



VIDEO'DA DERİN ÖĞRENME TABANLI GÜRÜLTÜ AZALTMA

Ahmet YAPICI

DOKTORA TEZİ
BİLİŞİM SİSTEMLERİ ANA BİLİM DALI

GAZİ ÜNİVERSİTESİ
BİLİŞİM ENSTİTÜSÜ

OCAK 2024

ETİK BEYAN

Gazi Üniversitesi Bilişim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Ahmet YAPICI

15/01/2024

VIDEO'DA DERİN ÖĞRENME TABANLI GÜRÜLTÜ AZALTMA
(Doktora Tezi)

Ahmet YAPICI

GAZİ ÜNİVERSİTESİ
BİLİŞİM ENSTİTÜSÜ

Ocak 2024

ÖZET

Videoda gürültü giderme teknikleri, görüntü detaylarını korurken gürültüyü ortadan kaldırmayı amaçlamaktadır. Ancak kullanılan gürültü giderme modelleri, görüntü üzerindeki gürültüleri tam olarak giderememekte ve görüntü özellikleri kaybolmaktadır. Tüm gürültü türleri ve seviyelerinde başarılı bir şekilde gürültüyü gideren tek bir model bulunmamaktadır. Bu çalışmada, farklı derin öğrenme yöntemlerini bir araya getiren video gürültü giderme modeli (VGGM) geliştirilmiştir. VGGM mimarisinde evrişimli sinir ağı (convolutional neural network-CNN), üretici çekişmeli ağ (generative adversarial network-GAN), U-Net mimarisi birlikte kullanılarak görüntülerdeki gürültü giderilmekte ve görüntü geçişlerindeki titremenin önlenmesi sağlanmaktadır. VGGM farklı tür ve seviyelerdeki gürültülerin giderilmesindeki performansı BSD400, CBSD400, Derf, DAVIS, Vimeo, Set12 veri kümeleri kullanılarak karşılaştırılmıştır. VGGM, klasik CNN tabanlı modellere göre düşük gürültü seviyelerinde daha başarılı performans göstermektedir. VGGM 0 - 30 dB (decibel) gürültü aralıklarında başarılı sonuçlar elde etmekle beraber ilerleyen gürültü seviyelerinde diğer modellere göre başarı seviyesinin düştüğü görülmektedir.

Bilim Kodu : 92408

Anahtar Kelimeler : Videoda gürültü giderme, derin öğrenme tabanlı gürültü giderme, görüntülerde gürültü azaltma, üretici çekişmeli ağlar, evrişimli sinir ağı

Sayfa Adedi : 149

Danışman : Prof. Dr. M. Ali AKCAYOL

DEEP LEARNING-BASED NOISE REDUCTION IN VIDEO

(Ph. D. Thesis)

Ahmet YAPICI

GAZİ UNIVERSITY

INSTITUTE OF INFORMATICS

January 2024

ABSTRACT

Video denoising techniques aim to eliminate noise while preserving image details. However, in the process of noise reduction, some image texture may be lost, and residual noise artifacts can persist. No single model has achieved universal success across all types and levels of noise. In this study, a video noise reduction model (VGGM) that combines different deep learning methods is developed. Specifically, we leverage a combination of convolutional neural network, generative adversarial network and U-Net architecture, which has demonstrated effectiveness in image denoising and flickering is prevented during image transitions. The performance of the VGGM in removing different types and levels of noise is compared using BSD400, CBSD400, Derf, DAVIS, Vimeo, Set12 datasets. Our evaluation of the VGGM reveals superior performance at low noise levels compared to previous CNN-based methods. The VGGM model achieves successful results in the noise ranges between 0 - 30 dB (decibel), and it is seen that the success level decreases compared to other models at advancing noise levels.

Science Code : 92408

Key Words : Video denoising, deep learning based denoising, image noise reduction, generative adversarial network, convolutional neural network

Page Number : 149

Supervisor : Prof. Dr. M. Ali AKCAYOL

TEŞEKKÜR

Çalışmalarım boyunca değerli yardım ve katkılarıyla beni yönlendiren kıymetli tecrübelerinden faydalandığım danışmanım Prof. Dr. M. Ali AKCAYOL, tezimin gelişmesi ve niteliğinin yükselmesinde öneri ve katkıları için tez izleme komitesi üyeleri Prof. Dr. Hacer KARACAN ve Prof. Dr. Sevil ŞEN AKAGÜNDÜZ'e, TÜRKSAT ailesine ve çalışma hayatımın her anında benden desteğini esirgemeyen eşim, çocuklarım ve aileme teşekkür ederim.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
1. GİRİŞ.....	1
2. GÖRÜNTÜ ÜZERİNDE GÜRÜLTÜ GİDERME KONUSUNDA YAPILAN ÇALIŞMALAR	7
2.1. Geleneksel Gürültü Giderme Yöntemleri	8
2.2. Gürültü Giderme İçin Kullanılan Derin Öğrenme Yöntemleri	13
3. VIDEO GÖRÜNTÜLERİ VE GÜRÜLTÜ TÜRLERİ.....	25
3.1. Video Verilerinin Sıkıştırılması	26
3.2. Video Verileri.....	27
3.3. Video Çözünürlükleri.....	30
3.4. Video Üzerindeki Gürültüler.....	31
3.5. Gürültü Türleri	32
3.6. Videoda Gürültü Giderme Başarısını Değerlendirme Ölçütleri.....	38
4. VIDEO ÜZERİNDE GÜRÜLTÜ GİDEREN DERİN ÖĞRENME MODELİNİN OLUŞTURULMASI.....	45
4.1. Uzaysal gürültü giderme (VGGM1) modelinin hazırlanması.....	48
4.2. Zamansal gürültü giderme (VGGM2) modelinin hazırlanması	61
5. DENEYSEL ÇALIŞMALAR.....	77
5.1. Çalışma Yapılan Veri Kümeleri.....	77
5.1.1. Set12 veri kümesi	77

Sayfa

5.1.2.	DAVIS veri kümesi	78
5.1.3.	Derf veri kümesi	78
5.1.4.	CBSD400 veri kümesi	79
5.1.5.	Vimeo veri kümesi.....	80
5.1.6.	BSD400 veri kümesi.....	80
5.2.	DeneySEL Sonuçlar	82
5.2.1.	Kullanılan donanım	82
5.2.2.	VGGM'nin diğer modellerle kıyaslanması	82
5.2.3.	Geliştirilen hibrit derin öğrenme modelinin çalışma zamanının analizi.....	114
5.2.4.	Görüntülerin görsel olarak kıyaslanması	116
5.2.5.	Modellerin eğitim verisi sayılarının kıyaslanması.....	119
5.2.6.	Modelin farklı veri kümeleri ile eğitim sonuçları.....	120
5.2.7.	Farklı gürültü türlerinde modelin performansı	122
6.	SONUÇ VE ÖNERİLER.....	135
	KAYNAKLAR	138

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Video formatları.....	28
Çizelge 3.2. Video çözünürlük değerleri	30
Çizelge 3.3. CIF formatlarına ait çözünürlük değerleri	31
Çizelge 4.1. VGGM1 ağına ait parametrelerin seçimi ve elde edilen sonuçlar	52
Çizelge 4.2. Uzaysal model katmanları	57
Çizelge 4.3. VGGM1 modeline piksel karıştırma özelliği eklenmesi	60
Çizelge 4.4. VGGM2 ağının oluşturulma sürecinde yapılan test sonuçları.....	63
Çizelge 4.5. Üretici ağ modeli katmanları	64
Çizelge 4.6. Ayırt edici ağın oluşturulma sürecinde yapılan denemelere ait sonuçlar ..	66
Çizelge 4.7. Ayırt edici ağ modeli	67
Çizelge 4.8. Yerel olmayan ortalamalar yöntemindeki hiper parametre seçimi.....	71
Çizelge 4.9. Yerel olmayan ortalamalar yöntemi ile VGGM2'nin kıyaslanması.....	73
Çizelge 5.1. Set12 veri kümesi kullanılarak gürültü giderme sonuçları	83
Çizelge 5.2. BSD400 veri kümesi ile $\sigma=25$ dB gürültü seviyesinde gürültü giderme...	84
Çizelge 5.3. Vimeo veri kümesi ile gürültü giderme	86
Çizelge 5.4. DAVIS veri kümesi ile gürültü giderme.....	94
Çizelge 5.5. CBSD400 veri kümesi ile gürültü giderme	101
Çizelge 5.6. Derf veri kümesi ile gürültü giderme.....	108
Çizelge 5.7. Modellerin DAVIS test verisi ile gürültü giderme işlem süreleri.....	115
Çizelge 5.8. Modellerin eğitim verisi sayılarının kıyaslanması.....	119
Çizelge 5.9. Seçilen parametrelere göre modelin eğitim süresi ve başarı oranları	121
Çizelge 5.10. 30 dB Gauss gürültüsüne sahip görüntülerde gürültü giderme	124
Çizelge 5.11. $\lambda = 100$ değerinde gürültü giderme sonucu elde edilen sonuçlar.....	126
Çizelge 5.12. %10 tuz gürültüsüne sahip görüntülerde gürültü giderme sonuçları	129
Çizelge 5.13. %10 karabiber gürültüsüne sahip görüntülerde gürültü giderme	131
Çizelge 5.14. 0 ortalama, 0,02 varyansa sahip benek gürültüsü giderme sonuçları	132

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Gürültü azaltmada kullanılan yöntemlerinin sınıflandırılması	8
Şekil 2.2. Gürültü gideren evrişimsel sinir ağı mimarisi	16
Şekil 2.3. BRDNet mimarisi	17
Şekil 2.4. FFDNet mimarisi	18
Şekil 2.5. ECDNET mimarisi	19
Şekil 2.6. FastDVDNet mimarisi	20
Şekil 3.1. Sinyallerdeki gürültü	32
Şekil 4.1. VGGM gürültü giderme işlem adımları	45
Şekil 4.2. Zamansal gürültü giderme modeli	46
Şekil 4.3. Görüntülerde gürültü ölçme testi sonuçları	49
Şekil 4.4. Çift katman genişletilmiş evrişim eklenmesi sonucu kayıp değerleri	50
Şekil 4.5. Geliştirilen uzaysal derin öğrenme modelinin mimarisi.....	56
Şekil 4.6. Tersine evrişim kullanılarak oluşturulan modelin kayıp değerleri	58
Şekil 4.7. Piksel karıştırma işlemi.....	59
Şekil 4.8. VGGM1 ağına piksel karıştırma özelliği eklenmesi	60
Şekil 4.9. Üretici ağ mimarisi	64
Şekil 4.10. VGGM2 ağına ayırt edici model mimarisi	68
Şekil 4.10. Üretici çekişken ağı eğitimi sırasında elde edilen kayıp değerleri	68
Şekil 5.1. Vimeo veri kümesi kullanılarak PSNR değerlerinin kıyaslanması	88
Şekil 5.2. Vimeo veri kümesi kullanılarak SSIM değerlerinin kıyaslanması	89
Şekil 5.3. Vimeo veri kümesi kullanılarak FSIM değerlerinin kıyaslanması	89
Şekil 5.4. Vimeo veri kümesi kullanılarak RMSE değerlerinin kıyaslanması	90
Şekil 5.5. Vimeo veri kümesi kullanılarak SRER değerlerinin kıyaslanması	90
Şekil 5.6. Vimeo veri kümesi kullanılarak NMI değerlerinin kıyaslanması.....	91
Şekil 5.7. DAVIS veri kümesi kullanılarak PSNR değerlerinin kıyaslanması	96
Şekil 5.8. DAVIS veri kümesi kullanılarak SSIM değerlerinin kıyaslanması.....	96
Şekil 5.9. DAVIS veri kümesi kullanılarak FSIM değerlerinin kıyaslanması.....	97
Şekil 5.10. DAVIS veri kümesi kullanılarak RMSE değerlerinin kıyaslanması	97
Şekil 5.11. DAVIS veri kümesi kullanılarak SRER değerlerinin kıyaslanması	98
Şekil 5.12. DAVIS veri kümesi kullanılarak NMI değerlerinin kıyaslanması	98

Şekil**Sayfa**

Şekil 5.13. CBSD400 veri kümesi kullanılarak PSNR değerlerinin kıyaslanması.....	103
Şekil 5.14. CBSD400 veri kümesi kullanılarak SSIM değerlerinin kıyaslanması	103
Şekil 5.15. CBSD400 veri kümesi kullanılarak FSIM değerlerinin kıyaslanması	104
Şekil 5.16. CBSD400 veri kümesi kullanılarak RSME değerlerinin kıyaslanması.....	104
Şekil 5.17. CBSD400 veri kümesi kullanılarak SRER değerlerinin kıyaslanması.....	105
Şekil 5.18. CBSD400 veri kümesi kullanılarak NMI değerlerinin kıyaslanması	105
Şekil 5.19. Derf veri kümesi kullanılarak PSNR değerlerinin kıyaslanması.....	109
Şekil 5.20. Derf veri kümesi kullanılarak SSIM değerlerinin kıyaslanması.....	110
Şekil 5.21. Derf veri kümesi kullanılarak FSIM değerlerinin kıyaslanması.....	110
Şekil 5.22. Derf veri kümesi kullanılarak RMSE değerlerinin kıyaslanması	111
Şekil 5.23. Derf veri kümesi kullanılarak SRER değerlerinin kıyaslanması.....	111
Şekil 5.24. Derf veri kümesi kullanılarak NMI değerlerinin kıyaslanması	112
Şekil 5.25. Gauss gürültüsü ile eğitilen modelde kayıp değerleri.....	123
Şekil 5.26. Poisson gürültüsü ile eğitilen modelde kayıp değerleri.....	125
Şekil 5.27. Tuz gürültüsü ile eğitilen modelde kayıp değerleri	127
Şekil 5.28. Karabiber gürültüsü ile eğitilen modelde kayıp değerleri	129
Şekil 5.29. Benek gürültüsü ile eğitilen modelde kayıp değerleri	131

RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 3.1. Gauss gürültüsü	34
Resim 3.2. Poisson gürültüsü.....	34
Resim 3.3. Tuz gürültüsü	35
Resim 3.4. Karabiber gürültüsü	36
Resim 3.5. Benek gürültüsü	37
Resim 3.6. Veri sıkıştırma gürültüsü	37
Resim 3.7. Rician gürültüsü.....	38
Resim 4.1. VGGM2 modelinde beş girdi kullanılması.....	69
Resim 4.2. Yerel olmayan ortalamalar yöntemi sonucu oluşan görüntüler.....	72
Resim 4.3. VGGM1 ve VGGM2 modelleri kullanılarak gürültü giderme.....	74
Resim 5.1. Set12 veri kümesine ait örnek görüntüler.....	78
Resim 5.2. DAVIS veri kümesine ait örnek görüntüler.....	78
Resim 5.3. Derf veri kümesine ait örnek görüntüler.....	79
Resim 5.4. CBSD400 veri kümesine ait örnek görüntüler.....	79
Resim 5.5. Vimeo veri kümesine ait örnek görüntüler	80
Resim 5.6. BSD400 veri kümesine ait örnek görüntüler	81
Resim 5.7. BSD400 veri kümesinde gürültü giderme	86
Resim 5.8. Vimeo veri kümesinde gürültü giderme işlemi	93
Resim 5.9. DAVIS veri kümesinde gürültü giderme işlemi	100
Resim 5.10. CBSD400 veri kümesinde gürültü giderme işlemi.....	107
Resim 5.11. Derf veri kümesinde gürültü giderme işlemi	114
Resim 5.12. CBSD400 veri kümesinde gürültü giderme işlemi.....	119
Resim 5.13. Gauss gürültüsünde gürültü giderme işlemi	124
Resim 5.14. Poisson gürültüsünde gürültü giderme işlemi.....	126
Resim 5.15. Tuz gürültüsü gürültünde gürültü giderme işlemi	128
Resim 5.16. Karabiber gürültüsünde gürültü giderme işlemi	130
Resim 5.17. Benek gürültüsünde gürültü giderme işlemi.....	133

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklamalar
2D	İki Boyutlu (Two Dimensional)
3D	Üç Boyutlu (Three Dimensional)
AWGN	Toplanabilir Beyaz Gauss Gürültüsü (Additive White Gaussian Noise)
BN	Toplu Normalleştirme (Batch Normalization)
CGAN	Koşullu Üretici Çekişmeli Ağ (Conditional Generative Adversarial Network)
CNN	Evrişimli Sinir Ağı (Convolutional Neural Network)
CONV	Evrişim (Convolution)
dB	Desibel (Decibel)
DBN	Derin İnanç Ağları (Deep Belief Networks)
DNCNN	Gürültü Gideren Evrişimli Sinir Ağı (Denoising Convolutional Neural Network)
DNN	Derin Sinir Ağı (Deep Neural Network)
GAN	Üretici Çekişmeli Ağlar (Generative Adversarial Network)
GPU	Grafik İşlem Birimi (Graphics Processing Unit)
LSTM	Uzun Kısa Süreli Bellek (Long Short-Term Memory)
MAE	Ortalama Mutlak Hata (Mean Absolute Error)
MSE	Ortalama Hata Karesi (Mean Squared Error)
PCA	Temel Bileşen Analizi (Principal Component Analysis)
RMSE	Ortalama Hata Karesinin Kare Kökü (Root Mean Squared Error)
SVM	Destek Vektör Makinesi (Support Vector Machine)
VGGM	Videoda Gürültü Giderme Modeli

1. GİRİŞ

Günümüzde video ve görüntü verileri hemen hemen her alanda yaygın bir şekilde kullanılmaktadır. Görüntü ve video verileri elde edilirken ve iletilirken bozulmalara uğramaktadırlar. Görüntü ve video kalitesindeki düşüş, görüntü işleme sırasında kullanılan uygulamaların performansı azaltmakta ve kullanılabilirliği düşürmektedir. Görüntü ve videolardan gürültüyü kaldırarak veya azaltarak daha kaliteli görüntü elde edebilmek için çok sayıda yöntem geliştirilmiştir [1-3]. Bu yöntemler, astronomi alanında görüntü kalitesini artırma [4], ilaç sektöründe insan vücudunu etkileyen parametreleri tespit etme [5], video ve görsel verilerin iletimi öncesi sıkıştırılması ve izlenmesi sırasında eski boyutuna dönüştürülmesi [6], videolarda görüntü yakalanması [7], yaşamsal olayları izleme [8, 9] gibi birçok alanda kullanılmaktadır.

Bilgisayarla görme uygulamalarında karşılaşılan sorunların önemli bir kısmını, görüntü transferi ve yakalama süreçlerinde meydana gelen video ve görüntü bozulmaları oluşturmaktadır. İletim kanalı ve çevresel faktörlerle, görüntülerin içeriği bozulmakta ve bu durum veri kaybına neden olmaktadır.

Kenarlar ve dokular, görüntülerde yüksek frekanslı bileşenleri temsil etmektedirler, bu nedenle gürültüden arındırma sürecinde gürültüyü belirlemek bazı ayrıntıları kaybetmeden gürültüyü azaltmak zor bir süreçtir. Görüntü üzerinde gürültü gidermeye yönelik araştırmalar farklı yöntemler kullanılarak sürdürülmektedir [10]. Video ve görüntülerde gürültü gidermek için kullanılan çalışmalarda uzaysal alan yöntemleri, alan dönüşüm yöntemleri ve zamansal gürültü giderme yöntemlerinden faydalanılmıştır [11]. Geleneksel yöntemlerin çoğu görüntüde gürültü giderme konusunda belirli bir düzeyde iyi performans elde edilmesine rağmen, elle ayarlanan parametreler bulunması ve problemin türüne göre farklı yöntemlere ihtiyaç duyulması nedeniyle uygulanması oldukça zordur [12, 13]. Son zamanlarda derin öğrenme yöntemleri ön işlem gerektirmemesi ve farklı uygulamalarda başarılı sonuçlar vermesi nedeniyle giderek yaygın bir şekilde kullanılmaya başlanmıştır [14, 15]. Derin öğrenme yöntemleri gürültüyü gidermek için öğrenme sürecinde karşılaştığı görüntüler ile gerçek görüntüyü oluşturmaya çalışmaktadır. Kullanılan derin öğrenme

yöntemine bağı olarak belirli düzeyde başarılı bir şekilde orijinal görüntü elde edilebilmektedir [16, 17].

Video ve görüntülerdeki gürültüyü azaltmak için uzamsal filtrelemeden model tabanlı yaklaşımlara kadar birçok farklı yöntem kullanılmıştır. Ancak, yapay sinir ağları GPU alanında gelişmeler sayesinde son zamanlarda geleneksel yöntemlerden daha iyi bir performans sergilemesinden ötürü daha yaygın kullanılmaya başlanmıştır [19, 20]. Derin öğrenme yöntemleri ile daha yüksek performanslı ve farklı veriler üzerinde çalışabilecek yöntemler geliştirilmeye başlanmıştır [21, 22]. Bununla birlikte, bu yöntemlerde hala çeşitli gürültü seviyelerine ve türlerine karşı istenen başarı düzeyine ulaşamamıştır [23, 24]. Yapılan araştırmalar, derin öğrenme yöntemlerinin çeşitli gürültü seviyeleri ve türleriyle başa çıkma konusunda yeterince esnek olmadığını ve her görüntüde aynı gürültü giderme başarısının elde edilemediğini göstermektedir. [25-30]. Yapılan deneysel çalışmaların toplanabilir beyaz gauss gürültüsü (additive white gaussian noise-AWGN) üzerine yapılan çalışmalara odaklandığını göstermektedir [31-34].

Araştırmanın amacı

Bu araştırmanın temel amacı, video üzerindeki gürültüyü gidererek görüntü kalitesini artırmaktır. Bu amaç doğrultusunda aşağıdaki alt amaçlar belirlenmiştir:

1. Video görüntülerinde gürültüyü azaltmak: Farklı gürültü kaynaklarının etkisiyle görüntü kalitesini düşüren gürültüyü, filtreleme ve gürültü giderme yöntemleriyle azaltmak.
2. Görüntü detaylarını korumak: Gürültü giderme işlemi sırasında görüntü detaylarının korunmasını sağlamak ve böylece temizlenmiş görüntülerin orijinal yapısını korumak.
3. Düşük gürültü seviyelerinde başarılı sonuçlar elde etmek: Özellikle düşük gürültü seviyelerinde diğer CNN tabanlı yöntemlere kıyasla daha başarılı sonuçlar elde etmek.
4. Daha az donanım kaynağı kullanmak: Derin öğrenme yöntemlerinde GPU kaynakları kullanılarak modeller eğitilmektedir. GPU ve bellek oluşturulan derin

öğrenme modelinin parametre sayısı, derinliği ve tekrar sayısına bağlı olarak kullanılmaktadır. Bu kaynakları daha verimli kullanacak bir model hazırlanacaktır.

5. Farklı veri kümeleri kullanılarak karşılaştırma: Farklı veri kümeleri üzerinde modeli test ederek farklı veri kümelerinde başarı etmesini sağlayıp, performansını analiz etmek.

Bu doktora çalışmasında videodaki gürültüleri gidermek için farklı derin öğrenme yöntemlerini birlikte kullanan bir model geliştirilmesi amaçlanmakta olup, oluşturulan derin öğrenme modelinin farklı uygulama alanlarında görüntü kalitesini artırmak için kullanılması planlanmaktadır.

Araştırmanın önemi

Video günümüzde hayatımızın her alanında yer almaktadır. Videonun çözünürlüğü ve kalitesi kullanıcı taleplerini karşılamak ve görüntü üzerinde işlem yapabilmek açısından önemlidir. Gürültü, video görüntülerinin kalitesini düşürmekte ve izleme deneyimini olumsuz etkileyebilmektedir. Gürültü giderme yöntemleri, görüntülerin daha temiz ve daha net hale gelmesini sağlayarak kullanıcılar için daha iyi bir izleme deneyimi sunabilmektedir. Video gürültüleri, tıbbi görüntüleme, güvenlik kameraları, endüstriyel görüntü işleme ve medya endüstrisi gibi birçok uygulama alanında önemli bir sorundur. Gürültü giderme algoritmaları kullanılarak görüntü kalitesinin iyileştirilmesi, daha doğru teşhis, güvenlik önlemleri ve içerik üretimi sağlayabilecektir.

Düşük gürültülü video dosyaları, depolama ve iletim maliyetlerini azaltabilmektedir. Bu, özellikle yüksek çözünürlüklü videoların işlenmesinde ve aktarılmasında büyük avantaj sağlamaktadır. Gürültü giderme algoritmaları derin öğrenme modellerinin eğitimi ve performansını artırmaktadır. Temizlenmiş verilerle eğitilen modeller, daha başarılı sonuçlar üretmekte ve veri işleme performansını artırmaktadır. Gürültü giderme algoritmalarının geliştirilmesi, video işleme endüstrisindeki standartları iyileştirmekte, daha tutarlı ve yüksek kaliteli sonuçlar elde edilmesini sağlayarak farklı platformlar arasında uyumluluğu desteklemektedir. Videoda gürültü giderme, görüntü işleme alanında hala geliştirilmesi gereken birçok alan bulundurmakta olup, video üzerinde gürültü giderme alanında yapılacak

bir çalışma hem günlük yaşantımızda hem de farklı uygulama alanlarında önemli kolaylıklar sağlayacaktır.

Sınırlılıklar

Derin öğrenme yöntemleri, GPU'nun kullanılmasıyla birlikte popülerlik kazanmıştır. Gürültü giderme düzeyi, kullanılan donanım ve oluşturulan modele bağlı olarak değişiklik gösterebilmektedir. Derin öğrenme modelleri derinleştikçe ve değişik veri kümeleri ile çalışıp yeterli eğitim süresi sağlandıkça daha başarılı sonuçlar elde edilebilmektedir. Donanım kaynaklarının sınırlı olmasından dolayı modelin oluşturulması, eğitilmesi ve kullanılması aşamalarında yetersizlikler ortaya çıkarabilmektedir. Gürültü giderme yöntemleri genellikle büyük ve karmaşık ağ yapılarını içermekte olup, model eğitimi ve tahmini sırasında yüksek performanslı bir grafik işlem birimine ihtiyaç duyulmaktadır. Ancak, GPU kaynaklarının sınırlı olması, aynı anda birden fazla işlem yapmayı veya büyük boyutlu verileri işlemeyi sınırlayabilmektedir.

Bu tez çalışmasında, sınırlı donanım kaynakları ve eğitim verisi ile video üzerinde başarılı gürültü giderme yapılması amaçlanmıştır. Yapılan çalışmada iki aşamalı gürültü giderme modeli geliştirilmiştir. Geliştirilen bu modele isim karmaşası yaşanmaması için VGGM (Videoda Gürültü Gideren Model) ismi verilmiştir. Gürültü gidermenin ilk aşamasında, geliştirilen CNN tabanlı model kullanılarak, görüntü üzerinde gürültü giderilmiştir. İkinci aşamada ise geliştirilen GAN tabanlı model kullanılarak, görüntünün komşu kareleri de kullanılarak görüntü geçişindeki titremenin önlenmesi ve gürültü seviyesinin azaltılması sağlanmıştır. Gürültü giderme modelinin ilk aşaması olan uzaysal gürültü giderme adımı kullanılarak CNN modeline, VGGM1 ismi verilmiştir. Gürültü giderme modelinin ikinci aşaması olan zamansal gürültü giderme adımı kullanılarak GAN modeline, VGGM2 ismi verilmiştir. Tez dokümanının dördüncü bölümünde geliştirilen modelin detayları hakkında bilgi verilmektedir.

