türleri ile kıyaslandığında, belirgin bir yapısal karakteristik ve yönelik özelliği gösterir. Bu özellik, şerit gürültü sinyalinin Fourier alanında genellikle dikey veya yatay ekseninde ani bir şekilde görülmesine neden olur (Alibabaie & Latif, 2021). Şerit gürültüsü aşağıdaki denklem (3.12) ile modellenenir:

$$p(x, y) = r(x, y) + s(x, y) \quad (3.12)$$

Burada $p(x, y)$ bozulmuş görüntüyü, $r(x, y)$ potansiyel şeritsiz görüntüyü ve $s(x, y)$ ise şerit gürültüsünü temsil eder (Chen ve ark., 2017) (Guan ve ark., 2019). Şekil 3.14'te görüldüğü gibi, şerit gürültüsü periyodik bir yapıda ilerler. Periyodik olması sebebiyle, frekans uzayında tepe noktaları kolaylıkla gözlemlenebilir.



Şekil 3.14.Periyodik yapıya sahip Şerit gürültüsü, gürültü eklenmiş görüntü ve gürültünün frekans uzayındaki görünümü.

3.1.8. Gürültü Giderme Teknikleri

Bu kısımda, görüntülerdeki gürültülerin giderilmesi sorununa yönelik temel yaklaşımlar ele alınacak ve bu yöntemlerin birbirleriyle olan benzerlikleri ile farklılıkları üzerinde durulacaktır.

Görüntü işlemede en yaygın kullanılan filtreleme teknikleri mekânsal alan filtreleme teknikleridir. Mekânsal filtreleme, görüntüde yalnızca toplamsal gürültünün bulunduğu

durumlarda tercih edilen yöntemdir. Mekansal Alan Filtreleme arkasındaki ana fikir, bir maskeyi görüntüyle evriştirmektir (Vyas ve ark., 2018).

3.1.8.1. Ortanca Filtreleme (Median Filtering)

Ortanca filtre, gürültüyü gidermek amacıyla sıklıkla başvurulmuş doğrusal olmayan bir dijital filtreleme tekniğidir. Bu tür gürültü azaltma işlemleri genellikle sonraki işleme aşamalarının (örneğin, bir görüntüde kenar belirleme) sonuçlarını iyileştirmek için tipik bir ön işleme adımı olarak ele alınır. Ortanca filtreleme, belirli şartlar altında görüntülerin kenarlarını muhafaza ederken gürültüyü etkili bir şekilde giderdiği için dijital görüntü işleme alanında geniş bir kullanım alanına sahiptir. Ortanca filtre, çıktı değeri, filtre penceresinden elde edilen piksel değerlerinin sıralı dizisinin ortanca elemanı olan doğrusal olmayan bir yerel filtredir. Ortanca değerin, uç değerlere karşı dayanıklı olması sebebiyle, filtre özellikle dürtü (impuls) gürültüsünü azaltma amacıyla tercih edilir (Chandel & Gupta, 2013). Ortanca (median) filtrelemenin formülü şu şekildedir:

$$\hat{f}(x, y) = \text{median}_{(s,t) \in S_{xy}} \{g(s, t)\} \quad (3.13)$$

Burada, $\hat{f}(x, y)$ filtrelenmiş görüntünün (x, y) konumundaki piksel değeri median, Medyan değeri almayı ifade eder. S_{xy} (x, y) merkezli filtre penceresi, çevredeki pikselleri içerir ve medyanı hesaplarken bu piksellerin değerleri dikkate alınır. $g(s, t)$ gürültülü orijinal görüntünün (s, t) konumundaki piksel değeridir. Formülde, S_{xy} penceresi içindeki piksellerin gri seviye değerlerine bakılır ve bu değerlerden medyan değer bulunur. Daha sonra (x, y) konumundaki pikselin değeri, bu medyan değer ile değiştirilir. Bu işlem, görüntünün tüm pikselleri için tekrarlanarak gürültü azaltılır ve görüntü düzeltilmiş olur. Ortanca filtre, özellikle darbe tipi gürültü (impulse noise) için etkili bir yöntemdir çünkü rastgele dağılmış yoğun gürültü piksellerini yumuşatır ve görüntünün ana hatlarını korurken gürültüyü giderir (Vyas ve ark., 2018).

3.1.8.2. Ortalama Filtreleme (Mean Filtering)

Ortalama filtreleme, görüntülerdeki gürültüyü azaltmak için kullanılan basit ve sezgisel bir yöntemdir. Her piksel değeri, kendisi dahil olmak üzere komşu piksellerin ortalaması ile değiştirilir (Gonzalez & Woods, 2008). Bu işlem, çevrelerine göre temsil edici olmayan piksel değerlerini ortadan kaldırır ve genellikle bir konvolüsyon filtresi olarak

düşünülür. Yaygın olarak 3x3'lük kare bir çekirdek kullanılsa da daha şiddetli yumuşatma için daha büyük çekirdekler (örneğin 5x5 kareler) kullanılabilir. Genelde Tuz & Biber gürültüsünü ortadan kaldırma için kullanılmaktadır (Erkan ve ark., 2019). Ortalama (mean) filtrelemenin formülü şu şekildedir:

$$f'(x, y) = \frac{1}{MN} \sum_i^a = -a \sum_j^b = -b^{f(x+i, y+j)} \quad (3.14)$$

Burada, $f'(x, y)$ filtrelenmiş görüntünün yeni değeri. $f(x+i, y+j)$ orijinal görüntünün komşu piksellerinin değerleri. $M \times N$ filtreleme penceresinin boyutu (örneğin, 3x3, 5x5, vb.). Bu, M satır ve N sütun olmak üzere bir matristir. a ve b filtreleme penceresinin yarı genişlikleri. Örneğin, 3x3'lük bir pencere için $a = b = 1$ (Gonzalez & Woods, 2008). Bu formül, her bir pikselin değerini, belirli bir boyuttaki bir penceredeki komşu piksellerin aritmetik ortalaması ile değiştirir. Bu süreç tüm görüntü üzerinde tekrarlanır (Rakshit, Ghosh, & Shankar, 2007).

3.1.8.3. Gaussian Filtreleme

Gaussian filtreleme, görüntü işleme, sinyal işleme ve diğer birçok alanda kullanılan önemli bir yumuşatma (smoothing) tekniğidir. Bu yöntem bir görüntü üzerindeki detay ve gürültüyü azaltarak görüntüyü bulanıklaştırır. Gaussian filtresi, merkezi pikseller üzerinde daha yüksek ağırlıklara sahip olduğu için, kenarları korurken yumuşak bir şekilde yumuşatma sağlar. Bu özellik, görüntü üzerindeki yüksek frekanslı parazitleri ve rastgele gürültüyü azaltırken, görüntünün önemli detaylarının korunmasına yardımcı olur (Afshari ve ark., 2017).

Gaussian filtresinin matematiksel formülü, 2 boyutlu izotropik (yani dairesel simetrik) bir Gaussian dağılımı olarak ifade edilir. Bu dağılım, merkezi pikseller üzerinde daha ağır bir ağırlık verir ve bu da filtre çekirdeğinin şeklini belirler. Pratikte, Gaussian fonksiyonunun teorik olarak sonsuz uzunlukta olması gerektiğinden, filtrenin pencere uzunluğu genellikle standart sapmanın üç katı civarında bir noktada kesilir

Gaussian filtresi, frekans cevabı açısından bir düşük geçiş filtresi (lowpass filter) olarak işlev görür. Bu, filtrelenmiş görüntünün yüksek frekans bileşenlerinin (örneğin, gürültü veya çok ince detaylar gibi) azaltılması anlamına gelir. Filtrenin frekans cevabı, yani farklı uzaysal frekanslara olan etkisi, filtrenin Fourier dönüşümü alınarak görülebilir. Gaussian filtresinin matematiksel formülü genellikle aşağıdaki gibi verilir:

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-(x^2+y^2)/2\sigma^2} \quad (3.15)$$

Burada, $G(x, y)$ Gaussian fonksiyonunun değeri, σ standard sapmayı ifade eder. x ve y , merkez piksele göre konumları belirten değişkenlerdir. Standard sapma (σ), filtre çekirdeğinin genişliğini ve dolayısıyla yumuşatma derecesini belirler. Daha büyük bir σ değeri, daha geniş bir çekirdek ve daha güçlü bir yumuşatma anlamına gelir (Shreyamsha Kumar, 2013).

3.1.8.4. Çentik Filtresi (Notch Filter)

Çentik filtresi, belirli frekans bileşenlerini bastırmak veya ortadan kaldırmak amacıyla tasarlanmış bir tür frekans alanı filtresidir. Özellikle dijital görüntülerde, belirli frekanslardaki gürültülerin giderilmesinde etkili bir araçtır. Çentik filtresi, hedeflenen frekansları seçici olarak baskılamak için kullanılır. Genellikle frekans alanında uygulanır ve bu nedenle Fourier dönüşümü kullanılarak görüntü frekans alanına dönüştürülür. Gürültü frekansları tespit edildikten sonra, bu frekansları bastırmak için bir Çentik filtresi tasarlanır (Gonzalez & Woods, 2008).

Çentik filtresi, bant durduran ve bant geçiren filtre olarak da bilinir. Bant durduran, belirlenmiş frekanslarda sinyalleri bastırır. Gürültünün veya istenmeyen frekans bileşenlerinin filtrelenmesi için kullanılır. Fourier dönüşümünün simetrisi nedeniyle, eğer filtre merkezi orijinde ise tek başına ortaya çıkabilir. Diğer durumlarda ise, filtreler genellikle simetrik çiftler halinde tasarlanır ve kullanılır. Bant geçiren ise bant durduranın tam tersi işlevi görür. Yani, durdurulan frekansları geri kazandırır. Bu durumda, bir çentik geçiş filtresinin aktarım fonksiyonu, çentik durduran filtresinin aktarım fonksiyonunun tamamlayıcısı olarak ifade edilir. Matematiksel olarak 3.16'da yer alan denklem ile ifade edilir.

$$H_{NP}(u, v) = 1 - H_{NR}(u, v) \quad (3.16)$$

Burada $H_{NP}(u, v)$ bant geçiren filtresinin aktarım fonksiyonunu, $H_{NR}(u, v)$ ise bant durduran filtresinin aktarım fonksiyonunu temsil eder. Gürültü gidermede çentik filtresi sıklıkla tercih edilen bir filtre türüdür.

3.1.8.5. Wiener Filtreleme

Wiener filtreleme, gürültülü görüntü ve görüntü dizilerinin adaptif filtrelenmesi için kullanılan bir yöntemdir. Bu teknik, bir sinyalin ya da görüntünün istenmeyen gürültüden arındırılmasını sağlayarak, orijinal sinyalin veya görüntünün daha iyi bir tahminini elde etmeyi amaçlar. Wiener filtreleme, özellikle gürültü içeren görüntülerin iyileştirilmesi, sinyal işlemede gürültü azaltma, görüntü keskinleştirme ve sinyallerin düzeltilmesi gibi çeşitli uygulamalarda kullanılır (Jin ve ark., 2003).

Wiener filtresinin matematiksel temeli, sinyalin güç spektrumu ile gürültünün güç spektrumu arasındaki orana dayanır ve minimum ortalama kare hatası kriterine göre optimal bir filtre tasarımını sağlar. Wiener filtresinin temel formülü şu şekildedir:

$$W(f) = \frac{S(f)}{S(f) + N(f)} \quad (3.17)$$

Burada, $W(f)$ Wiener filtresinin frekans domenindeki transfer fonksiyonudur, $S(f)$ sinyalin güç spektrumu ve $N(f)$ gürültünün güç spektrumudur. Bu formül, frekans bileşenlerinin sinyal ve gürültü oranına bağlı olarak ne ölçüde filtrelenmesi gerektiğini belirler.

Wiener filtrelemesi, görüntü işlemede, özellikle hareketli görüntülerin restorasyonu ve zaman serisi sinyallerinin analizinde geniş bir uygulama alanına sahiptir. Görüntü ve sinyal işlemede gürültüyü azaltmanın yanı sıra, bu yöntem aynı zamanda iletişim sistemlerinde sinyal tahmini ve iyileştirilmesi için de kullanılmaktadır.

3.1.8.6. Dalga Dönüşümü (Wavelet Transform)

Dalgacık dönüşümü, bir sinyalin zaman-frekans analizinde kullanılan bir yöntemdir. Sismik verilerin incelenmesi sırasında karşılaşılan zorluklar, “Sürekli Dalgacık Dönüşümü” nün geliştirilmesine imkân tanımıştır (Öner ve ark., 2017). Bilimsel araştırmalarda ilerleyici görüntü analizi amacıyla değerlendirilen dalgacık dönüşümü, özellikle değişken sinyallerin işlenmesinde fayda sağlamaktadır. Bu yöntem, değişen frekans ve uzunluklardaki minik dalgalar olan dalgacıklar temel alınarak oluşturulmuştur. Dalgacık dönüşümü, bir görüntünün hem frekansını hem de mekânsal konumunu ortaya koyar. Klasik Fourier dönüşümünün aksine, bu yöntemle zaman bilgisinin korunması mümkündür. Dalgacıklar, bir ana dalgacık fonksiyonunun çeşitli ölçeklerde

geniştirilmesi ve yer deęiřtirmesi ile elde edilir. Bu kapsamda, dalgacık dnüşümünün görüntüler üzerinde watermark oluşturmak için kullanımının uygunluğu ve dięer dnüşüm yöntemlerine göre avantajları incelenmektedir (Muthukrishnan ve ark., 2019).