Gürültü giderme aşamasında Google Colab ortamı kullanılmıştır. Colab ortamında GPU, CPU, RAM, disk kullanımında belirli boyut ve zaman limitleri bulunmaktadır. Özellikle yüksek boyutlu görüntüler kullanılarak oluşturulan modeller önemli miktarda belleğe ihtiyaç

duymaktadır. Bellek sınırlamaları, büyük ölçekli veri kümelerinin işlenmesini ve fazla parametreye sahip modellerin eğitilmesini kısıtlamaktadır. Ayrıca Colab ortamı kullanıcılara GPU kullanımını belirli zaman aralıklarında ücretsiz olarak kullandırmaktadır. Zaman kısıtı eğitim sürelerinin de belirli limitlerde tutulmasını zorunlu kılmaktadır.

Bu sınırlamalar nedeniyle daha küçük eğitim verisi ve boyutlara sahip verilerle model eğitilip, daha az kaynak kullanılarak derin öğrenme modeli oluşturulmuş ve gürültü giderme modelinin uygulanması sürecinde başarılı sonuçlar elde edilmiştir.

Tezin genel yapısı ve bölümleri hakkında bilgi aşağıda sunulmuştur.

Birinci bölümde, video üzerinde gürültü giderme problemi konusunun önemi, bu tez çalışmasındaki sınırlılıklar ve bu tezin amacı hakkında bilgiler verilmiştir.

İkinci bölümde, video üzerinde gürültü giderme problemi konusunda daha önce yapılmış çalışmalar ile derin öğrenme yöntemlerini içeren literatür araştırmaları hakkında bilgiler verilmiştir. Görüntülerde gürültü giderme konusunda kullanılan önemli yöntemler ve bunların mimarileri incelenerek modellerin önemli özellikleri detaylandırılmıştır.

Üçüncü bölüm, video görüntülerinin kullanıldığı yerler ve görüntülerin özellikleri hakkında bilgiler içermektedir. Görüntülerin formatları, görüntü iletimi, görüntü çözünürlükleri ve görüntüler üzerinde oluşan gürültüler bu başlık altında incelenerek, görüntülerde gürültü giderme sonucu başarı değerlendirme ölçütlerinin neler olduğu açıklanmaktadır.

Dördüncü bölümde, video üzerinde gürültü giderme için geliştirilen derin öğrenme modelinin hazırlanma aşamalarından basedilmektedir. Bu başlık altında iki aşamalı gürültü giderme modelinin oluşturulması, önerilen yöntemin mimarisi, geliştirme aşamasında kullanılan yöntemler hakkında açıklayıcı bilgiler sunulmuştur. İlk aşamada görüntüdeki gürültüyü gidermek için kullanılan evrişimsel sinir ağı modelinin geliştirme aşamaları ve bu modelde kullanılan katmanlar hakkında bilgi verilmektedir. İkinci aşamada görüntü karesine komşu ardışık görüntülerde titremeyi önlemek için oluşturulan çekişmeli üretken ağı hakkında bilgi verilmiştir.

Beşinci bölümde, modelin eğitimi ve testi için kullanılan veri kümeleri hakkında bilgi verilip, modelin diğer başarı kazanmış modellerle kıyaslaması yapılmaktadır. VGGM yönteminin özellikleri, avantajları ve dezavantajları ortaya konularak açıklanmıştır. Modelin farklı gürültü türlerindeki başarısı karşılaştırılmış ve bu karşılaştırma sonuçları nicel bir şekilde ortaya koyulmuştur.


Altıncı bölümde ise tez çalışmasının sonuçları değerlendirilerek elde edilen kazanımlar ve yöntemin geliştirilmeye açık yönleri açıklanmıştır.



2. GÖRÜNTÜ ÜZERİNDE GÜRÜLTÜ GİDERME KONUSUNDA YAPILAN ÇALIŞMALAR

Video, bilgilerin görsel bir biçimde iletilmesini sağlayan etkili bir iletişim aracıdır. Görsel ve işitsel öğelerin birleştirilmesi, mesajların daha etkili bir şekilde iletilmesini sağlamaktadır. Eğitim materyalleri ve eğlence içerikleri, video formatında sunulabilmekte, karmaşık kavramların daha anlaşılır bir şekilde açıklanmasına yardımcı olmaktadır. Video kullanılarak analiz ve anlatım gerektiren konularda veri aktarımı çok daha etkili olmaktadır.

Gürültü, video çekimi veya iletimi sırasında görüntülerin kalitesini düşürebilmekte ve izleme deneyimini olumsuz etkilemektedir. Video analizi için kullanılan algoritmalar gürültülü verilerden etkilenmektedir. Gürültü giderme çalışmaları video içeriklerinin kalitesini artırmak ve görüntü üzerinde kolay işlem yapmak için önemlidir. Gürültü giderme teknik açıdan ters ve karmaşık bir problemdir. Bu problemi çözebilmek için bugüne kadar çok farklı yöntemler kullanılmış olup, bu alanda kullanılan yöntemler Şekil 2.1’de sınıflandırılmıştır.



Şekil 2.1. Gürültü azaltmada kullanılan yöntemlerinin sınıflandırılması

Yapılan çalışmalarda gürültü giderme işlemi için değişik filtreleme yöntemleri ve istatistiksel yaklaşımlar geliştirilmiştir [35, 36]. Son yıllarda donanım teknolojisinin gelişmesiyle birlikte görüntülerdeki derin öğrenme tabanlı gürültü giderme yöntemlerinin kullanımı artmıştır [37-39]. Literatürde yer alan çalışmalar geleneksel ve derin öğrenme yöntemleri olarak iki ana kısma ayrılmaktadır.

2.1. Geleneksel Gürültü Giderme Yöntemleri

Geleneksel gürültü giderme yöntemleri, görüntü verisindeki istenmeyen gürültüyü azaltmak veya kaldırmak için kullanılan genellikle düşük seviyeli işlem adımlarını içeren ve

istatistiksel veya filtreleme yaklaşımlarına dayanmaktadır. Bu yöntemler uzaysal alan ve alan dönüşüm yöntemleri olarak iki gruba ayrılmaktadır.

Uzaysal alan yöntemleri

Uzaysal alan filtrelemesi, geleneksel gürültü giderme yöntemlerinden biridir. Bu yöntemde, her bir görüntü çerçevesi ayrılarak özelleştirilmiş bir filtreleme işlemine tabi tutulmaktadır. Video üzerindeki her kare, bir önceki karedeki nesnelerin hareketi veya ekrandan kaybolması veya yeni nesnelerin eklenmesiyle oluşmaktadır. Bu yaklaşımda, benzer çerçeveler hem görüntülerde hem de video karelerinde bulunup gruplandırılarak gürültü azaltma işlemi gerçekleştirilmeye çalışılmaktadır. Bu yöntemin uygulanmasında kullanılan metodolojiler aşağıda detaylandırılmıştır.

a. Uzaysal alan filtreleme: Bu alanda uygulanan filtreleme yöntemleri, görüntüdeki gürültüyü azaltmak, kenarları vurgulamak veya pürüzlü bölgeleri düzeltmek gibi amaçlarla kullanılmaktadır. Gauss gürültüsünün giderimi için genellikle ortalama filtreleme [40] tercih edilmekte olup, yüksek gürültü seviyelerinde bu filtre görüntüyü aşırı derecede düzleştirebilmektedir [41]. Bu sorunu çözmek amacıyla Wiener filtrelemesi [42] kullanılmakta olup, bu filtrenin keskin kenarları bulanıklaştırdığı görülmektedir. Gürültü seviyesi önceden bilinmeyen durumlarda medyan filtreleme [43] ve ağırlıklı medyan filtreleme [44] gibi doğrusal olmayan filtreler kullanılarak gürültü giderilebilmektedir. Bozulmayı önlemek için, Bilateral filtreleme [45] doğrusal olmayan, kenar koruyan ve gürültü azaltıcı yumuşatma filtresi yaygın bir şekilde kullanılmaktadır. Bu filtreleme yönteminde, piksel değerleri, komşu piksellerdeki ağırlıklı ortalama değerleriyle değiştirilmektedir.

b. Toplam değişim filtresi: Görüntü işleme alanında toplam değişim filtreleri aktif olarak kullanılmakta olup, bu filtreler konusunda yeni araştırmalar yapılmaktadır [46]. Toplam varyasyon tabanlı görüntü yenileme modelleri ilk olarak Rudin, Osher ve Fatemi (ROF) tarafından kenar koruma, görüntüde gürültü giderme konusunda yapılan çalışmalarda ortaya çıkmıştır [47]. Eş yönsüz doku filtresi, kenarları daha belirgin hale getirip, gürültüyü azaltmak amacıyla kullanılmaktadır [48]. Kısmi diferansiyel denklemler tabanlı yöntemler, gürültü giderme, bulanıklık giderme, kör gürültü giderme ve görüntü iç boyama gibi görüntü yenileme problemlerinde kullanılmaktadır [49]. Toplam değişim filtresi, yüksek frekanstaki

gürültüyü giderirken başarılı sonuçlar elde etmektedir. Ancak düşük frekanslı gürültüde kenar ve dokulardaki gürültü tam olarak giderilememektedir.

c. Yerel olmayan ortalamalar (Non-Local Means-NLM): Bu yöntemde görüntü üzerindeki benzer pikseller gruplanarak, gürültüyü azaltmak için piksellerin ortalama değerleri alınmaktadır [50]. Hızlı blok eşleştirme ve 3 boyutlu filtreleme tekniğinde videodaki benzer kareler gruplanarak blok eşleştirme yapıldıktan sonra görüntü blokları üzerinde filtreleme yapılmaktadır. Bu yöntemlerde bir çerçevenin, referans bir çerçeve ile benzerliği, belirtilen bir eşiğin altına düşerse gruplanıp, sonrasında 3 boyutlu filtre uygulanmaktadır [51]. Blok eşleme algoritmasında görüntünün içindeki bloklar kayar bir şekilde hareket ettirilip, bloğun bulunduğu yerdeki görüntüye benzer bloklar aranarak eşleştirme yapılmakta ve blokların ağırlıklı ortalaması alınmaktadır [52]. Gürültü kademeli olarak arttığında, blok eşleşme ve 3 boyutlu filtreleme yönteminin (block matching and 3D filtering-BM3D) uygulandığı görüntülerde, aynı renge sahip alanlarda gürültü kalıntılarının bulunduğu gözlemlenmektedir [53]. Bu yöntem görsel açıdan kaliteli bir sonuç elde etse de evrişimli sinir ağı tabanlı yöntemler BM3D yöntemine göre daha başarılı sonuçlar elde etmektedir [54].

VBM3D [55], VBM4D [56] blok eşleme ve 3 boyutlu filtreleme ile videolarda gürültüyü gidermek için kullanılmaktadır. VBM4D sadece uzaysal olarak değil, aynı zamanda zamansal olarak da benzer yamaların bulunması yoluyla gürültüyü gidermektedir. Daha fazla karede benzer yamalar arandığı için bu yöntemin işlem süresi büyük ölçüde artmaktadır.

Video üzerinde gürültü gidermedeki başarı ölçütleri arasında görüntü geçişlerinde titremenin olmaması, detayların korunması, gerçek zamanlı gürültü giderme yapılabilmesi yer almaktadır. Görüntülerde başarılı bir şekilde uygulanan gürültü giderme yöntemleri, aynı başarıyı yakalamak için videolara da uyarlanmıştır. Örneğin, BM3D ve NLB yöntemleri genellikle görüntüler üzerinde kullanılırken, VBM4D ve VNLB yöntemleri özellikle video üzerinde uygulanmaktadır [57]. VBM4D yönteminde, diğer gürültü giderme yöntemlerinden farklı olarak, ardışıl görüntülerdeki benzer yamalar bulunup gruplanarak, gürültü giderme işlemi benzer yamalar üzerinde yapılmıştır. Yamalar arasında benzerlik bulma, uzamsal olarak benzer komşu kareleri belirleme ve hareket tahmini yöntemleri, gürültü giderme işlemlerinde kullanılmaktadır. VBM4D yöntemi, hareket vektörlerini kullanarak nesnelerin takibini sağlamakta ve aynı nesneleri gruplandırılarak filtreleme

işlemi uygulamaktadır [58]. VNLB ise, bayes teoremi kullanılarak video üzerinde gürültü giderme için geliştirilen yama tabanlı bir yöntemdir.

Yerel olmayan ortalamalar kullanılarak oluşturulan gürültü giderme modelleri, görüntüleri yerel komşuluklar veya yamalar aracılığıyla temsil ederek ve gürültüyü tahmin etmeye çalışmaktadır. En büyük artçı kestirim (Maximum a Posteriori Estimation-MAP), gürültülü bir görüntüden temiz bir yama tahmin etmek için kullanılmaktadır [59]. Bu yöntem, istatistiksel veriler kullanarak görüntü üzerindeki bir değeri tahmin etmek için MAP hipotezlerini kullanmaktadır. Gerçek gürültü giderme problemleri için, hipotez uzayı genellikle çok büyük veya sonsuzdur. MAP hipotezlerini bulmak, bir optimizasyon problemidir, bu nedenle gürültü tahmini işlemleri genellikle daha hızlı gerçekleşir [60]. Bu yöntem, kenar ve dokuların korunmasında etkili bir çözüm sunmaktadır.

d. Seyrek yaklaşım: Seyrek yaklaşım metodunda, nesnelerin hangi sınıfa ait olduğu seyrek gösterim vektörleri kullanılarak belirlenmekte ve görüntü işleme teknikleri kullanılarak bazı özelliklerin daha kolay ortaya çıkması sağlanmaktadır [61-62]. Destek Vektör Makineleri [63] ve çekirdek tabanlı seyrek temsil [64] bu yöntemi kullanan önemli çalışmalar arasında yer almaktadır. Yerel olmayan merkezi seyrek temsil (Nonlocally Centralized Sparse Representation-NCSR) modeli, pürüzsüz ve dokulu bölgelerin başarılı bir şekilde yeniden yapılandırılmasını sağlamaktadır [65]. Ancak seyrek yaklaşım tekniklerinin, yinelemeli sözlük öğrenme ve bilinmeyen seyrek katsayıların yerel olmayan tahminleri nedeniyle hesaplama süresini uzattığı ve bu nedenle uygulamalarda kullanılabilirliği sınırladığı belirtilmelidir.

e. Düşük dereceli en iyileme: Bu yöntemde benzer yamalar gruplanarak bir matris oluşturulmakta ve matrisin her bir sütununda, benzer yamalara ait veriler bulunmaktadır. Gürültü giderimi için kullanılan düşük dereceli yaklaşımlar düşük sıralı matris çarpanlarına dayalı yöntemler [66] ve nükleer norm en iyilemesine dayalı yöntemler (Nuclear Norm Minimization-NNM) [67] olarak iki ana gruba ayrılmaktadır. Düşük sıralı matris çarpanlara ayırma, iki giriş arasındaki etkileşimleri bulmak ve ikili verileri analiz etmek amacıyla kullanılmaktadır [68]. Tekil değer ayrışımı (Singular Value Decomposition-SVD), bir matrisi farklı boyutlara bölerek boyut azaltmayı hedeflemektedir. K-ortalamaları tekil değer ayrışımı (K-Means Singular Value Decomposition-K-SVD), k-ortalamaları kümeleme yönteminin geliştirilmiş bir versiyonu olup, görüntü işleme, ses işleme, biyoloji ve belge analizi gibi çeşitli uygulamalarda yaygın olarak kullanılmaktadır [69].

Nükleer norm en iyilemesine dayalı yöntemler, tüm tekil değerleri eşit şekilde küçülterek matris sırasını yaklaşık olarak tahmin etmek için kullanılmaktadır. Farklı boyutlardaki tekil değerlere uyarlanan ağırlık atayabilen ve yumuşak bir eşik yöntemi kullanan Ağırlıklı Nükleer Norm Minimizasyon yöntemi (Weighted Nuclear Norm Minimization-WNNM) gürültü giderme alanında başarılı sonuçlar elde etmektedir [70]. Ancak bu yöntemin, hesaplama maliyeti nedeniyle, gürültü giderme işlem süresi uzun sürmektedir.

Alan dönüşüm yöntemleri

Alan dönüşüm yöntemleri sinyalin dönüşüm alanında daha seyrek bir temsile sahip olabileceği varsayımına dayanmaktadır [71]. Bu yöntem ilk olarak Fourier dönüşümünde kullanılmıştır. Zaman içinde, kosinüs dönüşümü, dalgacık alanı yöntemleri [72] gibi çeşitli dönüşüm alanı teknikleri geliştirilmiştir. Gürültülü görüntülerde dönüşüm araçları olarak bağımsız bileşen analizi [73] ve temel bileşen analizi fonksiyonları kullanılmıştır. Bağımsız bileşen analizi, normal dağılıma sahip olmayan verilerin gürültü azaltma süreçlerinde, başarılı bir şekilde uygulanmıştır [74]. Bu alanda geliştirilmiş yöntemler dört kategoride incelenmektedir.

1. Doğrusal filtreler, görüntülerde gürültüyü azaltmak için tercih edilen filtre türlerindendir [75]. Wiener filtresi, adaptif bir doğrusal filtre türüdür ve filtrelenmiş görüntüyü üretirken hata karelerinin ortalamasını istatistiksel bir yaklaşımla en aza indirmeye çalışmaktadır.

2. Dalgacık dönüşümü gürültü giderme alanında doğrusal olmayan katsayı eşikleme tabanlı yöntemlerde kullanılmaktadır. Gauss gürültüsü, dalgacık alanında genellikle küçük değerlerle temsil edilir ve gürültü, belirli bir eşiğin altındaki katsayıları sıfıra ayarlayarak veya eşiğin üstündeki katsayıları eşik değeriyle küçültüp yumuşak eşikleme teknikleri kullanılarak giderilmektedir [76]. VisuShrink yaklaşımı, tüm dalgacık detay katsayıları için tek bir eşik değeri kullanmaktadır [77]. BayesShrink algoritması ise her dalgacık alt bandı için farklı bir eşik değerinin kullanıldığı, uyarlanabilir bir yaklaşımdır [78].

3. Dalgacık katsayısı yaklaşımı, farklı çözünürlüklerde sinyalin yakın korelasyonunu tanımlayarak, gürültü giderme yapmaktadır. Deterministik modelleme yönteminde ise, dalgacık katsayılarını temsil eden düğümler ile bir ağaç yapısını oluşturmaktadır.

4. Gürültü sinyaliyi ayırtmak için, kırılmamış dalgacık dönüşümü (Undecimated Discrete Wavelet Transform-UDWT) de kullanılmıştır [79]. Yapılan bir çalışmada, azaltılmış bir dönüşüm yerine kırılmış bir dönüşüm kullanılarak eşikleme, gürültü giderme uygulamalarında sonucu 2,5 dB'den fazla iyileştirebileceği gösterilmektedir [80]. Ayırık Kosinüs Dönüşümü (Discrete Cosine Transform-DCT) filtreleme algoritması, görüntülere sabit veya adapte edilebilir bloklar halinde uygulanmaktadır. DCT, yüksek veri sıkıştırma oranlarında dahi yüksek kalite elde edebilme özelliğine sahiptir [81]. DCT tabanlı filtreleme yönteminde, bir eşik değeri belirlenerek gürültü giderimi yapılmaktadır [82].

2.2. Gürültü Giderme İçin Kullanılan Derin Öğrenme Yöntemleri

Gürültüyü kendi kendine modelleyebilmesi, kullanım kolaylığı ve farklı gürültülere adapte olması nedeniyle derin öğrenme yöntemleri gürültü giderme alanında kullanılmaktadır. Görüntülerdeki gürültüyü azaltmak amacıyla, derin öğrenme yöntemlerinde ilk olarak CNN mimarileri kullanılmıştır [83]. CNN tabanlı gürültü azaltma yöntemleri diğer derin öğrenme yöntemlerine kıyasla daha başarılı sonuçlar elde etmektedir [84, 85].

Denetimli öğrenme, bozuk görüntü ve temiz görüntü çifti içeren bir regresyon modelidir. CNN modelleri görüntü çiftlerini kullanan ileri beslemeli evrişimsel sinir ağlarıdır. Gürültü gideren evrişimsel sinir ağları (Denoising Convolutional Neural Network-DnCNN) [86], ek beyaz gauss gürültüsünü kaldırmak için eşleştirilmiş temiz ve gürültülü verilerle derin bir sinir ağını eğiterek gürültüden arındırılmış görüntüler elde etmektedir. Denetimsiz öğrenme yöntemlerinde eğitim için temiz görüntü verisi olmadan, gürültü doğrudan verilerden öğrenilerek giderilmektedir. Noise2Noise (N2N) [87], eşleştirilmiş görüntü olmadan, gürültülü verilerden öğrenim yaparak gürültüyü ortadan kaldırmaktadır. Noise2Self (N2S) [88] ve Noise2Void (N2V) [89], orijinal görüntüye erişilemeyen durumlarda kullanılan yöntemlerdir.

Gürültü giderme konusunda yapılan çalışmalarda artırılmış veri kümeleri ile çalışmak modelin performansını etkilemektedir [90]. Az veri ile yapılan çalışmalarda model ezberleme problemi ile karşılaşmaktadır. Veri artırımı, görüntü verileri üzerinde döndürme, çevirme, ölçeklendirme, kırpma yöntemleri kullanılarak yapılmaktadır. Eğitim veri

kümesinin belirli bir değere kadar artışı modelin doğruluk oranını artırmakta, belirli bir sayıdan sonra aşırı öğrenme ile modelin doğruluk oranını azalmaktadır [91].

Görüntülerde gürültü giderme için cnn yönteminin kullanımı

Görüntülerde gürültü giderimi için derin öğrenme mimarileri ilk olarak Zhou ve arkadaşları tarafından kullanılmıştır [92]. Hesaplama verimliliğinin artırılması ve performans arasında bir denge kurmak için ileri beslemeli ağlar önerilmiştir [93]. Ağın doğruluğunu artırmak ve gürültü giderme performansını yükseltmek için şablonlu hücrel sinir ağları kullanılmıştır [94]. Hesaplama maliyetini düşürmek amacıyla evrimsel sinir ağları kullanılmaya başlanmış, gürültü giderme ve süper çözünürlük gibi alanlarda yoğun olarak kullanılmıştır [95]. Daha karmaşık bozuk görüntüler için, bulanıklık gidermek ve gürültüyü tahmin etmek ve yüksek çözünürlüklü bir görüntüyü elde etmek için derin süper çözünürlük (Deep Super Resolution-DPSR) yöntemi [96] geliştirilmiştir.

Gürültü giderme aşamasında modelleri eğitirken ek beyaz gürültüler görüntüye kontrollü olarak eklenmektedir. Ek beyaz gürültüler gaussian, poisson, tuz ve karabiber ve çarpımsal gürültüleri içermektedir [97]. Görüntülerden gürültüleri gidermek için CNN ağları kullanılarak 3 farklı yöntem uygulanmaktadır.

1. Artık görüntü elde edilen evrimsel sinir ağları: Derin öğrenme modelleri genel olarak eğitim verisine benzer tahmini görüntüyü oluşturmaktadır. Artık görüntü elde eden yöntemler, tahmini görüntü yerine gürültüyü oluşturmakta ve gürültü orijinal görüntüden çıkartılarak temiz görüntü elde edilmektedir [98]. Bu tür mimariler oluşturulurken farklı yöntemler kullanılmakta olup, bu yöntemlerden yoğun olarak tercih edilenleri aşağıda sunulmuştur.

- CNN'nin çoklu girişlerindeki özellikleri birleştirilerek, farklı ağlardan çok sayıda girdi sağlanarak, girdi verisinin farklı perspektifleri kullanılabilir [99].
- Farklı kayıp fonksiyonları tasarlanarak mimari hızı değiştirilebilmektedir.
- CNN'nin derinliği veya genişliğini değiştirilerek gürültü giderme performansını iyileştirmek için alıcı alan boyutu büyütülmektedir [100].

- CNN'lere yardımcı katmanlar koyularak, CNN'nin başarısı artırılmaya çalışılmaktadır. Aktivasyon fonksiyonu, genişletilmiş evrişim, tam bağlı katman ve havuzlama işlemleri gibi eklentiler zaman içerisinde uygulanmıştır [101].
- CNN'de atlama bağlantıları [102] veya kademeli işlemler [103] kullanılarak, öğrenme aşamasında, sonraki katmanlara bilgi aktarımı sağlanarak aşırı öğrenme engellenmiştir.


2. CNN kullanarak ortak özellik çıkartma yöntemleri ile gürültü giderimi: Bu yöntem, gürültü giderimi sırasında CNN yöntemi ile birlikte diğer başarı elde etmiş mimariler birlikte kullanılmaktadır. Bir çalışmada dalgacık dönüşümü ve U-Net birlikte kullanılmaktadır [104]. Diğer bir çalışmada yüksek boyutlu gürültülü görüntüler için, CNN ve boyutsal indirgeme yönteminin kombinasyonu kullanılmaktadır [105]. Bir diğer çalışma görüntülerde gürültü giderimi için temel bileşen analizi içeren bir CNN kullanılmıştır [106]. Bu mimarinin ilk adımında, öznitelik çıkarmak için evrişim işlemi ikinci adımda, elde edilen özelliklerin boyutunu azaltmak için temel bileşen analizi üçüncü adımda ise temiz bir görüntüyü yeniden oluşturmak için evrişimler kullanılmıştır.

3. En iyileme yöntemi ile CNN'nin birlikte kullanımı: Bu yöntemde çekişmeli üretken ağlar kullanılmaktadır. Gürültü giderme hızını iyileştirmek için, en büyük artçıl kestirim yöntemine sahip bir çekişmeli üretken ağ, gürültüyü tahmin etmek ve görüntü iç boyama ve süper çözünürlük gibi işlevler için kullanılmaktadır [107]. Gürültü giderme performansını iyileştirmek ve gürültülü bir görüntüyü pürüzsüz hale getirmek için CNN en iyileme yöntemi kullanılmaktadır [108].

Görüntülerde gürültü giderme aşamasında kullanılan önemli CNN mimarileri aşağıda sunulmuştur.

a. Gürültü gideren evrişimsel sinir ağları: DnCNN görüntülerde gürültü azaltmak ve performanslı bir çözüm sunabilmek için geliştirilen bir yöntemdir. CNN ağlarında, ağın derinliği arttıkça hata miktarında da artış meydana gelmektedir. DnCNN, veri sayısını azaltarak işlem performansını artırmaktadır [86]. Derin öğrenme kullanan gürültü giderme yöntemleri başarılı olmalarına rağmen, iki büyük dezavantaja sahiptirler. Birincisi, modelin eğitimi sırasında ağın derinliğine bağlı olarak eğitim süreci uzamaktadır [109]. İkincisi, modellerin elle seçilen parametreleri sebebiyle, farklı gürültü ve görüntülerde başarısı düşmektedir. Gürültü gideren evrişimsel sinir ağı bu sorunlara toplu normalleştirme ve artık

ağ ile çözüm sunmaktadır. Böylece daha derin bir öğrenme ağı oluşması sağlanmaktadır. DnCNN mimarisi Şekil 2.2’de sunulmuştur [86].