3.1.9. Periyodik Gürültü Giderme Teknikleri ve Akademik Çalışmalar

Periyodik gürültülü görüntülerin giderilmesinde, dięer gürültü tiplerinde kullanılan filtreleme yöntemleri doğrudan yetersiz kalmaktadır. Uzamsal alan filtreleri periyodik gürültüyü tamamen ortadan kaldırmak için yeterli olmayabilir. Bu tür gürültü ancak frekans uzayında yapılan filtreleme işlemleri ile ortadan kaldırılabilir. (Hiremath & Rani, 2020) Periyodik gürültülerin görüntü spektrumunda tepe noktalar oluşturması sebebiyle, frekans alanında yapılan işlemler, uzamsal alan işlemlerinden çok daha iyi sonuç vermektedir (Aizenberg & Butakoff, 2002).

Fourier dnüşümü, tepe noktalarının belirlenmesinde en etkili yöntemlerden biridir. Bu nedenle frekans-uzamsal filtreler, Fourier dnüşümlerine dayalı olarak periyodik gürültünün filtrelenmesini kolaylaştırır. Fourier dnüşümü, bir görüntüyü sinüs ve kosinüs bileşenlerine ayırmak için önemli bir araçtır. Bu dnüşümün sonucu, görüntünün frekans alanında veya Fourier alanında bir temsilini sağlarken, giriş görüntüsü onun uzaysal alandaki karşılığıdır. Fourier alanındaki her nokta, uzaysal alandaki görüntüdeki belirli bir frekans bileşenine karşılık gelir. Fourier dnüşümleri görüntü analizi, filtreleme, yeniden oluşturma ve sıkıştırma gibi çeşitli uygulamalarda kullanılır.

Fourier Dnüşümü, frekans uzayında tepe noktalarının belirlenmesi ve periyodik gürültünün giderilmesinde etkili bir rol oynar. 3.18’de yer alan denklemde tanımlanmıştır. Denkleme göre; $F(k, l)$, görüntünün yoğunluk deęerlerinin, $M \times N$ boyutlarında bir evrende, k ve l noktası, kaydırılmış genlik frekans spektrumunun merkezinde bulunur (Ketenci & Gangal, 2012). Orijin kaydırılmış Fourier dnüşürülmüş görüntüsü, aşağıdaki F şeklinde belirlenir:

$$F(k, l) = \frac{1}{MN} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} (-1)^{i+j} A(i, j) e^{-x2\pi \left(\frac{ki}{M} + \frac{lj}{N} \right)} \quad (3.18)$$

Formülde $F(k, l)$, frekans domenindeki (k, l) konumundaki Fourier katsayısını ifade ederken, $A(i, j)$ zaman veya mekân domenindeki (i, j) konumundaki sinyal veya görüntü deęeridir. M ve N sinyalin veya görüntünün boyutlarını belirtir. Formülde yer alan (-

$l)^{i+j}$ terimi faz kayması için kullanılırken $e^{-x2\pi(\frac{ki}{M}+\frac{lj}{N})}$ terimi Fourier dönüşümünün temel bileşenidir. İç içe toplama işlemleri tüm sinyal noktaları üzerinden geçerek her bir Fourier katsayısını hesaplar ve sonuç $\frac{1}{MN}$ ile normalize edilir. Burada $i^2 = -1$ ve $(-1)^{i+j}$ orijin kaydırma işlemini gösterir (Ionita & Coanda, 2017). Ayrıca (k, l) konumu şu şekildedir: $0 \leq k \leq M-1$ ve $0 \leq l \leq N-1$ (Varghese J. , 2016).

Periyodik gürültüler, genellikle sinüzoidal fonksiyonlar tarafından üretilen tekrarlayan modeller olduğundan, bu gürültülere karşılık gelen frekanslar, görüntü spektrumunda, bozucu sinüzoidal fonksiyonların frekansına bağlı olarak farklı frekans konumlarında bulunan eşlenik tepe noktaları olarak gözlemlenir (Varghese J. , 2016). Böylece spektrum boyunca yayılan bu bozuk frekanslar, yıldız şeklinde bir görünüm sağlayarak frekans uzayında tepe noktaları oluşturur.

Periyodik gürültüler genellikle sinüzoidal fonksiyonların, yıldız şeklindeki spektral tepeler olarak ortaya çıkar ve bu durum, frekans alanında tespit ve filtreleme işlemlerinin daha etkili olmasına neden olur. Ayrıca, bu tepe noktalarını değiştirerek veya çıkararak, görüntünün daha iyi yenilenmesini sağlama olanağı sağlanır. Gürültüyü azaltmanın çeşitli yöntemleri arasında en yaygın olanı, Fourier dönüşümü kullanarak görüntüyü frekans domainine taşıma ve gürültüye neden olan frekansları filtreleme yöntemidir. Düşük geçişli, yüksek geçişli veya bant geçişli filtreler bu süreçte etkili araçlar olarak kullanılabilir.

Diğer bir yöntem olan uzaysal filtreleme, görüntü üzerinde doğrudan çalışarak, ortalama veya medyan filtreleme gibi tekniklerle gürültünün azaltılmasını sağlar. Adaptif filtreler, görüntünün kendine has özelliklerine göre uyarlanabilen ve özellikle Wiener filtresi gibi yerel değişkenlere dayalı dinamik filtreleme sağlayan yöntemlerdir. Ayrıca, dalgacık dönüşümü, görüntüyü farklı frekans ve konum bileşenlerine ayırarak gürültünün etkili bir şekilde izole edilmesine ve temizlenmesine imkân tanır. Her bir temizleme yöntemi, uygulama alanına ve gürültünün karakteristiklerine göre avantajlar ve dezavantajlar sunar; dolayısıyla, görüntüdeki bilgi kaybını minimize ederken gürültüyü etkin bir şekilde azaltacak en uygun yöntemin belirlenmesi esastır. Periyodik gürültünün giderilmesine yönelik yapılmış örnek çalışmalar aşağıda özetlenmiştir:

Ionita ve Coanda (2017) tarafından yürütülen çalışmada, mikroskopi görüntülerindeki periyodik gürültü kalıplarının giderilmesi ele alınmıştır. Önerilen yöntem, frekans alanında büyüklük spektrum bileşenlerini analiz ederek, belirler ve düzeltir. İki pencere filtresi ve yinelemeli bir eşikleme yöntemi kullanarak gürültü bileşenleri tespit edilir ve bu bileşenler için tasarlanan iki maske, periyodik gürültüyü ortadan kaldırmak için spektrumu işler. Bu yöntem, yüksek performanslı Grafik İşlem Birimi (GPU) donanımına ihtiyaç duyar ve gerçek dünya gürültüsünün çeşitliliği daha fazla araştırmayı gerektirir.

Aizenberg ve Butakoff (2008), görüntülerin Fourier genlik spektrumunda gürültüye bağlı olarak oluşan piklerin yerel medyan kullanılarak tespit edilmesi ve ardından bir Gauss çentik filtresi modifikasyonu ile düzeltilmesi sürecini uygulamışlardır. Bu yöntem, özellikle yarı periyodik gürültünün azaltılmasında etkili olmuş ve piklerin yanı sıra çevrelerindeki alanların da düzeltilmesini sağlamıştır. Ancak, tepe noktası tespiti ve filtreleme parametrelerinin manuel olarak belirlenmesi gerekliliği, yöntemin adaptasyonunu ve kullanıcı dostu oluşunu sınırlamaktadır.

Sur ve Grédiac (2015), çalışmasında, yarı periyodik gürültünün otomatik olarak giderilmesine odaklanmıştır. Görüntülerin Fourier alanındaki gürültü piklerinin tespiti ve bunların Gauss çentik filtresi ile düzeltilmesi esas alınmıştır. Bu süreç, karmaşık yarı periyodik gürültülerin de etkili bir şekilde azaltılmasını sağlamıştır, ancak tepe noktası tespiti ve filtre parametrelerinin manuel ayarlanması yöntemin genel uygulanabilirliğini sınırlayan bir eksiklik olarak değerlendirilmiştir.

Moallem ve ark., (2015), dijital görüntülerdeki periyodik gürültüleri azaltmayı amaçlayan bir adaptif Gauss iyileştirme filtresi geliştirmiştir. Bu yöntem, adaptif bir eşik kullanarak spektral band üzerinde bir segmentasyon algoritması uygulayarak ve ardından bir bölge büyütme algoritmasıyla periyodik gürültü bileşenlerinin bant genişliğini belirlemiştir. Sonrasında, yalnızca kirletilmiş gürültü frekanslarında periyodik gürültüleri azaltmak için uygun Gauss düğüm filtreleri kullanılmıştır. Bu yöntem, diğer bilinen filtrelerle karşılaştırıldığında daha yüksek performans ve daha düşük hesaplama maliyeti sağladığı gösterilmiştir.

Novikov ve ark., (2022), tarafından gerçekleştirilen çalışma, periyodik gürültü filtreleme yöntemlerini geliştirmeyi amaçlamaktadır. Bu çalışmada, iki boyutlu Fourier dönüşümünün katsayılarını dönüştürerek periyodik gürültüye karşılık gelen bileşenlerin


dışlanmasına dayanan bir yöntem önerilmiştir. Kenar dedektörü kullanımıyla genlik spektrumunun yerel maksimumları ve çevreleri basit bir şekilde tespit edilmektedir. Elde edilen kontur imajı, bir maske oluşturmak için kullanılarak periyodik gürültülerin frekanslarının “kesilmesi” sağlanmaktadır. Farklı şekil ve yoğunluktaki gürültüler üzerinde önerilen yaklaşım incelenmiş ve periyodik gürültü ile katkısız beyaz gürültünün bir karışımı üzerinde çalışmalar yapılmıştır.

Chen ve ark., (2017) tarafından geliştirilen yeni bir çizgi gürültüsü giderme yöntemi, uzaktan algılanan görüntülerdeki çizgi gürültüsünü azaltmayı amaçlamaktadır. Bu yöntem, çizgi gürültüsünün ve görüntü özelliklerinin içsel özelliklerini tam olarak dikkate alan bir görüntü ayrıştırma çerçevesi içerisinde birleştirir. Önerilen model, tek yönlü toplam varyasyon (TV) düzenlemesi, grup seyreklik düzenlemesi ve TV düzenlemesini bir araya getirir. İlk iki terim, istatistiksel analizler uygulayarak çizgi gürültüsü özelliklerini kullanırken, TV düzenlemesi çizgi gürültüsünden arındırılmış görüntünün mekânsal parça parça düzgün yapısını keşfetmek için benimsenmiştir. Ayrıca, önerilen modeli çözmek için etkili bir alternatif minimizasyon şeması tasarlanmıştır. Simüle edilmiş ve gerçek veriler üzerinde yapılan kapsamlı deneyler, önerilen yöntemin hem niceliksel hem de niteliksel değerlendirmeler açısından mevcut en iyi yöntemlerden daha üstün olduğunu göstermiştir.

3.2. Derin Öğrenme ve Derin Öğrenme ile Görüntülerdeki Gürültülerinin Giderilmesi

3.2.1. Derin Öğrenme

Derin öğrenmenin temelleri, 1940'ların sonlarında ve 1950'lerin başlarında ortaya çıkan yapay sinir ağları ve bunların bağlantısal modelleri ile atılmıştır. Bu alandaki ilk araştırmaların önemli örneklerinden biri, 1943'te McCulloch ve Pitts tarafından geliştirilen yapay sinir ağı modelidir. (McCulloch & Pitts, 1943) Daha sonra 1958 yılında Rosenblatt tarafından tanıtılan perceptron algoritması, derin öğrenmenin erken dönem gelişmelerinde önemli bir adım olmuştur. Perceptron, biyolojik nöronlardan esinlenerek tasarlanmış basit bir algoritmadır ve özellikle doğrusal olarak ayrılabilen veri kümeleri için kullanılır (İnik & Turan, 2018). Algoritmanın temel amacı, iki sınıfı birbirinden ayıran bir karar sınırı bulmaktır. Perceptron, lineer sınıflandırma yapabilen basit bir modeldir ve yapay sinir ağı yaklaşımları için temel oluşturmuştur (İnik & Ülker, 2017). Yapay sinir ağına ilişkin mimari Şekil 3.15'te verilmiştir.



Şekil 3.15. Yapay sinir ağı mimarisi (Amidi & Amidi, Stanford, 2023)


Derin öğrenme ile ilgili çalışmalarda en çok kullanılan yöntemlerden biri Evrişimli Sinir Ağlarıdır (CNN). Bu yaklaşım, bilgisayarla görme uygulamalarında başarılı sonuçlar vererek görüntü işleme alanında yeni bir standart oluşturmaktadır.

3.2.2. Evrişimli Sinir Ağları-ESA (Convolutional Neural Networks-CNN)

Evrişimli Sinir Ağları (CNN), derin öğrenmenin alt dallarından biri olup, çok boyutlu verilerin, özellikle görüntü ve ses verilerinin, işlenmesinde kullanılan bir yapay sinir ağı mimarisidir. CNN'ler, giriş verilerini analiz ederken yerel özellikleri tanımlamak amacıyla evrişim katmanlarından faydalanır. CNN'ler, bu evrişim katmanlarının yanı sıra, özellikleri daha yüksek seviyelerde soyutlayarak öğrenmek için aktivasyon, havuzlama

(pooling), ve tam bağlantılı (fully connected) katmanlar gibi ek bileşenleri de içermektedir (Kaya ve ark., 2023).