Şekil 2.2. Gürültü gideren evrişimsel sinir ağı mimarisi

b. Eğitilebilir doğrusal olmayan reaksiyon yayılması (Trainable Nonlinear Reaction Diffusion-TNRD): Eşyönsüz yayılma yönteminde, filtreler etki fonksiyonları ve diğer parametreler, doğrusal olmayan yayılma modellerinin aksine, kayıp tabanlı bir yaklaşımla, eğitim verilerinden eşzamanlı olarak öğrenilmektedir [110]. Bu model ilk olarak Perona ve Malik tarafından önerilmiş olup, görüntünün sınırlarını belirleme ve gürültü azaltmada başarılı olmuştur. Bu yöntem, gauss gürültüsünün giderilmesi, tek görüntüden yüksek çözünürlüğe sahip görüntü elde etme ve jpeg görüntülerinde kayıp giderme işlemi için kullanılabilmektedir.

c. Laplas piramit süper-çözünürlüklü ağ (Laplacian Pyramid Super-Resolution Network-LapSRN): Basamaklı alt ağlardan oluşan bir CNN ağıdır [111]. Yüksek çözünürlüklü bir ağ oluşturmak için kullanılmaktadır. Özellik çıkarım katmanı ile tersine evrişimsel dönüşüm katmanlarının birlikte kullanıldığı CNN mimarisine sahip bir ağıdır. LapSRN ağı 27 katmandan oluşmakta olup, düşük çözünürlüklü görüntüleri süper çözünürlüğe ulaştırmak için de kullanılmaktadır.

d. Toplu tekrar normalleştiren gürültü giderme ağı (Batch-Renormalization Denoising Network-BRDNet): Derin evrişimli sinir ağlarında modelin derinliği arttıkça eğitim süreleri uzamakta ve performans sorunları ortaya çıkmaktadır. BRDNet ağın genişliğini artırmak için iki ağı birleştirerek daha fazla özellik elde etmeyi amaçlamaktadır [112]. Bu yöntemde artık öğrenme ve genişletilmiş evrişimler kullanılmaktadır. Şekil 2.3’da modelin mimarisi sunulmuştur. Mimari iki kısımdan oluşmakta olup, toplu yeniden normalleştirme katmanı

yeşil ile, genişletilmiş evrişimsel ağ katmanı mavi ile gösterilmektedir.




Şekil 2.3. BRDNet mimarisi

e. Birim haritalama modülleri zinciri (Chain of Identity Mapping Modules-CIMM): CIMM yönteminde görüntülerde gürültü giderme için birim eşleme modülleri içeren tam evrişimli bir ağ modeli kullanılmıştır. CIMM mimarisi, kaybolan eğim sorununu çözmek için, atlama bağlantılarını kullanıp, bir önceki adımda elde edilen görüntüyü bir sonraki adımın girdisi olarak almaktadır [113]. Ayrıca bu modelde genişletilmiş çekirdekler kullanılarak, alıcı alanı genişletilmiştir.

f. Çok seviyeli dalgacık evrişimli sinir ağı: Bu yöntem gürültü giderme sürecini hızlandırmak amacıyla dalgacık dönüşümü kullanmaktadır. Modelin daha hızlı çalışması amacıyla, özellik haritalarının boyutu küçültüp, filtre sayısını azaltmak için bir evrişimsel katmanlar kullanılmaktadır [114]. Genişleyen alt ağda, yüksek çözünürlüklü özellik haritalarını yeniden oluşturmak için ters dalgacık dönüşümü uygulanmaktadır.

g. Hızlı ve esnek gürültü giderme evrişimli sinir ağı (Fast And Flexible Denoising Convolutional Neural Network-FFDNET): FFDNet gürültü seviyesi bilinmeyen görüntüler üzerinde gürültü giderme amacıyla oluşturulmuş bir yöntemdir [100]. İlk katman, gürültülü bir görüntüyü dört alt görüntüye yeniden şekillendiren tersine çevrilebilir bir alt örnekleme işlevine sahiptir. Her katman üç tür işlemten oluşmaktadır; ilk evrişim katmanı için “Conv + ReLU”, orta katmanlar için “Conv + BN + ReLU” ve son evrişim katmanı için “Conv” şeklindedir. Her evrişimden sonra özellik haritalarının boyutunu aynı tutmak için sıfır dolgu kullanılmaktadır. Son katmanda, görüntü boyutu artırılarak gürültü giderilmiş görüntü elde


edilmektedir. Şekil 2.4’de FFDNet mimarisi sunulmaktadır.



Şekil 2.4. FFDNet mimarisi

h. Verimli alt-piksel evrişimli sinir ağı (Efficient Sub-Pixel Convolutional Neural Network-ESPCN): ESPCN, düşük çözünürlüklü görüntülerden yüksek çözünürlüklü görüntüler elde etmek için kullanılan bir yöntemdir [115]. Bu yöntemde, görüntülerin kaydırma adımı değeri, her bir pikselin eğitim verisinde bir kez gözükmesini sağlamak üzere orijinal görüntüye göre ayarlanmaktadır. Algoritmada tanh aktivasyon fonksiyonu kullanılmakta, en fazla 100 tekrar ile model eğitilmekte, kayıp fonksiyonu sonucu elde edilen değerlerde herhangi bir değişim olmazsa tekrar işlemi sonlandırılmaktadır. İlk öğrenme oranı 0,01 ile başlamakta en sonunda 0,0001 değerine ulaşmaktadır. Modelin mimarisi, toplamda üç evrişim katmanından oluşmaktadır. İlk iki katman, özellik haritaları çıkarmak için kullanılırken, üçüncü katman düşük çözünürlüklü görüntüden süper çözünürlüklü görüntü elde etmek amacıyla kullanılmaktadır.


i. Gelişmiş evrişimli sinirsel gürültü giderme ağı (Enhanced Convolutional Neural Denoising Network-ECDNet): Bu yöntem 17 katmandan oluşmaktadır. Diğer modellerden farklı olarak genişletilmiş evrişim katmanı kullanılarak alıcı alan bilgisi genişletilmiştir. Artık öğrenme ile de modelin sonunda gürültü bilgisi elde edilmektedir [116]. ECDNet modeline ait ağıın mimarisi Şekil 2.5’de sunulmuştur. Genişletilmiş evrişim katmanı kullanılan bu modelde, kullanılan filtreler elde edilen görüntü arasındaki boşluğu artırırken, hesaplamada kullanılacak parametre sayısını azalttığı için modelin eğitim süresi düşmektedir.



Şekil 2.5. ECDNET mimarisi

j. Derin video gürültü giderme ağı (Deep Video Denoising Net-DVDNet): DVDNet yönteminde, videodan gürültü giderme aşamasında performans ve eğitim süresi arasında bir denge sağlamak amacıyla zamansal bilgiler birleştirilmektedir [117]. Bu metodoloji, geleneksel gürültü giderme yöntemleri ile CNN tabanlı gürültü giderme tekniklerinin bir araya getirmektedir. Hareket tahmini yöntemi kullanılarak, videoda farklı çerçevelerdeki benzer görüntüler tespit edilip, bu benzer pikseller üzerinde gürültü giderilerek görüntü geçişleri sırasındaki titremeler azaltılmaktadır.

k. Hızlı derin video gürültü giderme ağı (Fast Deep Video Denoising Net-FastDVDNet): DVDNet yöntemi geliştirilip, U-Net ağı kullanılarak FastDVDNet yöntemi geliştirilmiştir [118]. Geliştirilen bu yöntem uzamsal ve zamansal filtreleme yaparak daha kısa sürede gürültü giderme işlemini yapabilmektedir. FastDVDNet modelinin mimarisi Şekil 2.6'da sunulmuştur. Model ilk olarak 5 tane çerçeveyi girdi olarak almakta ve ikinci aşamada gürültü giderilen 3 blok üzerinde uzaysal filtreleme yapılmaktadır. Gürültü gideren bloklarda değiştirilmiş U-Net mimarisi kullanılmıştır. FastDVDNet modelin eğitimi sırasında temiz ve gürültülü video çiftlerini ve gürültü haritasını kullanmaktadır. Gürültü haritaları, model eğitilirken gürültüyü öğrenmesi için oluşturulmaktadır. Model, temiz çerçeveleri ve gürültülü çerçeveleri giriş olarak alıp ve aralarındaki farkı hesaplamaktadır. Bu fark, pikseller arasındaki gürültü seviyelerini temsil eden bir gürültü haritası oluşturmaktadır. Gürültü haritaları, modelin hangi bölgelerde daha fazla düzeltme yapması gerektiğini belirlemesine yardımcı olmaktadır. Model, gürültülü bölgelerde daha fazla düzeltme yapabilirken, temiz bölgelerde daha az işlem yapmaktadır. Bu, daha iyi sonuçlar elde etmeye ve daha fazla gürültüyü azaltmaya yardımcı olmaktadır.



Şekil 2.6. FastDVDNet mimarisi

1. Önce görüntü sonra video ağı (First Image Than Video Net-FITVNet): FITVNet yöntemi iki aşamalı bir gürültü giderme modeline sahiptir. İlk aşamada görüntü içindeki gürültü giderilmekte, ikinci aşamada ekran geçişlerindeki titreşimin azaltılması için, video üzerinde uzamsal ve zamansal gürültü giderme yöntemleri uygulanmaktadır [119]. Bu modelde iki aşamalı bir CNN ağı kullanılarak temiz video görüntüleri elde edilmektedir. Bu modelde gürültü haritaları kullanılmıştır. Gürültü haritaları, bir görüntünün veya videonun hangi bölgelerinin ne kadar gürültülü olduğunu gösteren görüntülerdir. Her piksel, karşılık gelen pikselin gürültü seviyesini temsil eden bir değere sahiptir. Bu haritalar, modelin gürültüyü nerede ve ne kadar gidermesi gerektiğinin belirlenmesine yardımcı olmaktadır. Bu modelin eğitimi sırasında [5-55] dB değerlerinde gürültü eklenmiş, gürültü haritası oluşturmak için 25 dB değerinde gürültü haritası oluşturulmuştur. Gürültü giderme sırasında girdi değeri olarak gürültü seviyesi değeri alınmakta ve modelin gürültü haritası oluşturma aşamasında bu değer kullanılmaktadır. Bu değeri normalden fazla artırdığımız zaman görüntü üzerinde gürültüler daha iyi giderilmekte ancak dokularda kayıplar ve görüntülerde bulanıklık meydana gelmektedir.

m. Görev odaklı akış (Task-Oriented Flow-ToFlow): Gürültülü videoların temizlenmesi için optik akış kavramını kullanarak gürültü gidermeyi yapmayı amaçlayan bir yöntemdir [120]. Optik akış, hareket eden nesnelerin ve piksellerin bir çerçeveden diğerine nasıl hareket ettiğini tanımlayan bir kavramdır. Bu metot görüntü üzerindeki hareketin çerçeveler arasındaki dağılımını dikkate alarak gürültüyü gidermeye çalışmaktadır. Bu, hızlı hareket eden nesnelerin veya kamera hareketlerinin neden olduğu gürültüyü daha etkili bir şekilde

azaltmaktadır. Optik akış bilgisini kullanmak, piksel hareketini ve farkları daha doğru bir şekilde hesaplayarak, gürültü azaltma sürecini iyileştirmektedir.

n. ViDeNN: Gürültü dağılımı hakkında önceden bilgiye sahip olmadan, evrişimli sinir ağlarını kullanarak gürültü gideren bir modeldir [121]. Modelde kullanılan CNN mimarisi, önce görüntü kareleri üzerinde uzaysal olarak gürültü giderimi yaptıktan sonra komşu üç görüntü üzerinde zamansal gürültü giderme işlemi yapmaktadır. ViDeNN modeli düşük ışık koşulları için özel bir veri kümesi kullanılarak eğitilmiş olup, düşük ışık koşullarında gürültü giderimi alanında başarılı sonuçlar elde etmektedir.

o. SCUNet: Bu derin öğrenme modeli gerçek görüntülerde eşleşmiş temiz görüntü çifti olmadan gürültü giderimi amacıyla kullanılmaktadır [122]. Farklı görüntü çerçeveleri arasındaki bağlantıyı bulabilmek ve iki piksel arasındaki ilişkiyi modellemek için kayan pencereler kullanılmaktadır. Model kayan pencereleri kullanarak benzer görüntüleri bloklara ayırıp, U-Net mimarisi ile oluşturulan evrişim katmanlarıyla gürültü giderimi yapmaktadır. Görüntünün boyutlarının artmasıyla oluşacak bellek problemine karşı, görüntü küçük parçalara ayrılmakta ve farklı görüntü boyutlarında başarılı sonuçlar elde edebilmesi sağlanmaktadır.

Otokodlayıcıların gürültü gideriminde kullanımı

Otokodlayıcılar, gözetimsiz öğrenme görevlerinde kullanılan ve genellikle boyut indirgeme, gürültü giderme ve veri sıkıştırma gibi uygulamalarda başarılı olan bir yöntemdir. Bu yöntemde gizli katmanlar kullanılarak, büyük boyutlu girdi verileri küçük boyutlara sıkıştırılarak gürültü giderme işlemi yapılmaktadır. Otokodlayıcılar, doğrusal olmayan aktivasyon fonksiyonları ve çoklu katman yığınları kullanarak, ağa doğrusal olmayan bir yapı kazandırmaktadır [123].

Otokodlayıcılar genellikle veri boyutunu azaltmak amacıyla kullanılmaktadır. Otokodlayıcı mimarisi özelleştirilerek özellik seçimi, çıkarım ve gürültü giderimi gibi farklı amaçlarla da kullanılabilir. Gürültü giderimi için tasarlanmış otokodlayıcı mimarileri aşağıdaki bölümde ele alınmıştır.

a. Gürültü azaltan otokodlayıcı: Otokodlayıcılarda, gizli katmandaki düğüm sayısı girdi verilerinden fazla olduğunda, modelin aşırı uyum sorunu nedeniyle, otokodlayıcı daha fazla gürültü gideremez. Otokodlayıcılarda bu durum, gizli katmandaki giriş değerlerinden bazıları rastgele devre dışı bırakılarak çözülmektedir. Gürültü gideren otokodlayıcı kullanılarak, aşırı öğrenme engellenip, daha iyi görüntü elde etmek için görüntülere gürültü eklenerek, görüntü tekrar elde edilmeye çalışılmaktadır [124].

b. Yığıt gürültü gideren otokodlayıcı: Bu yöntemde, otokodlayıcı mimarisine daha fazla gizli katman eklenerek, verinin karmaşıklığı modellenip, daha derin ve geniş bir öğrenme yeteneği elde edilebilmektedir. Gürültü giderme için kullanılan bu yöntemde veriler daha çok sıkıştırılarak veri üzerinde temsil öğrenimi yapılmaktadır [125]. Yığıt gürültü gideren otokodlayıcılarda modelin başarısı, gürültüsüz görüntü ile elde edilen görüntüye ait piksel değerleri karşılaştırılarak hesaplanmaktadır. Yığıt gürültü gideren otokodlayıcılarda bazı nöronlar devre dışı bırakılarak daha derin bir ağı kurulması sağlanabilmektedir.

c. Evrişimsel gürültü gideren otokodlayıcı (Convolutional Denoising Autoencoder-CDAE): Bu yöntemde, çözümleme işlemleri sıralı bir şekilde değil, kodlama ile birleştirilebilmektedir. Bu yaklaşım, önemli verilerin sıkıştırılmadan çıktı olarak kullanılmasına olanak tanmaktadır. Özellikle tıbbi görüntülerde gürültüyü azaltmak ve görüntülerde bozulmaları düzeltmek amacıyla evrişimli gürültü gideren otokodlayıcılar kullanılmaktadır. Bir araştırmada, göğüs röntgen filmlerindeki gürültüyü azaltmak için evrişimsel gürültü gideren otokodlayıcı mimarisi kullanılmış olup, model gürültüyü başarıyla kısa sürede gidermiştir [30].

d. Gürültü gideren varyasyonel otokodlayıcı: Seyrek otokodlayıcı yaklaşımında, daha az veri ile işlem yapmak amacıyla aktivasyon fonksiyonları kullanılarak daha az sayıda nöronun aktive edilmesi sağlanmaktadır. Bu sayede gereksiz bilgiler hesaplamaya dahil edilmemektedir. Benzer bir mimariye sahip olan varyasyonel otokodlayıcı, gizli katmandaki vektörlerin dağılımını normal dağılıma zorlamak için tasarlanmış bir gözetimsiz ve üretken otokodlayıcı modelidir [126]. Gürültü gideren varyasyonel otokodlayıcı, normal verilere gürültülü veriler ekleyerek, ağ üzerinde daha derin ağlar oluşturabilmektedir [127]. Bu yaklaşım, bozulmuş görüntülerden temiz görüntü elde etmek ve görüntüleri sınıflandırmak için kullanılmaktadır [128].

Yinelemeli sinir ağı

Yinelemeli sinir ağı (Recurrent Neural Network-RNN) mimarisinde yapılan işlemler, ağı sadece o anki girdi değerine bağlı olmadan, gizli katmandaki girdilere de bağlı olarak yapılmaktadır. RNN kullanarak videolarda gürültü giderimi için yapılan çalışmada; videoda üst üste binen görüntüler bloklara ayrılarak, bu bloklardaki verilerin ortalama değerleri alınıp, gürültü giderme işlemi yapılmaktadır [133]. Yapılan diğer bir çalışmada yinelemeli sinir ağları kullanılarak EKG sinyallerindeki gürültülerin giderimi yapılmıştır [134].

Uzun kısa süreli bellek yapısı (Long Short-Term Memory-LSTM), RNN mimarisine göre bilgiyi uzun süre hatırlama yeteneğine sahiptir. Uzun süreli bellekler, önceki verilerle yeni kararlar almaya, verileri gelecekte kullanmaya ve bilgileri depolamaya olanak sağlayan kapılar içermektedir. Akciğer tomografi görüntülerinde meydana gelen gürültülerin giderilmesi amacıyla LSTM yöntemi kullanılmış başarılı sonuçlar elde etmiştir [135].

Kısıtlanmış boltzmann makineleri

Kısıtlı boltzmann makinesi iki katmanlı sinir ağlarıdır. Gürültü oranı yüksek görüntüler üzerine yapılan çalışmada, Kısıtlanmış boltzman makinesinde derin ağların kullanılması ile gürültü gideren otokodlayıcı başarılı sonuçlar ortaya çıkarmaktadır [136].

Derin inanç ağları

Derin inanç ağları, Kısıtlanmış boltzmann makinelerinin iki katmanlı ağ yapısını daha da derinleştirmek amacıyla oluşturulmuştur. Derin inanç ağları görüntülerde gürültü giderme için de kullanılmış olup, yapılan bir çalışmada, toplanabilir beyaz gauss gürültüsü ile bozulmuş MNIST veri kümesine derin inanç ağları uygulanarak başarılı sonuçlar elde edilmiştir [137]. Derin inanç ağları gürültü giderme sürecinde, düşük seviyeli gürültüyü temsil etmek için uygun bir mimariye sahiptirler. Derin inanç ağları bu sayede, gürültü giderme görevinde karşılaşılan karmaşık ve doğrusal olmayan gürültü türlerini daha etkili bir şekilde giderebilmektedirler.

Üretici çekışmeli ağlar

GAN, iki temel bileşen olan bir üretici model ve bir ayırt edici model içermektedir. Bu iki model birbirleriyle rekabet ederek gürültü gidermeye çalışırlar. Eşleştirilmemiş gürültülü görüntüleri işlemek için, evrişimsel kör gürültü gideren ağ (Convolutional Blind Denoising Network-CBDNet) [138], biri gerçek gürültülü görüntünün gürültüsünü tahmin etmekten, diğeri ise temiz görüntüyü elde etmekten sorumlu olan iki alt ağ ile görüntüden gürültü giderilmiştir. Başka bir çalışmada GAN ve U-Net ağları kullanılarak, akıllı telefon görüntü gürültü giderme veri seti kullanılarak başarılı sonuçlar elde edilmiştir [139]. GAN modelleri, öğrenme sürecinde veri dağılımını doğrudan modelleyebilmektedirler. Bu, modelin gürültüyü daha iyi anlamasına ve gürültüyü giderme görevinde daha etkili olmasına olanak tanımaktadır. Model, gerçek görüntülerle benzer özelliklere sahip gürültüsüz görüntüler üretebilecek şekilde öğrenmektedir.

3. VIDEO GÖRÜNTÜLERİ VE GÜRÜLTÜ TURLERİ

Video, hareketli görüntülerin kaydedilmesi veya iletilmesi için kullanılan bir görsel medya formatıdır. Video, bir dizi görüntü çerçevesinden oluşmakta, her bir çerçeve ardışık olarak oynatılarak hareketli bir görüntü elde edilmektedir. Bugün görüntüler işlenerek bilgiler elde edilmekte, bilgi taşıyıcıları olarak kullanılan görüntüler ve videolar hayatımızda geniş bir şekilde kullanılmaktadır. Günümüzde teknolojinin gelişmesiyle birlikte video kalitesi artmakta ve videoların farklı kullanım alanları ortaya çıkmaktadır. Videoyu kullanım alanlarını göre aşağıdaki gibi sıralayabiliriz:

1. Televizyon ve film endüstrisi: Video, televizyon programları, filmler ve diğer görsel medya içeriklerinin oluşturulmasında yaygın olarak kullanılmaktadır. Bu alanlarda video, hikâye anlatımı, efektler ve görsel verilerin iletilmesinde önemli bir rol oynamaktadır.
2. Eğitim ve e-öğrenme: Video, eğitim materyallerinin oluşturulması ve dağıtılmasında etkili bir araçtır. E-öğrenme platformlarında, derslerin video formatında sunulması öğrencilere daha etkili bir öğrenme deneyimi sağlamaktadır.
3. İnternet ve sosyal medya: Video, internetin yaygınlaşması ile birlikte sosyal medya platformlarında yoğun olarak kullanılmaktadır. Kullanıcılar, video paylaşım sitelerinde kendi videolarını yükleyip, canlı yayınlar yaparak sosyal ağlarda video içerikleri paylaşabilmektedirler.
4. Güvenlik ve gözetim: Video, güvenlik kameraları ve gözetim sistemleri tarafından kullanılmaktadır. Bu sistemler, kamu alanlarında, işyerlerinde ve evlerde güvenliği artırmak için kullanılmaktadır. Video kayıtları, suç soruşturmalarında kanıt olarak kullanılabilir.
5. Tıp ve cerrahi: Tıp alanında video, cerrahi operasyonların kaydedilmesi ve incelenmesinde önemli bir rol oynamaktadır. Cerrahlar, video kayıtlarını kullanarak ameliyat sürecini inceleyebilmekte ve eğitim materyalleri oluşturup uzman görüşleri alabilmektedirler.
6. Sanal gerçeklik ve artırılmış gerçeklik: Video, sanal gerçeklik ve artırılmış gerçeklik deneyimlerinin oluşturulmasında kullanılmaktadır. Sanal gerçeklik gözlükleri veya artırılmış gerçeklik cihazları ile kullanıcılar, video tabanlı simülasyonlarla etkileşime girebilir ve farklı dünyaları deneyimleyebilmektedir.

Video kareleri de görüntüler gibi piksellerden oluşmaktadır. Dijital bir görüntünün 2 boyutlu dizi şeklindeki her bir elemanına bir piksel denilmektedir. Görüntüler, resmin farklı piksel boyutlarıyla ifade edilmektedir. Piksellerin sayısı arttıkça görüntünün uzaysal çözünürlüğü ve görüntünün sahip olduğu ayrıntılar artmaktadır. Görüntüler ilk zamanlarda gri ve tonları şeklinde kullanıcılara iletilmekte olup, sonraki yıllarda renkli görüntüler elde edilmiş ve görüntü kalitesi artırılmıştır. Gri ve renkli görüntülerde pikseller farklı veri desenleri şeklinde saklanmaktadır. Gri seviye sınırlarında siyah ve beyaz renkler bulunmaktadır. Bu ikisi arasında kodlanan görüntülere ise gri ton görüntüler adı verilmektedir. Her bir piksel genellikle 8 bit ile kodlanmaktadır. Bu tip görüntülerde her bir piksel 256 farklı renk değerinden oluşmaktadır. 0 ile ifade edilen renk seviyesi siyah renge, 255 değeri beyaz renge ve bu değerler arasındaki seviyeler ise grinin tonlarına karşılık gelmektedir. Renkli görüntüler, kırmızı, yeşil, mavi ile üç farklı veri dizisinin üst üste ekranda gösterilmesi ile oluşmaktadır [140].

Televizyon yayıncılığının ve video kayıt cihazlarının ilk dönemlerinde kullanılan analog video teknolojisiyle, radyo dalgaları ve analog kablo üzerinden veri iletimi sağlanmıştır. Bu tür videolar, analog sinyallerin elektronik olarak işlenmesiyle üretilmekte ve radyo frekansı sinyalleri olarak yayınlanmaktadır. Analog video, dalga şekilleri ve gerilim seviyeleri gibi sürekli değişen fiziksel değerler kullanmaktadır. Analog video sistemleri, PAL, SECAM gibi farklı video standartlara sahiptirler. Analog sinyallerin dezavantajı, kalite kaybı ve sinyal bozulması yaşama olasılıklarının daha yüksek olmasıdır. Bu nedenle yüksek çözünürlük ve netlik gerektiren modern görüntüleme ihtiyaçlarını karşılamak için dijital teknolojiye geçiş yapılmıştır.

3.1. Video Verilerinin Sıkıştırılması

Dijital video, verilerinin sayısal formatlarda temsil edildiği bir formattır ve görüntüyü pikseller halinde saklayıp, işleyerek yüksek kalitede görüntü sağlamaktadır. Dijital video, binlerce renk ve parlaklık seviyesi içeren yüksek çözünürlükte görüntüler sunabilmektedir. Dijital videolar, yüksek kaliteli görüntüler sağlamak ve görüntü sayısal formatta temsil edildiği için daha kolay işlenebilmektedir. Dijital video, video kameralar, dijital fotoğraf makineleri, akıllı telefonlar ve diğer dijital cihazlar tarafından üretilmektedirler. Dijital

görüntüler genellikle jpeg, png gibi bitmap formatlarında saklanmaktadır. Dijital video sıkıştırma algoritmaları ile videolar daha düşük dosya boyutlarına sıkıştırılabilmektedirler. Popüler dijital video sıkıştırma formatları arasında MPEG-4, H.264, H.265 gibi sıkıştırma standartları yer almaktadır.

Sıkıştırma, görüntülerin iletim kanalında daha küçük paketler halinde iletimini sağlamak için kullanılmaktadır. Dijital videonun, iletimi ve depolanması için uygun bir formata dönüştürülerek, veri boyutunda azalma sağlanmaktadır. Sıkıştırılmış veriler daha sonra kod çözücü tarafından orijinal video verilerinin bir temsiline dönüştürülmektedir. CODEC, kodlayıcı/kod çözücü çifti için yaygın olarak kullanılan bir terimdir. Video kodlayıcı/kod çözücü, sıkıştırma sonucu veri kaybına göre ikiye ayrılmaktadırlar. Veri kaybeden video kodlayıcı/kod çözücü, görüntü kalitesini genellikle belirli bir düzeye düşürmektedirler, örnek olarak H.264, H.265, VP9 gibi video kodlayıcı/kod çözücüleri bu kategoriye girmektedir. Veri kaybı olmayan video kodlayıcı/kod çözücüler, videolarda çok fazla veri kaybına neden olmadığı için bu yöntemlerin sıkıştırma oranları genellikle daha düşük kalmaktadır.