CNN 1980'lerin sonralarına doğru görüntü işleme konusunda kullanılmaya başlanmış ve ConvNet adlı ilk çok katmanlı CNN mimarisi önerilmiştir (Khan ve ark., 2020). İlk başarılı örnek ise olarak 1989 yılında Yann LeCun ve ekibi tarafından, el yazısı rakamların tanınması için kullanılan “LeNet” adlı ağ yapısıyla tanıtılmıştır. Bu çalışma, Evrişimli sinir ağlarının derin öğrenmede kullanımını gösteren ilk çalışmalardan biri olarak kabul edilmektedir. Bu ağ, özellikle el yazısı rakamların tanınması üzerine odaklanmış olup, daha sonra bilgisayarla görü alanında birçok uygulamaya öncülük etmiştir (LeCun ve ark., 1998). Evrişimli Sinir Ağının mimarisine ilişkin görsel Şekil 3.16’da verilmiştir.



Şekil 3.16.Evrişimli Sinir Ağı mimarisi (Amidi & Amidi, Stanford, 2023)


LeNet'in başarısından sonra, 2012 yılında AlexNet, Alex Krizhevsky ve arkadaşları tarafından tanıtıldı ve ImageNet yarışmasında kazandığı başarı ile derin öğrenme ve CNN'lerin bilgisayarla görü alanında kullanılmasının önünü açmıştır. (Krizhevsky, Sutskever, & Hinton, 2012) AlexNet'in başarısı, daha büyük ve daha derin modellerin geliştirilmesine yol açmıştır.

Bu bölümde LeNet, AlexNet, ZFNet, VGG, GoogLeNet/Inception ve ResNet gibi temel modelleri başlıklar altında inceleyeceğiz.

3.2.2.1. LeNet-5

LeNet (LeNet-5), 1998 yılında LeCun tarafından önerilmiş bir CNN'dir (LeCun, ve diğerleri, 1995). Bu mimari, tarihsel önemi nedeniyle ünlüdür; çünkü el yazısı ile yazılmış rakamların tanıma görevlerinde ileri düzey performans sergileyen ilk CNN'dir. LeNet, küçük bozulmalardan, döndürmeden ve konum ve ölçek değişikliklerinden etkilenmeden

rakamları sınıflandırabilmektedir. LeNet, dönüşümlü olarak yerleştirilmiş konvolüsyonel ve havuzlama katmanlarının ardından gelen iki tam bağlantılı katmandan oluşan 5 katmanlı bir yapıya sahiptir. LeNet mimarisi Şekil 3.17’de detaylıca gösterilmiştir.



Şekil 3.17. LeNet ağına ait çalışma prensibini gösteren mimari yapı (Zhang, Lipton, Li, & Smola, 2023)


LeNet, görüntünün temel özelliğinden yararlanarak komşu piksellerin birbirine bağlı olduğunu ve motiflerin tüm görüntüde dağıtıldığını belirledi. Bu nedenle, konvolüsyonel ağlar, öğrenilebilir parametreler kullanarak az sayıda parametre ile farklı konumlarda benzer özellikleri etkili bir şekilde çıkarılabilmektedir. Paylaşılabılır parametrelerle öğrenme, geleneksel olarak her pikselin kendi komşuluğundan ayrı bir giriş özelliği olarak değerlendirildiği anlayışı değiştirdi ve aralarındaki bağı göz ardı etti. LeNet, piksel bazlı öğrenmede konvansiyonel yaklaşımdan farklı olarak sadece parametre sayısını azaltmakla kalmadı, aynı zamanda ham piksellerden özellikleri otomatik olarak öğrenebilmiştir.

3.2.2.2. AlexNet

LeNet görüntü işlemede CNN'lerin tarihini başlatmış olsa da o dönemde CNN'ler el yazısı rakam tanıma görevleriyle sınırlıydı ve tüm görüntü sınıflarına yönelik iyi bir performans sergileyemiyordu. Bu kapsamda AlexNet, Krizhevsky ve ark., (2012) tarafından geliştirilmiştir. Görüntü sınıflandırma ve tanıma görevlerinde çığır açıcı sonuçlar gösteren ilk derin CNN mimarisi olarak kabul edilmektedir (Krizhevsky ve ark., 2012).

AlexNet 2012 yılında ImageNet yarışmasında kazandığı başarı, derin öğrenme modellerinin popülerliğini artırmıştır. AlexNet'in zaferi, derin öğrenme algoritmalarının büyük ölçekli görüntü tanıma ve bilgisayarla görme alanlarında güçlü bir araç olduğunu

gösterdi ve bu alanın hızlı bir şekilde büyümesine yol açmıştır. AlexNet'in temel mimari tasarımı Şekil 3.18'de gösterilmiştir.



Şekil 3.18. AlexNet mimarisi (Han, Zhong, Liqin, & Zhang, 2017)


2000'lerin başlarında, eğitim süreçlerini hızlandırmak için GPU'lar yaygın değildi ve CPU'lar da yavaştı (Potluri ve ark., 2011). Geleneksel çok katmanlı tam bağlantılı CNN'lerin başlıca kısıtlaması her bir pikseli ayrı bir giriş olarak ele alması ve her birine dönüşüm uygulamasıydı. Bu özellikle o dönemde önemli bir hesaplama yükü oluşturuyordu (Gardner & Dorling, 1998). Donanım kısıtlamaları derin CNN mimarilerinin öğrenme kapasitesini küçültmekte ve sınırlı boyutlarda kalmasına neden olmaktaydı. Derin CNN'lerin temsil gücünden faydalanmak için AlexNet, donanımın sınırlamalarını aşmak amacıyla iki NVIDIA GTX 580 GPU'su kullanılarak paralel olarak eğitilmiştir. AlexNet'te, derinlik CNN'i çeşitli görüntü kategorileri için uygulanabilir kılmak amacıyla LeNet'in 5 katmanlı yapısını 8 katmana çıkarılmıştır. Genellikle derinlik, farklı çözünürlüklerdeki görüntüler için genelleme yeteneğini artırsa da derinliğin artmasının ana dezavantajı aşırı öğrenmedir. Bu zorluğun üstesinden gelmek için Krizhevsky ve ark., (2012), algoritmalarının modelin daha sağlam özellikler öğrenmesini sağlamak için eğitim sırasında bazı dönüşüm birimlerini rastgele atladığı bir yöntemi kullanmışlardır. Aşırı öğrenmeyi azaltarak genellemeyi geliştirmek için çakışan alt örnekleme ve yerel yanıt normalizasyonu da uygulanmıştır.

3.2.2.3. ZFNet

Zeiler ve Fergus (2014) tarafından tasarlanan ZFNet, AlexNet'in performansını optimize etmek amacıyla çok katmanlı bir Dekonvolüsyonel ağ olarak geliştirilmiştir (Zeiler & Fergus, 2014). Dekonvolüsyonel Sinir Ağı (DeCNN), daha düşük çözünürlüklü

girişlerden yüksek çözünürlüklü özelliklerin üst örnekleme veya yeniden oluşturulması gibi ters görüntü işleme görevlerini gerçekleştirmek için tasarlanmış bir tür yapay sinir ağıdır (Cao, Yao, & Liang, 2020).

ZFNet, ağ performansını nicel olarak görselleştirmek için geliştirilmiştir. Ağ aktivitesinin görselleştirilmesi fikri, nöronların aktivasyonunu yorumlayarak CNN performansını izlemektir. ZFNet mimarisine ait görsel Şekil 3.19’da yer almaktadır.




Şekil 3.19.ZFNet mimarisi (Olugboja ve ark., 2021)

ZFNet, AlexNet’ten farklı olarak ilk katmanlardaki filtre boyutunu 11x11’den 7x7’ye düşürerek daha ayrıntılı özelliklerin çıkarılmasını sağlamıştır. Bu, ağın öğrenme sürecini hızlandıran ve daha verimli hale getiren bir geliştirme olmuştur. Ek olarak ZFNet, sinir ağlarının iç yapısını analiz etmek ve ağın nasıl çalıştığını daha iyi anlamak için dekonvolüsyonel görselleştirme tekniklerini kullandı (Olugboja ve ark., 2021). Bu gelişmeler, ZFNet’in AlexNet’e göre daha düşük bir hata oranına ulaşmasına yardımcı olmuştur. ImageNet büyük ölçekli görsel tanıma yarışmasında LSVRC-2013, ZFNet %11,2’lik hata oranıyla AlexNet’ten (%19,2) daha iyi performans göstermiştir (Zeiler & Fergus, 2014). Bu sonuçlar, ZFNet’in daha küçük filtre boyutları ve optimize edilmiş katman yapısı sayesinde daha iyi sonuçlar elde ettiğini gösterir. ZFNet’in bu başarısı, derin öğrenme modellerinin evriminde önemli bir kilometre taşıdır.

3.2.2.4. VGG (Very Deep Convolutional Networks)

Görüntü tanıma görevlerinde CNN’lerin başarılı kullanımı mimari tasarım araştırmalarını hızlandırmıştır. Bu bağlamda, Simonyan ve ark., (2015), CNN mimarileri için basit ve etkili bir tasarım ilkesi önermişlerdir. VGG olarak adlandırılan bu mimari, katman deseni açısından modülerdi (Simonyan & Zisserman, 2015). VGG, derinliğin ağın temsili

kapasitesiyle ilişkisini simüle etmek için AlexNet ve ZfNet'e kıyasla 19 katman derinliğe sahipti. VGG mimarisine ilişkin görsel Şekil 3.20'de görülmektedir.




Şekil 3.20.VGG mimarisi ve ağ yapısı (İnik & Turan, 2018)

2013 ILSVRC yarışmasının öncü ağı olan ZfNet, küçük boyutlu filtrelerin CNN'lerin performansını artırabileceğini öne sürmüştür. Bu bulgulara dayanarak, VGG 11×11 ve 5×5 filtrelerini üst üste yerleştirilmiş 3×3 filtre katmanıyla değiştirdi ve küçük boyutlu (3×3) filtrelerin eşzamanlı yerleştirilmesinin büyük boyutlu filtrelerin (5×5 ve 7×7) etkisini oluşturabileceğini deneysel olarak göstermiştir. Küçük boyutlu filtrelerin kullanılması, parametre sayısını azaltarak düşük hesaplama karmaşıklığına ek bir fayda sağlar. Bu bulgular, CNN'de daha küçük boyutlu filtrelerle çalışma konusunda yeni bir araştırma trendi başlattı. VGG, 1×1 konvolüsyonel katmanlar arasında yerleştirerek ağı karmaşıklığını düzenler ve ayrıca sonuçta ortaya çıkan özellik haritalarının doğrusal bir kombinasyonunu öğrenir. Ağı ayarı için, maksimum havuzlama konvolüsyonel katmandan sonra yerleştirilir ve uzaysal çözünürlüğü korumak için pedleme yapılır (Ranzato ve ark., 2007). VGG hem görüntü sınıflandırma hem de lokalizasyon sorunları için iyi sonuçlar verdi. VGG16, 2014-ILSVRC yarışmasında 2. sırada yer aldı. Ancak basitliği, homojen topolojisi ve artan derinliği nedeniyle ün kazanmıştır. VGG mimarisi güncel olarak VGG19 modeline yükselmiştir. Bu model öncesine kıyasla daha çok

katman içermektedir. VGG19 modeli, 19 katmandan oluşan (16 evrişim katmanı, 3 tam bağlantılı katman, 5 maksimum havuzlama katmanı ve 1 yumuşak maksimum katmanı) bir VGG çeşididir. VGG11 ve VGG16 gibi diğer çeşitleri de bulunmaktadır. VGG19, 19,6 milyar FLOP'a sahiptir (Karras ve ark., 2022).

3.2.2.5. GoogLeNet


GoogLeNet, 2014 ILSVRC yarışmasının galibi olup Inception-V1 olarak da bilinir. GoogLeNet mimarisinin temel amacı, azaltılmış hesaplama maliyetiyle yüksek doğruluk elde edilmesidir (Szegedy ve ark., 2015). GoogLeNet'te, geleneksel konvolüsyonel katmanlar Network in Network (NIN) mimarisinde önerildiği gibi, her katmanı mikro bir sinir ağı ile değiştirme fikrine benzer şekilde küçük bloklarla değiştirilmiştir (Lin, Chen, & Yan, 2013). Bu blok, farklı ölçeklerde uzamsal bilgileri yakalamak için farklı boyutlarda (1×1 , 3×3 ve 5×5) filtreleri kapsar. GoogLeNet, büyük boyutlu çekirdekler kullanmadan önce 1×1 konvolüsyonel filtrelerden oluşan bir dar boğaz katmanı ekleyerek hesaplamaları düzenler. Bunun yanı sıra, gerekli olmayan özellik haritalarını atlayarak yinelenen bilgi sorununu ve maliyeti azaltmak için seyrek bağlantılar kullanmıştır. Ayrıca tam bağlantılı bir katman yerine son katmanda küresel ortalama havuzlaması kullanılarak bağlantı yoğunluğu azaltmıştır. Bu parametre ayarları, parametre sayısında 138 milyondan 4 milyona önemli bir düşüşe neden olmuştur. GoogLeNet mimarisi Şekil 3.21'de detaylı bir şekilde görülmektedir.



Şekil 3.21. GoogLeNet mimarisi (Ajith ve ark., 2021)

3.2.2.6. ResNet

ResNet (Residual Networks) bir diğer ifade ile artık ağlar, bu ağ mimarisi He ve ark., (2015), tarafından geliştirilmiştir. İlgili çalışma aynı yıl içerisinde ILSVRC yarışmasında dikkate değer başarılar elde ederek, derin öğrenme ve bilgisayarla görme alanlarında önemli bir gelişme olarak kabul görmüştür (He ve ark., 2016). ResNet'in ILSVRC yarışmasındaki başarı grafiği Şekil 3.22'de verilmiştir.




Şekil 3.22.CNN mimarileri ve ILSVRC'deki hata oranı sonucu (Chowanda & Sutoyo, 2019)

Artık ağlar, derin sinir ağlarının eğitimi sırasında karşılaşılan zorlukları aşmak amacıyla geliştirilmiş, katmanlar arası bağlantılar vasıtasıyla bilginin katmanlar arasında etkin bir şekilde aktarılmasını sağlayan bir yapıdır. Bu sayede, modelin daha derin katmanlarda dahi etkin bir şekilde öğrenmesi mümkün hale gelmektedir. ResNet mimarisinde, evrişim katmanları arasına yerleştirilen kimlik kısayol bağlantıları, girdinin doğrudan sonraki katmanlara aktarılmasını sağlayarak ağın derinleşmesine rağmen öğrenme kabiliyetinin korunmasını hedeflemektedir. Bu bağlantılar, ağın her katmanında yalnızca girdi ile çıktı arasındaki farkı (artık) öğrenmesini gerektirir, böylece daha karmaşık fonksiyonların öğrenilmesi kolaylaşır.

ResNet mimarisi, temelde üç ana katman türünden oluşur: evrişimli katmanlar, kimlik kısayol bağlantıları ve tam bağlı katmanlar. Evrişimli katmanlar, görüntü ve diğer yüksek boyutlu veri türlerinden özellikler çıkarmak için kullanılırken, kimlik kısayol bağlantıları bu özelliklerin derin ağ yapısında bozulmadan iletilmesini sağlar. Ağın sonunda yer alan

tam bağı katmanlar ise, çıkarılan özellikleri kullanarak sınıflandırma veya diğer görevler için sonuçlar üretir (He ve ark., 2016). ResNet mimarisine ait görsel Şekil 3.23'te yer almaktadır.



Şekil 3.23. ResNet mimarisi görünümü (Reith & Wandell, 2019)

ResNet'in farklı varyasyonları, katman sayısına göre adlandırılır. Örneğin, ResNet-50, ResNet-101 ve ResNet-152 modelleri sırasıyla 50, 101 ve 152 katmana sahiptir. Bu modeller, yapılandırmalarına göre çeşitli hesaplama yükleri ve performans özellikleri göstermektedir.


3.2.3. Derin Öğrenme ile Gürültü Giderme

2014 yılından bu yana, derin ağlar gerçek dünyadaki görüntü uygulamalarında, yüz tanıma ve tıbbi tanı gibi alanlarda yaygın olarak kullanılmaktadır (Hu ve ark., 2015) (Li ve ark., 2014). Gürültülü görüntülerin temizlenmesinde yeterli olmadıklarından, derin evrişimli sinir ağları (CNN) bu tür görüntü uygulamalarında zayıf performans gösterebilmektedir. Bu kapsamda, Generative Adversarial Networks (GAN) ve Denoising Convolutional Neural Networks (DnCNN) gibi yenilikçi derin öğrenme yaklaşımları öne çıkmaktadır.

3.2.4. Generative Discriminative Networks (GAN)

GAN'ler, 2014 yılında Goodfellow ve ark., tarafından önerilen bir modeldir (Goodfellow ve ark., 2014). İki temel bileşenden oluşur: üretici (generator) ve ayırt edici (discriminator). Üretici, gerçekçi sahte görüntüler üretirken, ayırt edici bu sahte görüntüleri gerçek olanlardan ayırt etmeye çalışır. Bu iki ağ arasındaki rekabetçi süreç, modelin zamanla daha gerçekçi görüntüler üretmesini sağlar. GAN'ler, özellikle yüksek detay ve gerçekçilik gerektiren görüntü iyileştirme ve üretim görevlerinde başarılı

sonuçlar vermektedir (Radford ve ark., 2015). Ek eğitim örnekleri oluşturma yeteneği sayesinde, karmaşık gürültülü görüntü temizleme gibi küçük örnek içeren görevlerde oldukça etkilidir (Chen ve ark., 2018). GAN'ın ağ yapısı Şekil 3.24'te gösterilmektedir.




Şekil 3.24.GAN ağının mimari yapısı (Zhu ve ark., 2022)

GAN'lar görüntüler üzerindeki gürültülerin giderilmesine örnek olarak Gauss gürültüsünün temizlenmesinde kullanılmaktadır (Zhu ve ark., 2022). Tıbbi görüntüleme alanında, eğitim veri kümelerinin genellikle sınırlı ve hastalıklı sınıfa ağır basması gibi zorlukları aşmak için kullanılmıştır (Jeong ve ark., 2022). GAN ağının geliştirilmesiyle farklı ağ modelleri de kullanılarak görüntüler üzerindeki Blind Denoising (kör gürültü) gibi gürültülerin giderilmesi de sağlanmaktadır (Cha ve ark., 2021).

3.2.5. Denoising Convolutional Neural Networks (DnCNN)

DnCNN, derin konvolüsyonel sinir ağlarının gürültü giderme için özelleştirilmiş bir versiyonudur. Zhang ve ark. (2017) tarafından geliştirilen bu model, doğrudan gürültülü görüntüden gürültüyü çıkarmak için eğitilmiştir (Zhang ve ark., 2017). DnCNN, farklı düzeylerde gürültü giderme işlemlerini gerçekleştirebilen bir ağ yapısı kullanır ve genellikle daha hızlı ve daha az karmaşık bir süreç sunmuştur. Bu model, özellikle düşük işlem süresi ve yüksek performans gerektiren uygulamalarda tercih edilmektedir. Şekil 3.25'te DnCNN ağına ait mimari görülmektedir.



Şekil 3.25.DnCNN Ağ Mimarisi (Alawode ve ark., 2021)

DnCNN modelinin, Gaussian gürültüsü içeren görüntülerde geleneksel yöntemlere kıyasla daha iyi performans gösterdiği ve gürültüyü etkili bir şekilde azalttığı gösterilmiştir (Zhang ve ark., 2017).

3.2.6.FFDNet (Flexible and Fast Denoising Convolutional Neural Network)

FFDNet, (Esnek ve Hızlı Gürültü Giderme Konvolüsyonel Sinir Ağı) farklı gürültü seviyeleri için hızlı ve etkili bir çözüm sunan bir derin öğrenme modelidir. Giriş olarak gürültü seviyesi haritasını alabilir ve buna göre gürültü giderme işlemi yapabilmektedir. FFDNet derin öğrenme tekniklerini kullanır ve belirli gürültü seviyeleri için daha hızlı sonuçlar sağlamaktadır. Bu model, gerçek zamanlı video işleme ve mobil cihazlarda görüntü işleme gibi uygulama alanlarına sahiptir (Zhang ve ark., 2018).

3.2.7.IRCNN (Iterative Residual Convolutional Neural Network)

IRCNN, (İteratif Artık Konvolüsyonel Sinir Ağı), artıklı öğrenme ve iteratif çözüm stratejileri kullanarak görüntüler üzerinde bulunan gürültüleri azaltmaktadır. Bu yöntem, gürültü giderme işlemi adım adım iyileştirir. FFDNet'ten farklı olarak, IRCNN iteratif bir yaklaşım benimser ve gürültü giderme işlemi kademeli olarak gerçekleştirir. IRCNN, yüksek kaliteli fotoğrafçılık, güvenlik kameraları ve uydu görüntüleri gibi alanlarda kullanılmaktadır (Zhang ve ark., 2017).

3.2.8.MemNet (Multi-level MemNet)

MemNet, tam adıyla "Multi-level MemNet" (Çok Düzeyli MemNet), çok katmanlı hafıza ağları kullanarak görüntülerin detaylarını koruyarak gürültü giderme işlemi yapar. Bu yöntem, bellek blokları ile daha derin özellikler öğrenir ve gürültüyü azaltmaktadır.

IRCNN'den ağından farklı olarak, MemNet bellek blokları ile daha derin özellikler öğrenir ve daha karmaşık yapıların gürültüsünü etkili bir şekilde giderir. Yüksek çözünürlüklü görüntü işleme, tıbbi görüntülerde detay koruma ve gelişmiş fotoğraf düzenleme gibi alanlarda kullanılmaktadır (Tai ve ark., 2017).




4. MATERYAL VE YÖNTEM

Bu bölümde tezin ana konusu olan periyodik gürültünün giderilmesinde kullanılan ikili yöntemin geliştirilmesi, uygulanması ve sonuçların çıktıları yer alacaktır. Bölüm şu şekilde ilerleyecektir; periyodik gürültü tiplerinin görüntüler üzerinde tespit edilmesi, gerekli filtrelerin uygulanması, çıkan sonuçlara göre filtrenin güncellenmesi, derin öğrenme modelinin eğitilmesi ve eğitilen modele filtrelenmiş görüntülerin verilerek görüntüler üzerinde daha iyi bir sonuç elde edilmesi.


4.1. Periyodik Gürültü Tespiti, Gürültünün Giderilmesi ve DnCNN Modeli ile İyileştirme

Periyodik gürültü diğer gürültülerden farklı olarak frekans uzayında belirli tepe noktaları ile kendini göstermektedir. Bu tepe noktalarının tespit edilmesi gürültünün giderilmesinde önemli bir yer tutmaktadır. Literatüre baktığımızda yapılan çalışmalar genel bilgiler bölümünde belirttiğimiz gibi tek bir periyodik gürültü tipine ya da birkaçını temizlemeye yöneliktir. Bu temizleme işleminde tepe noktaları özel geliştirdiğimiz yöntemde frekans uzayında tepe noktaları otomatik olarak tespit edilip periyodik gürültünün tipi fark etmeksizin tepe noktalarının konumları alına bilmekte ve temizleme işlemi yapılabilmektedir. Temizleme işleminde de tiplerde uygulanan yöntemler neticesinde, saf periyodik gürültü ve şerit gürültüsü “Ortanca Filtresi” ile diğerleri “Çentik Filtresi” yöntemi ile daha iyi sonuçlar verdiği anlaşılmaktadır. Yapılan işlemleri detayları aşağıdaki gibidir.


Öncelikle gürültülerin Fourier dönüşümü sonucunda tepe noktalarının tespiti gerçekleşmiştir. Tepe noktalarının tespiti, periyodik gürültülerin frekans domaininde belirgin hale getirilmesi amacıyla kritik bir adımdır. Fourier dönüşümü, görüntü verisinin frekans bileşenlerine ayrılmasını sağlar ve periyodik bileşenler bu frekans uzayında tepe noktaları olarak görünür. Periyodik gürültü uygulanmış görüntüler ve bu görüntülerin frekans uzayında tespit edilen tepe noktaları aşağıda ki şekillerde detaylı bir şekilde görülmektedir. Tepe noktaları kırmızı daire ile işaretlenmiştir.




Şekil 4.1. Saf Çapraz periyodik gürültü eklenmiş görüntü ve fouier dönüşümü sonrasında frekans uzayındaki işaretlenmiş tepe noktaları




Şekil 4.2. Saf Dikey periyodik gürültü eklenmiş görüntü ve fouier dönüşümü sonrasında frekans uzayındaki işaretlenmiş tepe noktaları




Şekil 4.3. Saf Yatay periyodik gürültü eklenmiş görüntü ve fouier dönüşümü sonrasında frekans uzayındaki işaretlenmiş tepe noktaları




Şekil 4.4. Yarı periyodik gürültü eklenmiş görüntü ve fouier dönüşümü sonrasında frekans uzayındaki işaretlenmiş tepe noktaları



Şekil 4.5. Düşük Frekanslı periyodik gürültü eklenmiş görüntü ve fouier dönüşümü sonrasında frekans uzayındaki işaretlenmiş tepe noktaları



Şekil 4.6. Yüksek Frekanslı periyodik gürültü eklenmiş görüntü ve fouier dönüşümü sonrasında frekans uzayındaki işaretlenmiş tepe noktaları



Şekil 4.7. Çok Frekanslı (multi) periyodik gürültü eklenmiş görüntü ve fouier dönüşümü sonrasında frekans uzayındaki işaretlenmiş tepe noktaları

Tepe noktalarının tespiti, hangi frekans bileşenlerinin gürültü içerdiğini belirlememize yardımcı olur. Bu sayede, sadece bu frekans bileşenlerini hedef alarak gürültü temizleme işlemini daha etkili bir şekilde gerçekleştirebiliriz. Fourier dönüşümü kullanılarak görüntünün frekans uzayında elde edilir ve tepe noktaları tespit edilir. Bu noktalar, periyodik gürültülerin yerini belirler. Tepe noktalarının tespiti belirli bir eşik değeri kullanılarak gerçekleştirilir ve merkezi hariç tutarak sadece çevresel tepe noktaları hedef alınır. Fourier dönüşümüne ilişkin (3.18) numaralı denklem kullanılmaktadır.