3.2. Video Verileri

Video verileri, ses ve resim karelerinin bir araya gelmesi ile oluşmaktadır. Görüntü verisi, video çerçevelerine ait piksellerin renk ve parlaklık değerlerini içermektedir. Zaman verisi, her karenin ne kadar süreyle gösterileceği, videonun başlama ve bitiş süreleri gibi bilgileri içermektedir. Videolar genellikle görüntü yanında ses içeriği de bulundurmaktadırlar. Bu ses verisi genellikle dalga formunda ses dalgalarının zaman içindeki değişimini temsil etmektedir. Videolar boyutları nedeniyle sıkıştırılarak belirli bir formatta saklanmaktadır. Önemli video formatları Çizelge 3.1’de sunulmuştur.

Çizelge 3.1. Video formatları

Video Format İsmi	Dosya Uzantısı	Açıklama
YUV	.yuv	Bu dosya formatı işlenmemiş video dosyasıdır ve tüm çözünürlükleri, örnekleme yapılarını ve kare hızlarını desteklemektedir.
AVI	.avi	Video ve ses dosyalarını bir arada içeren dosyalara verilen isimdir, dosyalar sıkıştırılarak saklanabilmektedir.
MPEG-4	.mp4, .m4p, .m4v	Ses görüntü ve altyazıların saklanabildiği dosya formatıdır.
Vob	.vob	Videoların sıkıştırılmasına imkân sağlayan bir formattır. DVD formatındaki videoların saklanması sağlamaktadır.
Ogg	.ogg	Ogg dosya biçimi, video, ses, metin ve metadata bilgilerini birlikte taşıyabilen açık kaynak bir formattır.

YUV videolarının kullanımı

YUV video formatı, parlaklık (Y) bileşeni ve renk (U, V) bileşenlerinden oluşan bir renk modelidir. YUV, sıkıştırılmamış veya düşük sıkıştırımlı video dosyalarında kullanılmaktadır. Derf videoları YUV renk uzayını kullanmaktadır. YUV formatında bir dosya başlığı, veri ve dosya sonu bilgisi yer almaktadır. Parlaklık bileşeni, gri tonlamaları temsil ederken, renk bileşenleri renk farkı bilgisini içermektedir. Parlaklık bilgisi olarak 0, siyah renge karşılık gelirken, 255 beyaz renge karşılık gelmektedir. U ve V bileşenleri, YUV renk uzayında renklerin farkını temsil etmektedir. Bu bileşenler, piksel değerleri aracılığıyla renk bilgilerini taşımaktadırlar. U bileşeni, mavi renk kanalıyla yeşil renk kanalı arasındaki renk farkını temsil etmektedir. Pozitif U değerleri daha yeşil renkleri, negatif U değerleri ise daha mavi renkleri ifade eder. U bileşeninde 128 değeri, gri tonlarında bir renge karşılık gelirken, daha düşük veya daha yüksek değerler, yeşil veya mavi renk tonunun yoğunluğunu gösterir. V bileşeni, kırmızı renk kanalıyla yeşil renk kanalı arasındaki renk farkını temsil etmektedir. Pozitif V değerleri daha kırmızı renkleri, negatif V değerleri ise daha yeşil renkleri ifade etmektedir. V bileşeninde 128 değeri, nötr bir renge karşılık gelirken, daha düşük veya daha yüksek değerler, kırmızı veya yeşil renk tonunun yoğunluğunu göstermektedir. RGB renk modeliyle karşılaştırıldığında, YUV renk uzayının farklılıkları ve avantajları şu şekilde sıralanabilmektedir:

- Yüksek parlaklık hassasiyeti: Y bileşeni, parlaklık bilgisini temsil etmektedir. Y

bileşeni gri tonlamaları ifade eder ve insan gözünün parlaklık değişikliklerine daha duyarlı olduğu için bu değer farklı bir bileşen olarak tutulmaktadır.

b. Renk farkları: U ve V bileşenleri, renk farklarını temsil etmektedir. U bileşeni, kırmızı ve yeşil renk arasındaki renk farkını ifade ederken, V bileşeni, mavi ve sarı renk arasındaki renk farkına ait bilgiyi tutmaktadır. RGB renk modelinde, renkler kırmızı, yeşil ve mavi bileşenlerinin birleşimi olarak ifade edilirken, YUV renk modelinde renkler parlaklık bileşeni (Y) ve renk farkı bileşenleri (U, V) olarak ayrı ayrı ifade edilmektedir. Renklerin parlaklık bilgisinden bağımsız olarak işlenmesi ve sıkıştırılması işlem kolaylığı sağlamaktadır.

c. Veri boyutlarının küçültülmesi: YUV formatındaki verilerde, renk bileşenlerinin çözünürlüğü parlaklık bileşenine göre daha düşük olmaktadır. Bu sayede, renk verilerinin daha az yer kaplaması sağlanırken, insan gözü için fark edilmeyen bir kayıp elde edilmektedir. Bu avantaj, video sıkıştırma ve iletiminde daha verimli bir kullanım sağlamaktadır.

d. Renk dönüşümü kolaylığı: YUV renk uzayı, RGB renk uzayına ve diğer renk uzaylarına dönüşüm işlemlerinde kullanışlı olmaktadır. RGB'den YUV'a veya YUV'dan RGB'ye dönüşüm, renk düzeltme, video işleme ve sıkıştırma gibi birçok uygulamada yaygın olarak kullanılmaktadır.

Modelin eğitimi aşamasında kullanılan Derf videoları sıkıştırılmamış YUV4MPEG formatına sahiptirler. YUV4MPEG formatı, videoyu sıkıştırmadan veya işlem yapmadan sakladığı için genellikle büyük dosya boyutlarına sahip olabilmektedir. Bu nedenle, sıkıştırılmış video formatları genellikle daha yaygın olarak kullanılmaktadır. YUV4MPEG formatı, farklı örnekleme formatlarını desteklemekte olup, YUV420, YUV422 ve YUV444 gibi yaygın örnekleme formatları vardır. YUV420 formatı, video sıkıştırma ve video akışı gibi düşük bant genişliği gerektiren uygulamalarda yaygın olarak kullanılmaktadır. YUV420 formatında her 2x2 piksel grubu için bir renk örneği içermektedir. Yani bir renk örneği, dört pikselin parlaklık bilgileri için kullanılmaktadır. YUV422 formatı, her 2 piksel için bir renk örneği içermektedir. Bu nedenle renk örnekleme oranı daha yüksektir ve renk doğruluğu artmaktadır. YUV424 formatı da her 2 piksel için bir renk örneği içermektedir ancak, YUV422'den farklı olarak, her iki piksel grubu için ayrı renk örnekleri sağlayarak daha yüksek renk doğruluğu oluşturulmaktadır. YUV4MPEG formatı, dosya içindeki video

verilerine ilişkin başlık bilgilerini içermektedir. Başlık bilgileri, video çözünürlüğü, örnekleme formatı, çerçeve hızı ve diğer parametreleri içermektedir. YUV4MPEG formatı, video çerçevelerini ardışık olarak saklamaktadır. Her çerçeve, parlaklık bileşeni (Y) ve renk bileşenleri (U, V) için ayrı ayrı veriler içermektedir. Modelin eğitimi aşamasında YUV formatını kullanan Derf kümesi kullanılmış olup, Derf veri kümesinde kullanılan bu video formatında gürültü giderme işlemi yapılmadan önce RGB formatına dönüştürülmüş ve gürültü giderme işlemi yapılmıştır.

3.3. Video Çözünürlükleri

Video çözünürlüğü, bir görüntünün sahip olduğu piksel sayısı ile belirtilmektedir. Daha fazla piksel, daha yüksek kaliteli görüntü anlamına gelmektedir. Yaygın olarak kullanılan video çözünürlükleri Çizelge 3.2’de sunulmuştur.

Çizelge 3.2. Video çözünürlük değerleri

Çözünürlük Adı	Piksel Boyutu
SD	640 x 480
HD	1280 x 720
Full HD	1920 x 1080
QHD	2560 x 1440
2K	2048 x 1080
4K	3840 x 2160
8K	7680 x 4320

Modelin eğitimi sırasında kullanılan videoların çözünürlükleri CIF video formatında ifade edilmektedir. CIF, video sistemlerinde kullanılan dijital video dizilerinin görüntü çözünürlüğü, kare hızı, renk alanı için kullanılan standart bir formattır. İlk olarak 1988 yılında H.261 standardında tanımlanmıştır. Bir CIF, NTSC formatında 352×240 piksel; Pal formatında ise 352×288 pikseldir. Full çözünürlük ise 4 CIF’tir [141]. CIF formatlarına ait çözünürlük değerlerine ait bilgiler Çizelge 3.3’de sunulmuştur.

Çizelge 3.3. CIF formatlarına ait çözünürlük değerleri

Format	Çözünürlük (Yatay x Dikey)
Sub-QCIF	128 x 96
QCIF	176 x 144
CIF	352 x 288
4CIF	704 x 576
16CIF	1408 x 1152

1080 piksel yüksek çözünürlüklü bir görüntüde yatayda 1920 piksel, dikeyde 1080 piksel gösterilebilmektedir. Bu video görüntüsünün saniyede 25 kare iletimi sağlanırsa, her saniyede 51.840.000 piksel iletilmektedir.

3.4. Video Üzerindeki Gürültüler


Video gürültüsü, bir sensör, tarama devresi veya dijital kamera tarafından üretilen bir görüntünün parlaklık veya renk üzerindeki rastgele değişimi olarak da ifade edilmektedir. Videoda genellikle karşılaşılan gürültü türleri gaussian, poisson, rician, tuz, karabiber ve benek gürültüleridir. Videonun boyutunu azaltma sırasında kullanılan sıkıştırma programları da video görüntülerinde bozulmalara neden olmaktadır. Video gürültüsü, video kalitesini düşürüp, görüntü analiz ve işleme aşamalarını etkileyebilmektedir. Video üzerindeki gürültüler, verinin aktarımı ve görüntü elde etme sırasında meydana gelmektedir.

Görüntü aktarma sırasında verilerin bozulması

İletim ortamı ve mesafesi, verinin iletiminde bozulmalara neden olmakta ve görüntü kalitesini düşürmektedir. Sinyaldeki zayıflama, sınırlı bant genişliği, sinyallerdeki gecikme gecikme ve çevresel etkiler, sinyallerin bozulmasına ve gürültüye neden olmaktadır [142].

- Zayıflama: Görüntüye ait sinyal gücünün azalmasıdır. Sinyal gücü desibel ile ifade edilmektedir.
- Sınırlı bant genişliği: Verinin iletim zamanını etkileyen önemli bir faktör olup, sınırlı bant genişliğinde veri hızı düşmekte ve veri kayıpları meydana gelmektedir.
- Gecikme bozulması: Gecikme bozulması, orijinal sinyal ile elde edilen sinyalin farklı olduğu durumda meydana gelmektedir. Hedefe farklı süre ve sırada varan sinyaller verinin bozulmasına neden olmaktadır.

- **Gürültü:** Gürültü, sinyal ve görüntüleri bozarak, görüntüdeki piksel değerlerini değiştirmektedir. İletişim sistemlerinde kullanılan elektronik devrelerde, iletken ve yarı iletken materyallerin çevresel ve kendi ürettikleri ısıdan kaynaklanan olumsuz etkiler sonucu ortaya çıkan gürültü, termal gürültü olarak adlandırılmaktadır. İndükleme gürültüsü, motor gibi cihazlar nedeniyle oluşabilmektedir. Karışma bir kablunun diğerini etkilemesiyle oluşmaktadır. Darbe gürültüsü, öngörülemeyen ve aniden oluşan etkiler sebebiyle ortaya çıkmaktadır. Görüntülerde tuz karabiber gürültüsü, benek, Poisson, Gaussian, Rician gürültüleri meydana gelebilmektedir. Şekil 3.1’de gürültünün orijinal sinyali nasıl etkilediği gösterilmektedir.



Şekil 3.1. Sinyallerdeki gürültü

Görüntü yakalama sırasında verilerin bozulması

Video görüntüleri, parlaklığın sinüzoidal modülasyonu şeklinde gözükken rastlantısal olmayan periyodik gürültülerle bozulabilmektedirler. Bu tür gürültüler görüntüye bir motor veya bir elektromekanik aygıttan elektriksel veya elektromanyetik girişim sonucu karışabilmektedir. Titreşim ile görüntülerin birbiri üzerine gelmesi, periyodik gürültülere neden olmaktadır. Bir görüntü taranırken, tarayıcının çözünürlüğü görüntünün yüksek frekans bileşenlerine etki etmekte ve görüntüler birbiri üzerine çakışmaktadır.