Fourier dönüşümü sonucunda elde edilen kompleks sayıların genlik spektrumu, mutlak değer fonksiyonu kullanılarak hesaplanır:

$$Genlik(u, v) = \sqrt{Re(F(u, v))^2 + Im(F(u, v))^2} \quad (4.1)$$

Burada, $Re(F(u, v))$ ve $Im(F(u, v))$, sırasıyla Fourier dönüşümünün gerçek ve hayali bileşenlerini temsil eder. Genlik spektrumu, $Genlik(u, v)$ ile ifade edilir. Genlik spektrumundaki tepe noktalarını belirlemek için bir eşik değeri kullanılır. Bu eşik değeri, genlik spektrumunun maksimum değerinin belirli bir oranı olarak hesaplanır:

$$Eşik = 0.78 \times \max(Genlik(u, v)) \quad (4.2)$$

Burada 0.78 çarpanı deneysel olarak belirlenmiş bir değerdir ve tepe noktalarını belirlemek için uygun bir eşiği temsil eder. Genlik spektrumundaki her bir piksel, eşik değeri ile karşılaştırılır. Eşik değerini aşan ve merkezi bölgenin dışındaki noktalar tepe noktası olarak kabul edilir. Merkezi bölgenin dışındaki noktalar, belirli bir yarıçap

kullanılarak belirlenir. Bu işlem, aşağıdaki matematiksel denklemler kullanılarak gerçekleştirilir:

$$Merkez = \left(\frac{Satır\ Sayısı}{2}, \frac{Sütun\ Sayısı}{2} \right) \quad (4.3)$$

$$Mesafe = \sqrt{(i - Merkez_{satır})^2 + (j - Merkez_{sütun})^2} \quad (4.4)$$

Eğer $Genlik(u, v) \geq$ eşit ve mesafe > hariç tutma yarıçapı ise, (i, j) tepe noktası olarak kabul edilir. Burada “hariç tutma yarıçapı” merkezi bölgenin hariç tutulmasını sağlayan bir parametredir. Yukarıdaki kriterleri sağlayan noktalar, tepe noktaları olarak bir listeye eklenir ve sonuç olarak döndürülür.

Tepe noktaları tespit edildikten sonra, merkezde yer alan tepe noktaları temizleme işlemine dahil edilmez. Bu işlemler tamamlandıktan sonra, tespit ettiğimiz tepe noktalarına çentik filtre uygulamaya başlanır. Çentik filtresi (notch filter), belirli bir yarıçap (r) içindeki frekans bileşenlerini sıfırlar. Çentik filtresi, görüntüdeki belirli frekans bileşenlerini yok ederek, periyodik gürültüyü ortadan kaldırmayı amaçlar. Filtreleme işlemi matematiksel olarak şöyle ifade edilir:

$$F(u, v) = \begin{cases} 0 & \text{if } \sqrt{(u - u_0)^2 + (v - v_0)^2} \leq r \\ F(u, v) & \text{diğer durumlarda} \end{cases} \quad (4.5)$$

Burada (u_0, v_0) çentik filtresinin merkezi ve $F(u, v)$ filtrelenmiş frekans bileşenlerini temsil eder. Ayrıca, her bir tepe noktasının simetriği olan noktalara da çentik filtresi uygulanır. Bu, simetrik frekans bileşenlerinin de sıfırlanmasını sağlar ve daha etkili bir gürültü azaltma işlemi gerçekleştirir. Filtrelenmiş frekans bileşenleri, ters Fourier dönüşümü (F^{-1}) kullanılarak yeniden uzay alanına aktarılır. Ters Fourier aşağıdaki denklemle yapılabilmektedir:

$$\hat{I}(x, y) = F^{-1}\{F(u, v)\} = \frac{1}{MN} \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} F(u, v) e^{j2\pi(\frac{ux}{M} + \frac{vy}{N})} \quad (4.6)$$

Burada $\hat{I}(x, y)$ filtrelenmiş görüntüyü ifade etmektedir. Çentik filtresi uygulaması, sonrasında filtrelenen görüntülerin kalitesini değerlendirmek için PSNR ve Yapısal Benzerlik İndeksi (SSIM) kullanılmıştır.

PSNR, orijinal ve işlenmiş görüntüler arasındaki farkı değerlendiren bir metriktir. PSNR, Mean Squared Error (MSE) değerine dayanarak hesaplanır ve birim olarak desibel (dB)

cinsinden ifade edilir. MSE, iki görüntü arasındaki ortalama karesel farkı temsil eder. PSNR'nin hesaplanması şu şekilde gerçekleştirilir:

İlk olarak, orijinal görüntü (I) ve temizlenmiş ($\hat{I}$) görüntüler arasındaki ortalama karesel (MSE) hesaplanır:

$$MSE = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} [I(x, y) - \hat{I}(x, y)]^2 \quad (4.7)$$

Burada M ve N , görüntülerin boyutları temsil etmektedir. MSE değerine dayanarak PSNR şu formülle hesaplanır:

$$PSNR = 10 \log_{10} \left(\frac{MAX^2}{MSE} \right) \quad (4.8)$$

Burada MAX, görüntüdeki maksimum piksel değerleridir (genellikle 255). MSE'nin 0 olduğu durumlarda, PSNR değeri sonsuz (∞) olarak kabul edilir. Python fonksiyonunda bu hesaplama şu şekilde gerçekleştirilmiştir:

```
def mse(image1, image2):
    # İki görüntü arasındaki farkın karelerinin ortalamasını hesapla
    err = np.sum((image1.astype("float") - image2.astype("float")) ** 2)
    err /= float(image1.shape[0] * image1.shape[1])
    return err

def psnr(image1, image2):
    # MSE değerini hesapla
    mse_value = mse(image1, image2)

    # PSNR hesapla
    if mse_value == 0:
        # İki görüntü tamamen aynı ise PSNR sonsuz olur
        return float('inf')

    max_pixel = 255.0
    psnr_value = 20 * np.log10(max_pixel / np.sqrt(mse_value))
    return psnr_value

def calculate_psnr(image1_path, image2_path):
    # Görüntüleri yükle
    img1 = cv2.imread(image1_path, cv2.IMREAD_GRAYSCALE)
    img2 = cv2.imread(image2_path, cv2.IMREAD_GRAYSCALE)

    # PSNR değerini hesapla
    psnr_value = psnr(img1, img2)

    return psnr_value

# Fonksiyonu test etmek için dosya yollarını kullan
psnr_result = calculate_psnr('path_to_original_image.jpg', 'path_to_compressed_image.jpg')
print(f"PSNR değeri: {psnr_result} dB")
```

Şekil 4.8. Python programlama dili ile PSNR değeri hesaplama yöntemi

SSIM, orijinal ve işlenmiş görüntüler arasındaki yapısal benzerliği ölçen bir metriktir. SSIM, luminans, kontrast ve yapısal benzerlik olmak üzere üç bileşen üzerinden

hesaplanır. SSIM, iki görüntü arasındaki farkları daha insan algısına uygun bir şekilde değerlendirmek için kullanılır. SSIM'in hesaplanması şu şekilde gerçekleştirilir:

Luminans (l): İki görüntünün ortalama parlaklık seviyeleri arasındaki farkı değerlendirir.

Kontrast (c): İki görüntünün kontrast seviyeleri arasındaki farkı değerlendirir.

Yapısal Benzerlik (s): İki görüntünün yapısal desenleri arasındaki benzerliği değerlendirir.

Bu bileşenler kullanılarak SSIM şu formülle hesaplanır:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (4.9)$$

Burada μ_x ve μ_y , orijinal ve temizlenmiş görüntülerin ortalama değerleridir. σ_x^2 ve σ_y^2 , orijinal ve temizlenmiş görüntülerin varyanslarıdır. σ_{xy} , orijinal ve temizlenmiş görüntülerin kovaryansıdır. C_1 ve C_2 istikrar sabitleridir. Python fonksiyonunda bu hesaplama şu şekilde gerçekleştirilmiştir:

```
# 2. SSIM hesaplama fonksiyonu
def calculate_ssim(original, compressed):
    ssim_value, _ = ssim(original, compressed, full=True, data_range=compressed.max() - compressed.min())
    return ssim_value
```

Şekil 4.9. Python programlama dili ile SSIM hesaplama yöntemi

Görüntüye FFT uygulanarak işlendikten sonra elde edilen PSNR değeri, görüntü kalitesini değerlendirmek için kullanılır. Elde edilen PSNR değeri 17 dB'nin altında ise, bu değer düşük kabul edilerek ek bir “Ortanca Filtresi” uygulanır.

Ortanca filtresi, her pikselin değerini, komşu piksellerin medyan değeri ile değiştirerek gürültüyü azaltır. Bu işlem, özellikle Tuz&Biber (salt and pepper) tipi gürültüyü etkin bir şekilde ortadan kaldırır. Ortanca Filtresi her pikselin değerini, 3x3 komşuluk bölgesindeki piksellerin medyan değeri ile değiştirir. Bu işlem şu şekilde ifade edilir:

$$\hat{I}(x, y) = \text{median} \{I(x + i, y + j) | i, j \in \{-1, 0, 1\}\} \quad (4.10)$$

burada, $\hat{I}(x, y)$, filtre uygulanmış görüntünün (temiz görüntünün) (x,y) koordinatındaki piksel değerini temsil eder. $I(x + i, y + j)$, orijinal görüntünün (x,y) pikselinin komşuluğundaki (i,j) koordinatındaki piksel değerini ifade eder. i ve j, -1, 0 veya 1 olabilir, bu da 3x3 bir komşuluk bölgesi oluşturur. median {}, bu komşuluk bölgesindeki

piksel değerlerinin ortancasını hesaplar. Örneğin, 3x3 bir komşuluk bölgesinde aşağıdaki piksel değerleri olduğunu varsayalım:

$$\begin{bmatrix} 100 & 150 & 200 \\ 50 & 100 & 150 \\ 0 & 50 & 100 \end{bmatrix}$$

Bu değerlerin medyanı 100'dür. Dolayısıyla bu komşuluk bölgesinin merkezindeki pikselin yeni değeri 100 olur.


Gürültülü görüntüye uygulanan “Ortanca (Median) Filtresi” neticesinde PSNR ve SSIM değerleri kontrol edilerek belirlenen eşiğin üstüne geçip geçmediği kontrol edilir ve işlem tamamlanır. Gürültülü görüntülerin tipinin belirlenmesi ve bunun sonucunda uygun filtrenin uygulanması sonucunda istatistiki olarak periyodik gürültü tiplerine adaptif bir yapı meydana getirmekteyiz. Bu sayede gürültünün giderilmesi konusunda otomatik bir yapı oluşturulmuştur. Bu yapı kullanılarak görüntülerde temizleme işlemi gerçekleştirilmiş. Temizlenmiş görüntüler incelendiğinde yöntemlerin PSNR değerleri yüksek olsa da görüntüler üzerinde temizlenmemiş veya görüntü yapısı neticesinde temizlenmesi zor alanlar yer almaktadır.

Periyodik gürültünün görüntüler üzerinde temizlenmesi istatistiksel yöntemler ile yapılabilmektedir. Bu konuda genel bilgiler başlığı altında detaylı bilgiler verilmiştir. Ancak bu temizleme işlemi yeterli olmamasından dolayı derin öğrenme kullanılarak eğitilen bir model ile temizlenmiş görsellerde iyileştirme yapılmaktadır. İyileştirme işlemi için DnCNN modeli kullanılmıştır. Bu modelin eğitim süreci, dikkatlice seçilmiş hiperparametreler ve optimize edilmiş eğitim prosedürleri ile gerçekleştirilmiştir.

4.1.1. Veri Seti

Eğitimi için 500 adet orijinal görsel olmak üzere periyodik gürültünün tiplerinden 5 tanesi kullanılarak (saf periyodik gürültünün toplamda 3 çeşidi de dahil edilmiş ve toplamda 7 çeşit periyodik gürültü oluşturulmuştur) hazırlanan sentetik periyodik gürültü algoritmaları kullanarak gürültülü görüntüler oluşturulmuştur. Ardından bu görüntüler yine hazırlamış olduğumuz uygulama yardımı ile istatistiksel olarak temizlenmiştir. Bütün bu işlemler sonucunda gürültü eklenip sonra temizlenmesi yapılan 3500 adet temizlenmiş görüntü ve 500 adet orijinal görüntüden oluşan toplamda 4000 adet

görüntüden oluşan veri seti hazırlanmıştır. Harici olarak görüntülerin test edilmesi için her bir gürültü tipinden toplamda 700 adet test görüntüsü hazırlanmıştır. Hazırlanan veri seti hazırlanan DnCNN modeline girdi olarak verilmiştir. Model eğitimi için hazırlanan veri setine ilişkin örnek görseller Şekil 4.10’da yer almaktadır.





Şekil 4.10. Veri setinde kullanılan periyodik gürültülü görüntülere ait bir kesit

4.1.2.Ön İşleme ve Model Eğitimi

Ön işleme ve model eğitimi için kullanılan donanım ve yazılımlara ait bilgiler şu şekildedir: Eğitim sırasında, Intel(R) Core(TM) i5-13450HX 2.40 GHz CPU kullanılmıştır. Bu işlemci, 2.40 GHz hızında çalışmakta olup 8 çekirdeğe sahiptir. Sistem, 8 GB RAM kapasitesine sahiptir ve grafik işlemleri için NVIDIA GeForce RTX 3050 6GB Laptop GPU kullanılmıştır. CUDA sürümü olarak V12.5.40 kullanılmıştır. Eğitim için kullanılan yazılım ise Anaconda yazılımı üzerinden Python dili kullanılarak model eğitimi gerçekleştirilmiştir. Bu donanım ve yazılım bileşenleri, modelin eğitimi ve test edilmesi için uygun bir ortam sağlamaktadır.

Bu güçlü donanım altyapısı, DnCNN modeli gibi derin öğrenme tabanlı modellerin verimli bir şekilde çalıştırılması ve eğitilmesi için gerekli kaynakları sağlamaktadır. DnCNN modeli, giriş görüntüsünde bulunan gürültü bileşenlerini tahmin etmeyi

amaçlayan bir regresyon problemine odaklanır. Bu süreç, modelin girdi olarak aldığı görüntüden gürültü bileşenlerini öğrenmesini ve doğru bir şekilde ayırt etmesini sağlar. Gürültüyü tahmin etmek için kullanılan denklem (4.11), modelin tahmin edilen gürültü bileşeni ile gerçek gürültü bileşeni arasındaki farkı minimize etmeye odaklanır, bu da modelin doğruluğunu artırır ve gürültü giderme performansını optimize eder.

$$\hat{A}(x, y) = \frac{I(x, y)}{R(x, y)} \quad (4.11)$$

Burada $I(x, y)$ gürültülü görüntüyü, $R(x, y)$ tahmin edilen gürültüyü ve $\hat{A}(x, y)$ orijinal görüntünün tahminini temsil eder. Bu yaklaşım, gürültüyü doğrudan tahmin etmeye çalışmak yerine, orijinal ve gürültülü görüntüler arasındaki farkı öğrenmeyi hedeflediği için daha etkili bir gürültü giderme sağlar.

DnCNN modelinin mimarisini oluştururken, üç ana katman tipi dikkatle yapılandırılmıştır:

İlk Katman (Input Layer) Konvolüsyon Katmanı: İlk katman, 3x3 boyutunda 64 filtre içerir ve ReLU (Rectified Linear Unit) aktivasyon fonksiyonu uygulanır. Bu katman, giriş görüntüsündeki temel özellikleri çıkartarak, sonraki katmanların daha karmaşık ilişkileri öğrenmesine zemin hazırlar. Özellikle kenar algılama gibi düşük seviyeli özellikleri çıkarır. ReLU aktivasyonu, negatif değerleri sıfıra çekerken pozitif değerleri olduğu gibi korur, bu da modele doğrusal olmayan bir özellik kazandırarak, modelin daha karmaşık veri ilişkilerini öğrenmesini sağlar. Bu aşama, modelin temel bilgi setini oluşturur ve sonraki katmanlara ham veri yerine işlenmiş bir temsil iletir.

Ara Katmanlar (Intermediate Layers):

Konvolüsyon Katmanları: Ara katmanlarda, yine 3x3 boyutunda 64 filtre kullanılır. Bu katmanlar modelin derinliğini artırarak, daha karmaşık ve çok boyutlu özellikleri öğrenmesini sağlar.

Batch Normalization (BN): Her konvolüsyon katmanının ardından Batch Normalization uygulanır. BN, eğitim sürecini hızlandırmak ve modelin genelleme yeteneğini artırmak için mini-batch'ler üzerinde girişleri normalize eder. Bu işlem, modelin farklı veri dağılımlarına karşı daha dayanıklı olmasını sağlar ve eğitim sırasında katmanlar arasındaki verilerin daha tutarlı olmasına yardımcı olur.

ReLU Aktivasyon Fonksiyonu: Her BN katmanından sonra tekrar ReLU aktivasyon fonksiyonu uygulanır. Bu katman dizisi, modelin doğrusal olmayan ilişkileri daha iyi öğrenmesini sağlar ve modelin karmaşıklığını artırarak, daha iyi bir gürültü giderme (denoising) performansı sunar. Bu 18 ara katman, modelin giriş görüntüsündeki gürültüyü etkili bir şekilde temizlemesi için gerekli olan derin öğrenme kapasitesini sağlar.

Son Katman (Output Layer) Konvolüsyon Katmanı: Modelin son katmanında, yine 3x3 boyutunda ancak bu kez görüntünün kanal sayısına (genellikle 3; RGB kanalları için) eşit sayıda filtre bulunur. Bu katman, giriş görüntüsünden gürültüyü temizleyerek, nihai temizlenmiş (denoised) görüntüyü üretir. Bu katmanın görevi, ara katmanlardan gelen karmaşık özellik haritalarını birleştirip, çıkışta orijinal görüntü boyutlarında ve kanal sayısında bir çıktı oluşturmaktır.

Bu mimari yapı, modelin hem giriş görüntüsündeki detayları korumasını hem de etkin bir şekilde gürültüyü azaltmasını sağlamıştır. Model girdiği her aşamada daha karmaşık ve yüksek seviyeli özellikleri öğrenirken, çıktıda orijinal görüntüyü mümkün olan en temiz haliyle yeniden oluşturmaya odaklanır.

Özetlemek gerekirse DnCNN modelinde toplamda 20 katman bulunmaktadır: 1 giriş katmanı, 18 ara katman ve 1 çıkış katmanı. Giriş katmanı, 3x3 konvolüsyon ve ReLU aktivasyonu içerirken ara katmanlar 3x3 konvolüsyon Batch Normalization (BN) ve ReLU aktivasyonundan oluşur. Son olarak çıkış katmanı 3x3 konvolüsyon içerir. Bu yapı modelin girdi görüntüsünü işleyip temizlenmiş (denoised) görüntüyü üretmesine olanak tanır.



Şekil 4. 11. Hazırlanan DnCNN modeline ait mimari görünümü

Modelin eğitim sürecinde kullanılan hiperparametreler, modelin performansını en üst düzeye çıkarmak amacıyla özenle seçilmiş ve optimize edilmiştir. Eğitim süreci, modelin toplamda 100 epoch boyunca eğitilmesiyle gerçekleştirilmiştir. Her epoch'ta, tüm eğitim veri seti modele bir kez sunularak, modelin tüm veri üzerinde bir tam geçiş yapması

sağlanmıştır. Bu süreç, modelin veriyi tam olarak öğrenmesine olanak tanıyarak, modelin her bir veri örneği üzerinde kapsamlı bir şekilde çalışmasını mümkün kılmıştır.

Eğitim sırasında batch boyutu 64 olarak belirlenmiştir. Bu, modelin her adımda küçük gruplar halinde veriyi işlemeyi öğrenmesine yardımcı olmuş, böylece hem bellek kullanımı optimize edilmiş hem de modelin öğrenme süreci dengelenmiştir. Ayrıca, başlangıç öğrenme oranı 0.001 olarak ayarlanmıştır. Öğrenme oranı, modelin ağırlıklarını güncelleme hızını belirler ve bu değer, eğitim sürecinde modelin doğru şekilde öğrenmesine olanak tanır. Epoch'lar ilerledikçe öğrenme oranı kademeli olarak azaltılmış, bu sayede model, başlangıçta hızlı bir şekilde öğrenirken, sonlara doğru daha hassas ayarlarla ince öğrenme yaparak daha stabil hale gelmiştir.

Eğitim sürecinde modelin genelleme kabiliyetini artırmak amacıyla çeşitli veri artırma teknikleri de uygulanmıştır. Bu teknikler arasında görüntülerin rastgele döndürülmesi, ölçeklendirilmesi, yatay ve dikey çevrilmesi ve parlaklıklarının değiştirilmesi gibi işlemler yer almıştır. Bu sayede model, eğitim sırasında daha çeşitli veri örnekleri ile karşılaşmış, bu da gerçek dünya verileri üzerinde daha iyi performans göstermesini sağlamıştır. Bu eğitim stratejileri ve dikkatle seçilen hiperparametreler, DnCNN modelinin daha stabil, hızlı ve etkili bir şekilde öğrenmesini sağlamış, sonuç olarak modelin gürültü azaltma performansı optimize edilmiş ve gerçek dünya senaryolarında daha yüksek başarı oranları elde edilmiştir. Kayıp fonksiyonu olarak, tahmin edilen gürültü ile gerçek gürültü arasındaki ortalama kare hatasını (MSE) minimize etmeyi hedefledik. Kayıp fonksiyonu şu şekilde tanımlandı:


$$L(\theta) = \frac{1}{2N} \sum_{i=1}^N \|R(I_i; \theta) - (I_i - A_1)\|_F^2 \quad (4.12)$$

Burada N , orijinal ve gürültülü görüntü çiftlerinden oluşan seti temsil eder ve θ ağırlık öğrenilebilir parametreleridir. Optimizasyon süreci için Adam optimizasyon algoritmasını kullandık. Adam algoritması, adaptif öğrenme oranları kullanarak daha hızlı ve stabil bir optimizasyon süreci sağlamıştır (Güneş & Kaya, 2024).


Eğitim sürecinin ardından modeli, çeşitli test görüntüleri üzerinde değerlendirdik. Performans metrikleri olarak PSNR ve SSIM kullandık. Bu metrikler, modelin hem gürültü azaltma kabiliyetini hem de görüntü detaylarını koruma performansını ölçmek için kullanıldı. Sonuçlar, DnCNN modelinin görüntüler üzerindeki problemleri etkili bir


şekilde azaltırken, periyodik gürültülerin temizlenmesi sonrasında kalan eksiklikleri başarılı bir şekilde giderdiği görülmektedir.

Eğitim sonucunda yapılan testlere ilişkin görüntüler aşağıda görülmektedir.




Şekil 4.12. a) Orijinal görüntü b) Düşük frekans periyodik gürültü eklenmiş görüntü c) İstatistiksel temizleme (Çentik filtre) yöntemi ile temizlenmiş gürültülü görüntü, d) Eğitilmiş DnCNN (Denoising Convolutional Neural Network) modeli ile temizlenmiş görüntü.







Şekil 4.13. a) Orijinal görüntü b) Yüksek frekans periyodik gürültü eklenmiş görüntü c) İstatistiksel temizleme (Çentik filtre) yöntemi ile temizlenmiş gürültülü görüntü d) Eğitilmiş DnCNN (Denoising Convolutional Neural Network) modeli ile temizlenmiş görüntü.




Şekil 4.14. a) Orijinal görüntü b) Çok frekanslı (multi) periyodik gürültü eklenmiş görüntü c) İstatistiksel temizleme (Çentik filtre) yöntemi ile temizlenmiş gürültülü görüntü d) Eğitilmiş DnCNN (Denoising Convolutional Neural Network) modeli ile temizlenmiş görüntü.




Şekil 4. 15. a) Orijinal görüntü b) Yarı periyodik (quasi) gürültü eklenmiş görüntü c) İstatistiksel temizleme (Çentik filtre) yöntemi ile temizlenmiş gürültülü görüntü d) Eğitilmiş DnCNN (Denoising Convolutional Neural Network) modeli ile temizlenmiş görüntü.






Şekil 4. 16. a) Orijinal görüntü b) Saf çapraz periyodik gürültü eklenmiş görüntü c) İstatistiksel temizleme (Ortanca filtre) yöntemi ile temizlenmiş gürültülü görüntü d) Eğitilmiş DnCNN (Denoising Convolutional Neural Network) modeli ile temizlenmiş görüntü.



Şekil 4.17. a) Orijinal görüntü b) Saf dikey periyodik gürültü eklenmiş görüntü c) İstatistiksel temizleme (Ortanca filtre) yöntemi ile temizlenmiş gürültülü görüntü, d) Eğitilmiş DnCNN (Denoising Convolutional Neural Network) modeli ile temizlenmiş görüntü.



Şekil 4.18. a) Orijinal görüntü b) Saf yatay periyodik gürültü eklenmiş görüntü c) İstatistiksel temizleme (Ortanca filtre) yöntemi ile temizlenmiş gürültülü görüntü d) Eğitilmiş DnCNN (Denoising Convolutional Neural Network) modeli ile temizlenmiş görüntü.

Tablo 1.1’de sunulan veriler, İstatistiksel Temizleme ve DnCNN modelinin çeşitli gürültü tipleri karşısında performanslarını karşılaştırmak amacıyla PSNR ve SSIM metrikleri kullanılarak analiz edilmiştir. Sonuçlar, DnCNN modelinin her tür gürültü temizlemede İstatistiksel Temizleme yöntemine kıyasla daha üstün olduğunu göstermektedir. Bu üstünlük, özellikle yapısal benzerlik indeksindeki belirgin artış ve PSNR oranındaki iyileşmelerle belirginleşmektedir. DnCNN modeli, saf çapraz, dikey ve yatay gürültü türlerinden düşük ve yüksek frekans gürültülerine kadar geniş bir yelpazede, daha yüksek görüntü kalitesi ve yapısal bütünlük sağlayarak gürültüyü daha etkin bir şekilde temizlemektedir. Bu da DnCNN modelinin, gürültü temizleme görevlerinde daha güvenilir ve tercih edilebilir bir yöntem olduğunu kanıtlamaktadır.

Tablo 1. Basketbol oynayanlara ait gürültülü görüntülerin istatistiksel olarak temizlenmesi sonrasında ve DnCNN modeli ile iyileştirilmesi sonrasında PSNR ve SSIM değerleri

	İstatistiksel Temizleme		DnCNN Modeli ile Temizleme	
Gürültü Tipi	PSNR	SSIM	PSNR	SSIM
Saf Çapraz	30,5	0,75	33,39	0,88
Saf Dikey	31,41	0,78	33,92	0,91
Saf Yatay	32,44	0,8	33,86	0,91
Yarı	18	0,65	29,62	0,75
Düşük Frekans	23,15	0,78	34,07	0,91
Çok Frekanslı (Multi)	17	0,74	31,73	0,83
Yüksek	23,27	0,81	33,93	0,91

Tablo 2. Kameraman görüntüsüne ait gürültülü görüntülerin istatistiksel olarak temizlenmesi sonrasında ve DnCNN modeli ile iyileştirilmesi sonrasında PSNR ve SSIM değerleri

	İstatistiksel Temizleme		DnCNN Modeli ile Temizleme	
Gürültü Tipi	PSNR	SSIM	PSNR	SSIM
Saf Çapraz	22,97	0,75	36,77	0,96
Saf Dikey	27,63	0,76	37,04	0,96
Saf Yatay	27,61	0,76	36,89	0,96
Yarı	25,77	0,73	37,46	0,94
Düşük Frekans	22,98	0,68	37,10	0,95
Çok Frekanslı (Multi)	25,80	0,73	38,15	0,95
Yüksek	23,53	0,41	37,02	0,95

5. SONUÇ VE ÖNERİLER

Bu çalışmada, periyodik gürültünün istatistiksel olarak giderilmesi ve DnCNN modeli ile görüntü iyileştirmesi üzerine iki aşamalı bir yöntem geliştirilmiştir. Geliştirilen iki aşamalı model periyodik gürültülerin etkin bir şekilde giderilmesinde başarılı olmuş ve görüntü kalitesini önemli ölçüde artırmıştır. Çalışma DnCNN modeli ile frekans alanı filtreleme yöntemlerinin birleştirilmesiyle oluşturulan iki aşamalı modelin geleneksel yöntemlere kıyasla daha yüksek PSNR (Peak Signal-to-Noise Ratio) ve SSIM (Structural Similarity Index) değerlerine ulaştığını göstermiştir. Bu durum derin öğrenme yöntemlerinin özellikle DnCNN modelinin periyodik gürültüleri temizleme kapasitesinin oldukça yüksek olduğunu ve geleneksel yöntemlerin eksik kaldığı durumlarda bile üstün performans sergilediğini kanıtlamaktadır.

Çalışma boyunca elde edilen bulgular iki aşamalı modelin farklı türdeki periyodik gürültüler üzerinde etkili olduğunu ve çeşitli görüntü veri setleri üzerinde test edildiğinde tutarlı bir şekilde üstün performans gösterdiğini ortaya koymuştur. Geleneksel yöntemlerle karşılaştırıldığında iki aşamalı modelin periyodik gürültüleri daha etkili bir şekilde giderdiği ve bu sayede görüntülerin yapısal bütünlüğünü ve kalitesini koruduğu tespit edilmiştir.

Gelecek çalışmalar için farklı derin öğrenme modellerinin ve iki aşamalı yaklaşımların araştırılması önerilmektedir. Örneğin diğer ileri düzey derin öğrenme mimarileri ve transfer öğrenme teknikleri kullanılarak modelin performansı daha da artırılabilir. Ayrıca modelin gerçek zamanlı uygulamalarda kullanılabilirliğini artırmak amacıyla hesaplama verimliliğinin optimize edilmesi gerekmektedir. Bu özellikle yüksek çözünürlüklü görüntülerin işlenmesi ve büyük veri setleriyle çalışılması gereken durumlar için kritik öneme sahiptir.

Sonuç olarak bu tez çalışması dijital görüntü işlemede derin öğrenme tabanlı yöntemlerin potansiyelini ortaya koymakta ve periyodik gürültü giderme alanında önemli bir katkı sağlamaktadır. Geliştirilen iki aşamalı modelin üstün performansı bu yöntemin gelecekteki araştırmalar ve uygulamalar için güçlü bir temel oluşturduğunu göstermektedir. Periyodik gürültülerin etkin bir şekilde giderilmesi görüntü kalitesini ve doğruluğunu artırarak çeşitli bilimsel ve endüstriyel uygulamalarda daha güvenilir ve yüksek kaliteli sonuçlar elde edilmesine olanak tanıyacaktır.

6. KAYNAKLAR

- Abdulah, C. S., Rohani, M. N., Ismail, B., Isa, M. A., Rosmi, A. S. ve Mustafa, W. A., 2021. Comparison of Image Restoration Using Median, Wiener and Gaussian Filtering Techniques Based on Electrical Tree. 2021 IEEE Industrial Electronics and Applications Conference, IEACon), 163-168. doi: <https://doi.org/10.1109/IEACon51066.2021.9654752>
- Abu-Ein, A. A.-K., 2013. A Novel Methodology for Digital Removal of Periodic Noise Using 2D Fast Fourier Transforms. Contemporary Engineering Sciences, 103-116.
- Acito, N., Diani, M. ve Corsini, G., 2010. Subspace-Based Striping Noise Reduction in Hyperspectral Images. IEEE Transactions on Geoscience and Remote Sensing, 1325-1342. doi:<https://doi.org/10.1109/TGRS.2010.2081370>
- Afshari, H. H., Gadsden, A. ve Habibi S., 2017. Gaussian Filters For Parameter and State Estimation: A General Review of Theory and Recent Trends. Signal Processing, 218-238. doi:<https://doi.org/10.1016/j.sigpro.2017.01.001>
- Aghajarian, M. ve McInroy, J. E., 2022. Random Valued Impulse Noise Detection and Removal Based on Local Statistics of Images. International Journal of Advanced Computer Science and Applications, 1-8.
- Aghajarian, M., McInroy, J. E. ve Muknahallipatna S., 2020. Deep Learning Algorithm For Gaussian Noise Removal From Images. Journal of Electronic Imaginn, 29 (4), 043005-043005.
- Aizenberg, I. ve Butakoff, C., 2002. Frequency Domain Medianlike Filter For Periodic and Quasi-Periodic Noise Removal. In Image Processing: Algorithms and Systems, 181-191.
- Aizenberg, I. ve Butakoff, C., 2008, 10 1. A Windowed Gaussian Notch Filter For Quasi-Periodic Noise Removal. Image and Vision Computing, 1347-1353. doi:<https://doi.org/10.1016/j.imavis.2007.08.011>
- Ajith, K., Menaka, R. ve Kumar, S., 2021. EEG Based Mental State Analysis. Journal of Physics: Conference Series. Vol. 1911. No. 1. IOP Publishing. doi:10.1088/1742-6596/1911/1/012014
- Alawode, B. O., Masood, M., Ballal, T. ve Al-Naffouri, T., 2021. Dense-Sparse Deep CNN Training for Image Denoising. arXiv Preprint arXiv:2107.04857. doi:<https://doi.org/10.48550/arXiv.2107.04857>

- Alibabaie, N. ve Latif, A., 2021. Adaptive Periodic Noise Reduction in Digital Images Using Fuzzy Transform. *Journal of Mathematical Imaging and Vision*, 503-527.
- Alibabaie, N. ve Latif, A. M., 2021. Bio-inspired Computing Paradigm for Periodic Noise Reduction in Digital Images. *Journal of AI and Data Mining*, 9-29. doi:<https://doi.org/10.22044/jadm.2020.9358.2071>
- Alibabaie, N. ve Latif, A. M., 2021. Self-learning based image decomposition for blind periodic noise estimation: a dual-domain optimization approach. *Multidimensional Systems and Signal Processing*, 465-490. doi:<https://doi.org/10.1007/s11045-020-00738-9>
- Alolaiwy, M., Tanik, M. ve Jololian, L., 2021. From CNNs to Adaptive Filter Design for Digital Image Denoising Using Reinforcement Q-Learning. *SoutheastCon*, 1-8.
- Altunok, M. ve Turan, B., 2022. Periyodik Gürültü Tipleri ve Yapısal Özellikleri. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 15(2), 140-150.
- Amidi, A. ve Amidi S., 2023. Derin Öğrenme El Kitabı. Stanford. <https://stanford.edu/~shervine/l/tr/teaching/cs-229/cheatsheet-deep-learning>; (05.01.2024)
- Amidi, A. ve Amidi S., 2023. Evrişimli Sinir Ağları el kitabı. Stanford. <https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-convolutional-neural-networks>; (05.03.2024)
- Boyat, A. K. ve Brijendra, K. J., 2015. A review paper: noise models in digital image processing. *Signal & Image Processing : An International Journal*, 63-75.
- Cao, C., Dai, K., Hong ve Zhang, M., 2021. Anisotropic total variation model for removing oblique stripe noise in remote sensing image. *Optik*. doi:<https://doi.org/10.1016/j.ijleo.2020.165254>
- Cao, F., Yao, K. ve Liang, J., 2020. Deconvolutional neural network for image super-resolution. *Neural Networks* 132, 394-404.
- Cao, W., Chang, Y., Han, G. ve Li, J., 2018. Destriping Remote Sensing Image via Low-Rank Approximation and Nonlocal Total Variation. *IEEE Geoscience and Remote Sensing Letters*, 848-852. doi:10.1109/LGRS.2018.2811468
- Carvalho, Â., Esteves, T., Quelhas, P. ve Monteiro, F. J., 2018. MobilityAnalyser: A novel approach for automatic quantification of cell mobility on periodic patterned substrates using brightfield microscopy images. *Computer methods and programs in biomedicine*, 61-67. doi:<https://doi.org/10.1016/j.cmpb.2018.05.003>
- Cha, S, Park, T., Kim, B., Baek, J. ve Moon, T., 2021. GAN2GAN: Generative Noise Learning for Blind Denoising with Single Noisy Images. *arXiv preprint*. doi:<https://doi.org/10.48550/arXiv.1905.10488>

- Chandel, R. ve Gupta, G., 2013. Image Filtering Algorithms and Techniques: A Review. *International Journal of Advanced Research in Computer Science and Software Engineering* , 198-202.
- Chang, Y., Yan, L., Wu, T. ve Zhong, 2016. Remote Sensing Image Stripe Noise Removal: From Image Decomposition Perspective. *IEEE Transactions on Geoscience and Remote Sensing*, 7018-7031. doi:10.1109/TGRS.2016.2594080
- Chen, H., Gu, J., Liu, Y., Magid, A., Dong, C., Wang, Q. ve Pfister, H., 2023. Masked Image Training for Generalizable Deep Image Denoising. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 1692-1703.
- Chen, J., Chen, J., Chao, H. ve Yang, M., 2018. Image Blind Denoising with Generative Adversarial Network Based Noise Modeling. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 3155-3164. doi:10.1109/CVPR.2018.00333
- Chen, W. ve Li, B., 2023. Overcoming Periodic Stripe Noise in Infrared Linear Array Images: The Fourier-Assisted Correlative Denoising Method. *Sensors*, 8716.
- Chen, Y., Huang, T.-Z., Zhao, X.-L., Deng, L.-J. ve Huang, J., 2017. Stripe noise removal of remote sensing images by total variation regularization and group sparsity constraint. *Remote sensing*, 559.
- Chowanda, A. ve Sutoyo, R., 2019. Convolutional neural network for face recognition in mobile phones. *ICIC Express Letters* 13/7, 569-574.
- Deng, J. ve Hu, C., 2024. Recovering a clean background: a new progressive multi-scale CNN for image denoising. *Signal Image and Video Processing*, 1-12.
- Dutta, , Mallick, A., Roy, ve Kumar, U., 2014. Periodic noise recognition and elimination using RFPCM clustering. In *2014 International Conference on Electronics and Communication Systems, ICECS*), 1-5.
- Erkan, U., Thanh, D. N., Hieu, L. M. ve Enginoğlu, , 2019. An Iterative Mean Filter for Image Denoising. *IEEE Access* 7, 167847-167859. doi:https://doi.org/10.1109/ACCESS.2019.2953924
- Erol, A., Gürbüz, M. E. ve Gangal, A., 2016. Video Görüntülerindeki Periyodik Gürültülerin Yok Edilmesi. *Researchgate*, 535-537.
- Fajardo-Delgado, D., Rodríguez-González, A., Sandoval-Pérez, Molinar-Solís, J. E. ve Sanchez Cervantes, M., 2024. Genetic Programming to Remove Impulse Noise in Color Images. *Genetic Programming to Remove Impulse Noise in Color Images. Applied Sciences*, 126.

- Fan, L., Zhang, F., Fan, H. ve Zhang, C., 2019. Brief review of image denoising techniques. *Visual Computing for Industry, Biomedicine and Art*, 2-7. doi:<https://doi.org/10.1186/s42492-019-0016-7>
- Fehrenbach, J., Weiss, P. ve Lorenzo, C., 2012. Variational algorithms to remove stationary noise: applications to microscopy imaging. *IEEE transactions on image processing*, 4420-4430. doi:10.1109/TIP.2012.2206037
- Gardner, M. W. ve Dorling, R., 1998. Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric Environment* 32/14-15, 2627-2636. doi:[https://doi.org/10.1016/S1352-2310\(97\)00447-0](https://doi.org/10.1016/S1352-2310(97)00447-0)
- Gonzalez, R. ve Woods, R., 2008. *Digital Image Processing*. New Jersey: Pearson Education, Inc.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair. ve Bengio, Y., 2014. Generative Adversarial Networks. *Advances in neural information processing systems* 27, 138-144. doi:<https://doi.org/10.48550/arXiv.1406.2661>
- Guan, J., Rui, L. ve Xiong, A., 2019. Wavelet deep neural network for stripe noise removal. *IEEE Access* 7, 44544-44554. doi:<https://doi.org/10.1109/ACCESS.2019.2908720>
- Guttman, N. ve Julesz, B., 1963. Lower limits of auditory periodicity analysis. *journal of the Acoustical Society of America*, 610. doi:<https://doi.org/10.1121/1.1918551>
- Güneş, A. ve Kaya, Y. Ç., 2024. Evrişimsel Sinir Ağları ile Görüntülerde Gürültü Türünü Saptama. *Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 17(1), 75-89.
- Han, X., Zhong, Y., Liqin, C. ve Zhang, L., 2017. Pre-trained alexnet architecture with pyramid pooling and supervision for high spatial resolution remote sensing image scene classification. *Remote Sensing* 9/8, 848. doi:<https://doi.org/10.3390/rs9080848>
- Hiremath, S. ve Rani, A., 2020. A Concise Report on Image Types, Image File Format and Noise Model for Image Preprocessing. *International Research Journal of Engineering and Technology*, 4991-4997.
- Hu, G., Yang, Y., Yi, D., Kittler, J., Christmas, W., Li, Z. ve Hospedales, T., 2015. When Face Recognition Meets With Deep Learning: An Evaluation of Convolutional Neural Networks for Face Recognition. *Proceedings of the IEEE international conference on computer vision workshops*, 142-150.
- İnik, Ö. ve Turan, B. 2018. Classification of animals with different deep learning models. *Journal of New Results in Science*, 7(1), 9-16.

- İnik, Ö. ve Turan, B. 2018. Classification of different age groups of people by using deep learning. *Journal of New Results in Science*, 7(3), 9-16.
- İnik, Ö. ve Ülker, E., 2017. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi* 6 (3), 85-104.
- Ionita, M. G. ve Coanda, H. G., 2017. Automatic periodic noise removal in microscopy images. 2017 International Symposium on Signals, Circuits and Systems, ISSCS), 1-4. doi:<https://doi.org/10.1109/ISSCS.2017.8034894>
- Jeong, J. J., Tariq, A., Adejumo, T., Trivedi, H., Gichoya, J. W. ve Banerjee, I., 2022. Systematic Review of Generative Adversarial Networks, GANs) for Medical Image Classification and Segmentation. *Journal of Digital Imaging* 35/2, 137-152. doi:<https://doi.org/10.1007/s10278-021-00556-w>
- Jin, F., Fieguth, P., Winger, L. ve Jernigan, E., 2003. Adaptive Wiener filtering of noisy images and image sequences. *Proceedings 2003 International Conference on Image Processing, Cat. No. 03CH37429*), 349-352. doi:<https://doi.org/10.1109/ICIP.2003.1247253>
- Kaiming H., X. Z., 2016. Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, CVPR*), 770-778.
- Kang, X., Li, Y. L., Qu, Z. ve Jiwu, H., 2011. Enhancing Source Camera Identification Performance With a Camera Reference Phase Sensor Pattern Noise. *IEEE Transactions on Information Forensics and Security*, 393-402. doi:<https://doi.org/10.1109/TIFS.2011.2168214>
- Kang, X., Li, Y., Qu, Z. ve Huang, J., 2012. Enhancing Source Camera Identification Performance With a Camera Reference Phase Sensor Pattern Noise. *IEEE Transactions on Information Forensics and Security*, 393-402. doi:<https://doi.org/10.1109/TIFS.2011.2168214>
- Karras, C., Karras, A., Tsolis, D., Avlonitis, M. ve Sioutas, S. 2022. A Hybrid Ensemble Deep Learning Approach for Emotion Classification. 2022 IEEE International Conference on Big Data, Big Data), 3881-3890. doi:<http://dx.doi.org/10.1109/BigData55660.2022.10020483>
- Kaya, M., Ulutürk, S., Kaya, Y. Ç., Altıntaş, O. ve Turan, B. 2023. Optimization of Several Deep CNN Models for Waste Classification. *Sakarya University Journal of Computer and Information Sciences*, 6(2), 91-104. doi: <https://doi.org/10.35377/saucis...1257100>
- Ketenci S. ve Gangal, A., 2012. Design of Gaussian star filter for reduction of periodic noise and quasi-periodic noise in gray level images. 2012 International

Symposium on Innovations in Intelligent Systems and Applications, 1-5. doi: 10.1109/INISTA.2012.6246937

- Ketenci S. ve Gangal, A., 2017. Automatic reduction of periodic noise in images using adaptive Gaussian star filter. *Turkish Journal of Electrical Engineering and Computer Sciences*, 2336-2348.
- Khan, A., Sohail, A., Zahoor, U. ve Qureshi, A. S., 2020. A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review* 53, 5455-5516. doi:<https://doi.org/10.1007/s10462-020-09825-6>
- Ko, J. ve Lee, S., 2023. Self2Self+: Single-Image Denoising with Self-Supervised Learning and Image Quality Assessment Loss. *arXiv preprint arXiv*.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012. ImageNet Classification with Deep Convolutional Neural Networks. *Advances in neural information processing systems* 25. doi:<https://doi.org/10.1145/3065386>
- Küpeli, C. ve Bulut, F., 2020. Görüntüdeki tuz biber ve gauss gürültülerine karşı filtrelerin performans analizleri. *Haliç Üniversitesi Fen Bilimleri Dergisi*, 211-239. doi:<https://doi.org/10.46373/hafebid.768240>
- Latifi, B. ve Raie, A., 2022. Image Denoising Using Convolutional Neural Network. In *2022 30th International Conference on Electrical Engineering, ICEE*), 185-190.
- Le, T., Chartrand, R. ve Asaki, T. J., 2007. A variational approach to reconstructing images corrupted by Poisson noise. *Journal of mathematical imaging and vision*, 257-263. doi:<https://doi.org/10.1007/s10851-007-0652-y>
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P., 1998. Gradient Based Learning Applied to Document. *Proceeding of the IEEE* 86/11, 2278-2324.
- LeCun, Y., Jackel, L. D., Bottou, L., Cortes, C., Denker, J. S., Drucker, H., S. ve Vapnik, V., 1995. Learning algorithms for classification: A comparison on handwritten digit recognition. *Neural networks: the statistical mechanics perspective* 261.276.
- Leventhall, G., 2009. Low Frequency Noise. What we know, what we do not know, and what we would like to know. *Journal of Low Frequency Noise. Journal of Low Frequency Noise, Vibration and Active Control*, 79-104. doi:<https://doi.org/10.1260/0263-0923.28.2.79>
- Li, B., Zhang, Y., Chen, W., Ma, Y. ve Li, L., 2024. Neural Network-Based Investigation of Periodic Noise Reduction Methods for High-Resolution Infrared Line Scanning Images. *Remote Sensing*, 841.
- Li, Q., Cai, W., Wang, X., Zhou, Y., Feng, D. D. ve Chen, M., 2014. Medical image classification with convolutional neural network. *2014 13th International*

- Conference on Control Automation Robotics & Vision, ICARCV), 844-848. doi:10.1109/ICARCV.2014.7064414.
- Li, Z., 2023. Image Denoising based on Deep Learning. Highlights in Science Engineering and Technology, 1245-1251.
- Lin, M., Chen, Q. ve Yan, S., 2013. Network In Network. arXiv preprint arXiv:1312.4400. doi:https://doi.org/10.48550/arXiv.1312.4400
- Maity, A., Pattanaik, A. ve Sagnik, S., 2015. A Comparative Study on Approaches to Speckle Noise Reduction in Images. In 2015 International Conference on Computational Intelligence and Networks, 148-155. doi:https://doi.org/10.1109/CINE.2015.36
- McCulloch, W. ve Pitts, W., 1943. A logical calculus of the ideas immanent in nervous activity. The bulletin of mathematical biophysics 5, 115-133.
- Moallem, P., Masoumzadeh, M. ve Habibi, M., 2015. A novel adaptive Gaussian restoration filter for reducing periodic noises in digital image. Signal, Image and Video Processing, 1179-1191.
- Muthukrishnan, A. D., Kumar, V. ve Kanagaraj, M., 2019. Internet of image things-discrete wavelet transform and Gabor wavelet transform based image enhancement resolution technique for IoT satellite applications. Cognitive Systems Research, 46-53. doi:https://doi.org/10.1016/j.cogsys.2018.10.010
- Novikov, A., Pronkin, A. ve Vityazev, S., 2022. Edge Detector Application in the Problem of Periodic Interference Filtering. In 2022 24th International Conference on Digital Signal Processing and its Applications, (DSPA), 1-6.
- Olugboja, A., Wang, Z. ve Sun, Y., 2021. Parallel convolutional neural networks for object detection. Journal of Advances in Information Technology 12/4. doi:http://dx.doi.org/10.12720/jait.12.4.279-286
- Öner, İ. V., Yeşilyurt, M. K. ve Yılmaz, E. Ç., 2017. Wavelet Analiz Tekniği ve Uygulama Alanları. Ordu Üniversitesi Bilim ve Teknoloji Dergisi, 42-56.
- Perona, P. ve Malik, J., 1990. Scale-space and edge detection using anisotropic diffusion. IEEE Transactions on pattern analysis and machine intelligence, 629-639. doi:https://doi.org/10.1109/34.56205
- Potluri, S., Fasih, A., Vutukuru, L. K., Machot, F. A. ve Kyamakya, K., 2011. CNN based high performance computing for real time image processing on GPU. Proceedings of the Joint INDS'11 & ISTET'11. IEEE, 1-7. doi:10.1109/INDS.2011.6024781
- Radford, A., Metz, L. ve Chintala, S., 2015. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. arXiv preprint arXiv:1511.06434.

- Rakshit, S., Ghosh, A. ve Shankar, B. U., 2007. Fast mean filtering technique, FMFT. Pattern Recognition, 890-897. doi:<https://doi.org/10.1016/j.patcog.2006.02.008>
- Ranzato, M., Huang, F. J., Boureau, Y.-L. ve LeCun, Y., 2007. Unsupervised learning of invariant feature hierarchies with applications to object recognition. 2007 IEEE conference on computer vision and pattern recognition, 1-8.
- Reith, F. ve Wandell, B. A., 2019. "Comparing pattern sensitivity of a convolutional neural network with an ideal observer and support vector machine. ArXiv abs/1911.05055.
- Rieken, D. W., 2011. Periodic noise in very low frequency power-line communications. 2011 IEEE International Symposium on Power Line Communications and Its Applications, 295-300. doi:<https://doi.org/10.1109/ISPLC.2011.5764410>
- Saadia, A. ve Rashdi, A., 2018. A speckle noise removal method. Circuits Systems and Signal Processing 37, 2639-2650.
- Shreyamsha Kumar, B. K., 2013. Image denoising based on gaussian/bilateral filter and its method noise thresholding. Signal, Image and Video Processing, 1159-1172. doi:<https://doi.org/10.1007/s11760-012-0372-7>
- Simonyan, K. ve Zisserman, A., 2015. Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556. doi:<https://doi.org/10.48550/arXiv.1409.1556>
- Sur, F. ve Grediac, M., 2015. An automated approach to quasi-periodic noise removal in natural images.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P. ve Reed, S., 2015. Going deeper with convolutions. Proceedings of the IEEE conference on computer vision and pattern recognition, 1-9. doi:10.1109/CVPR.2015.7298594
- Tai, Y., Yang, J., Liu, X. ve Xu, C., 2017. Memnet: A persistent memory network for image restoration. Proceedings of the IEEE international conference on computer vision, 4539-4547. doi:10.1109/ICCV.2017.486
- Tian, C., Zheng, M., Zuo, W., Zhang, B., Zhang, Y. ve Zhang, D., 2023. Multi-stage image denoising with the wavelet transform. Pattern Recognition, 1-12. doi:<https://doi.org/10.1016/j.patcog.2022.109050>
- Tsai, F. ve Chen, W. W., 2008. Striping noise detection and correction of remote sensing images. IEEE Transactions on Geoscience and remote sensing, 4122-4131. doi:10.1109/TGRS.2008.2000646
- Varghese, J., 2016. Adaptive threshold based frequency domain filter for periodic noise reduction. AEU-international journal of electronics and communications, 1692-1701.

- Varghese, J. S., Subramaniam, K. ve Palaniswamy, K. S., 2020. Adaptive Gaussian notch filter for removing periodic noise from digital images. *IET Image Processing*, 1529-1538.
- Vyas, A., Yu S. ve Paik, J., 2018. Multiscale transforms with application to image processing. Singapore: Springer.
- Wang, J. ve Liu, D. C., 2010. 2-d fft for periodic noise removal on strain image. 2010 4th International Conference on Bioinformatics and Biomedical Engineering, 1-4.
- Wei, Z., Wang, J., Nichol, H., Wiebe, S. ve Chapman, D., 2012. A median-Gaussian filtering framework for Moiré pattern noise removal from X-ray microscopy image. *Micron*, 170-176. doi:<https://doi.org/10.1016/j.micron.2011.07.009>
- Weickert, J., 1998. Anisotropic diffusion in image processing. Stuttgart: Teubner.
- Xie, Y., Chen, L. ve Hofmann, U., 2012. Reduction of periodic noise in Fourier domain optical coherence tomography images by frequency domain filtering. *Biomedical Engineering/Biomedizinische Technik*, 830-832. doi:<https://doi.org/10.1515/bmt-2012-4189>
- Yapıcı, A. ve Akcayol, M. A., 2022. Derin Öğrenme ile Görüntülerde Gürültü Azaltma Üzerine Kapsamlı Bir İnceleme. *International Journal of Advances in Engineering and Pure Sciences*, 65-90.
- Zeiler, M. D. ve Fergus, R., 2014. Visualizing and understanding convolutional networks. *Computer Vision—ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part I 13*. Springer International Publishing. doi:https://doi.org/10.1007/978-3-319-10590-1_53
- Zhang, A., Lipton, Z. C., Li, M. ve Smola, A. J., 2023. Dive Into Deep Learning. https://tr.d2l.ai/chapter_convolutional-neural-networks/lenet.html; (05.03.2024)
- Zhang, K., Zuo, W. ve Zhang, L., 2018. FFDNet: Toward a fast and flexible solution for CNN-based image denoising. *IEEE Transactions on Image Processing* 27/9, 4608-4622. doi: 10.1109/TIP.2018.2839891
- Zhang, K., Zuo, W., Chen, Y., Meng, D. ve Zhang, L., 2017. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising. *EE Transactions on Image Processing*, 26/7, 3142-3155. doi:<https://doi.org/10.48550/arXiv.1608.03981>
- Zhang, K., Zuo, W., Gu S. ve Zhang, L., 2017. Learning Deep CNN Denoiser Prior for Image Restoration. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, CVPR*, 3929-3938. doi: 10.1109/CVPR.2017.300
- Zhu, M.-L., Zhao, L.-L. ve Xiao, L., 2022. Image Denoising Based on GAN with Optimization Algorithm. *Electronics* 11/15, 1-12. doi:<https://doi.org/10.3390/electronics11152445>