3.5. Gürültü Türleri

Kontrollü olarak gürültülü oluşturmak zor olduğu için, gürültü giderme modellerinin eğitiminde toplanabilir beyaz gauss gürültüsü yaygın olarak kullanılmaktadır [143]. VGGM’nin gürültü giderme başarısı test edilirken Gauss gürültüsü, Poisson, tuz, karabiber, benek, gürültüleri üzerine çalışma yapılmıştır. Aşağıda video üzerinde yaygın olarak görülen gürültü türleri sunulmuştur [144].

a. Gauss gürültüsü: Gauss eğrisi, bir istatistiksel dağılım olan normal dağılımı ifade etmektedir. Gauss eğrisi, bir orta nokta etrafında verilerin simetrik olarak dağıldığı çağ eğrisi şeklinde gösterilmektedir. Eş. 3.1'de gösterildiği üzere, orta nokta olan ortalama, eğrinin simetrik olduğu yeri, varyans, verilerin ortalamadan ne kadar uzaklaştığını ve dağılımın yayılma derecesini belirlemektedir. Gauss eğrisi, matematiksel olarak, üç parametre ile tanımlanmaktadır: ortalama (μ), varyans (σ^2) ve standart sapma (σ).

$$\sigma^2 = \frac{\sum_{i=1}^N (X_i - \mu)^2}{N-1} \quad (3.1)$$

Bu formülde σ^2 standart sapmayı, μ ortalama değeri, N ise veri sayısını belirtmektedir. Standart sapma veri değerlerinin yayılımının özetlenmesi için kullanılan bir ölçüdür. Eş. 2.2'de gösterilen standart sapma varyansın karekökü şeklinde hesaplanır ve verilerin dağılımındaki değişkenliği ölçmektedir.


$$\sigma = \sqrt{\frac{\sum_{i=1}^N (X_i - \mu)^2}{N-1}} \quad (3.2)$$

Standart sapma veri değerlerinin aritmetik ortalamadan farklarının karelerinin toplamının veri sayısının bir eksiğine bölümünün kareköküdür. Bu formülde σ standart sapmayı, μ ortalama değeri, N ise veri sayısını belirtmektedir. Bu formüller sonucu normal dağılım ya da gauss eğrisi ortalama değeri 0 ve varyans değeri 1 olan normal dağılımı ifade etmektedir.

Görüntü üzerine eklenen gürültülerde gürültünün şiddetini belirlemek için sigma değeri kullanılmaktadır. Sigma değeri, gürültünün yoğunluğunu belirleyen bir parametredir. Sigma değeri ne kadar yüksekse, gürültünün etkisi o kadar fazla olmaktadır. Piksel değeri 0 siyahı, piksel değeri 255 ise beyaz değeri ifade etmektedir. Eklenen gürültü görüntüde beyaz, siyah ve renkli kalıntılar oluşturmaktadır. Bir görüntüye gauss gürültüsü ekleme aşamasında, seçilen sigma değerine bağlı olarak renkli görüntülerde, her bir renk kanalı için ayrı bir gürültü matrisi oluşturulmaktadır. Sigma değeri, maksimum piksel değeri olan 255'e oranlanarak normal dağılıma sahip, gürültü değerleri matrisi orijinal resmin ilgili piksellerine eklenmektedir. Gauss gürültüsünün görüntüde nasıl bir bozulmaya neden olduğu Resim 3.1'de gösterilmektedir.



Orijinal Görüntü



Gauss Gürültüsü

Resim 3.1. Gauss gürültüsü

b. Poisson gürültüsü: Poisson gürültüsü, istatistiksel olarak poisson dağılıma sahip olan bir tür rastgele gürültüdür. Poisson dağılımı, nadir meydana gelen rastgele olayların belirli bir zamanda gerçekleşme olasılığını modellemek için kullanılmaktadır. Özellikle radyasyon gibi süreçlerin analizinde sıkça kullanılmakta olup, bu gürültü özellikle düşük ışık seviyelerindeki görüntüleme sistemlerinde meydana gelmektedir. Her piksele, fotonların belirli bir hızda düşmesi beklenmektedir, ancak poisson gürültüsünde bu rastgelelik, piksel değerlerinde poisson gürültüsünün oluşmasına neden olmaktadır. Daha yüksek ortalama değerlere sahip piksellerde, poisson gürültüsü daha belirgin olmakta, beyaz renge sahip pikseller daha parlak görünmektedir. Gauss gürültüsü, piksel değerlerinde sürekli bir varyasyon sağlarken, poisson gürültüsü daha dar, kesikli ve yüksek frekanslı dalgalanmalar sergilemektedir. Poisson gürültüsü oluşturulurken, gürültü değeri λ ile ifade edilmektedir. Poisson gürültüsünün görüntüde nasıl bir bozulmaya neden olduğu Resim 3.2’de gösterilmektedir.



Orijinal Görüntü



Poisson Gürültüsü

Resim 3.2. Poisson gürültüsü

c. Tuz Gürültüsü: Bu gürültü, görüntülerde rastgele beyaz noktaların oluştuğu bir tür gürültüdür. Tuz gürültüsü genellikle analog görüntünün dijitalleştirilmesi sırasında yanlış örnekleme, veri iletimi sırasında hatalar veya elektriksel parazitler gibi dış etkenler nedeniyle meydana gelebilmektedir. Tuz gürültüsü, bir görüntüde bazı piksel değerlerinin maksimum değer olan beyaza dönüştürülmesiyle oluşmakta, bu nedenle, bazı pikseller tamamen beyaz bir görüntüye sahip olmaktadır. Tuz gürültüsünü algılamak ve etkilenen piksel değerlerini düzeltmek için filtreleme teknikleri kullanılmaktadır. Tuz gürültüsünün görüntüde nasıl bir bozulmaya neden olduğu Resim 3.3’de gösterilmektedir.



Orijinal Görüntü



Tuz Gürültüsü

Resim 3.3. Tuz gürültüsü

d. Karabiber gürültüsü: Görüntülerde rastgele siyah noktaların oluştuğu bir tür gürültüdür. Karabiber gürültüsü, görüntü işleme veya veri iletimi sırasında meydana gelebilmektedir. Tuz gürültüsü, bir görüntüde bazı piksel değerlerinin minimum değer olan siyaha dönüştürülmesiyle oluşmakta, bu nedenle, bazı pikseller tamamen siyah bir görüntüye sahip olmaktadır. Tuz gürültüsünün görüntüde nasıl bir bozulmaya neden olduğu Resim 3.4’de gösterilmektedir.



Orjinal Görüntü



Karabiber Gürültüsü

Resim 3.4. Karabiber gürültüsü

e. Benek gürültüsü: Benek gürültüsü, görüntülerde piksel değerlerinde rastgele dalgalanmaların meydana geldiği bir tür gürültü türüdür. Bu gürültü genellikle radar görüntülemesi, ultrasonografi ve sentetik açıklıklı radar ile elde edilen görüntülerde oluşmaktadır. Benek gürültüsünde, parlak benekler, piksel değerlerinin arttığı bölgeleri temsil ederken, koyu benekler piksel değerlerinin azaldığı bölgeleri temsil etmektedir. Bu tür yansımalar, kâğıt, beyaz boya, pürüzlü yüzeyler gibi alanlarda veya havadaki toz gibi çok sayıda parçacık bulunan ortamlarda meydana gelebilmektedir. Bir resme benek gürültüsü eklemek için çarpımsal gürültü ekleme yöntemi kullanılmaktadır. Gürültü ekleme işlemi Eş. 3.3’de belirtilen şekilde yapılmaktadır.

$$\text{Gürültülü Görüntü} = (\text{Görüntü} + (n \times \text{Görüntü})) \quad (3.3)$$

Bu formülde belirtilen n , belirtilen ortalama ve varyansa sahip gauss gürültüsüdür. Gürültü üretilirken görüntü üzerindeki her piksel için rastgele bir sayı üretilir ve rastgele sayılar, benek gürültüsü dağılımını temsil etmektedir. Görüntü piksel değerleri ile bu rastgele sayılar çarpılmaktadır. Benek gürültüsünün görüntüde nasıl bir bozulmaya neden olduğu Resim 3.5’de gösterilmektedir.



Orijinal Görüntü



Benek Gürültüsü

Resim 3.5. Benek gürültüsü

f. Sıkıştırma sonrası oluşan gürültüler: Video sıkıştırma algoritmaları videoyu düşük boyutlarda depolamak veya iletmek için kullanılmaktadır. Sıkıştırma işlemi görüntü üzerinde gürültüye neden olmaktadır. Bu gürültü türünde, görüntü üzerinde mozaik benzeri görüntü bozulmaları olmaktadır. Veri sıkıştırma sonrası görüntüde nasıl bir bozulmanın olduğu Resim 3.6'da gösterilmektedir.



Orijinal Görüntü



Veri Sıkıştırması Sonrası Oluşan Görüntü

Resim 3.6. Veri sıkıştırma gürültüsü

g. Rician gürültüleri, tıp görüntüleme, radyo iletişimi, astronomi ve radar gibi alanlarda karşılaşılan bir tür gürültü modelidir. Rician gürültü modelinde gerçek sinyal genellikle zayıf olup, gürültü seviyesi yüksek olmaktadır. Rician gürültüsü, tıbbi görüntüleme tekniklerinde yaygın olarak karşılaşılan bir sorundur. Rician gürültüsünün görüntüde nasıl bir bozulmaya neden olduğu Resim 3.7'de gösterilmektedir.



Orijinal Görüntü



Rician Gürültüsü

Resim 3.7. Rician gürültüsü

3.6. Videoda Gürültü Giderme Başarısını Değerlendirme Ölçütleri

Görüntülerde gürültü giderme algoritmalarının başarı oranını değerlendirmek için çeşitli ölçütler kullanılmaktadır. Kullanılan hesaplama yöntemlerine göre elde edilen sonuçlar farklılık göstermektedir. Video üzerinde gürültü giderme başarısını değerlendirirken sıklıkla kullanılan yöntemler aşağıda sunulmuştur [145-147].

a. Tepe sinyali gürültü oranı (Peak Signal-To-Noise Ratio-PSNR): PSNR, gürültü giderme sonucunun gerçek görüntüye olan benzerliğini ölçmektedir. PSNR, gürültü giderme sonucu görüntü ile gerçek görüntü arasındaki piksel değerlerinin benzerliğini hesaplamaktadır, daha yüksek bir PSNR değeri, daha iyi bir sonuç göstermektedir. PSNR hesaplarken ilk adımda, gerçek görüntü ve gürültü giderme sonucu elde edilen görüntü arasındaki fark hesaplanmaktadır. Bu hesaplamada görüntülerdeki piksel bazında fark alınıp, piksel farklarının kareleri bulunur ve bu karelerin ortalaması hesaplanmaktadır. Elde edilen sonuç, ortalama kare hatası (Mean Square Error-MSE) olarak adlandırılmaktadır. MSE, gürültü giderme sonucu görüntü ile gerçek görüntü arasındaki hata miktarını ölçmektedir. MSE'nin değeri, piksel değerleri 0 ile 255 arasında olduğunda daha büyük hesaplama gerektirdiğinden, hesaplamayı kolay karşılaştırılabilir hale getirmek için, PSNR hesaplanırken logaritmik bir ölçek kullanılmaktadır. Eş. 3.4'de PSNR değerinin hesaplanması için kullanılan formül gösterilmektedir.

$$PSNR = 10 \times \log(MAX^2 \div MSE) \quad (3.4)$$

Burada, MAX, piksel değerlerinin maksimum değeridir, RGB formatında bu değer 255'dir. MSE ise, ortalama karekök hatası değeridir. Elde edilen PSNR değeri, genellikle dB cinsinden ifade edilmektedir. PSNR, görüntü işleme ve gürültü giderme alanında sıkça kullanılan bir ölçüttür, ancak PSNR, insan görsel sistemine göre bazen yanıltıcı sonuçlara neden olabilmektedir. Bu nedenle, PSNR değeri tek başına bir görüntünün kalitesini değerlendirmek için yeterli olmayabilmektedir. Bu yüzden, PSNR değeri yanında diğer değerlendirme ölçütleri ve görsel değerlendirme yöntemleri de kullanılmaktadır.

b. Yapısal benzerlik endeksi (Structural Similarity Index Measure-SSIM): SSIM, gürültü giderme sonucunun gerçek görüntüye olan benzerliğini ölçerken, aynı zamanda algısal benzerlikleri de dikkate almaktadır. SSIM, görüntüler arasındaki yapısal benzerlikleri hesaplayıp, sonucu $[0, 1]$ aralığında bir değer olarak vermektedir. Daha yüksek bir SSIM değeri, görüntüler arasında benzerliğin fazla olduğunu göstermektedir. SSIM hesaplaması üç ana bileşen olan; parlaklık, kontrast ve yapısal benzerliklerinden oluşmaktadır. Parlaklık benzerliği, iki görüntünün parlaklık bilgisi arasındaki benzerliği ölçmektedir. Görüntülerin parlaklığı, piksel değerlerinin genel yoğunluğunu temsil etmektedir. Parlaklık benzerliği, görüntülerin piksel değerlerinin ortalamalarının karşılaştırılmasıyla hesaplanmaktadır. Kontrast benzerliği, iki görüntünün yoğunluk farklılıklarını temsil etmektedir. Kontrast benzerliği, görüntülerin standart sapmalarının karşılaştırılmasıyla hesaplanmakta olup, daha yüksek zıtlık benzerliği, görüntülerin zıtlık düzeyleri arasında daha fazla benzerlik olduğunu göstermektedir. Yapısal benzerlik, görüntülerin kovaryansının ve korelasyonunun karşılaştırılmasıyla hesaplanmaktadır. Daha yüksek yapısal benzerlik, görüntülerin yapısal ilişkileri arasında daha fazla benzerlik olduğunu göstermektedir. Bu üç işlemin birleşimiyle SSIM değeri hesaplanmaktadır. SSIM, piksel bazlı hata hesaplamalarından daha fazla bilgi sağlamakta ve insanın görsel algısına uygun sonuçlar elde edilmektedir. Eş. 3.5'de SSIM değerinin hesaplanmasına ait formül gösterilmektedir.

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (3.5)$$

Görüntüye ait piksel değerlerini x ve y olarak alacak olursak, SSIM değerini hesaplarken μ_x x değerlerinin ortalamasını, μ_y y değerlerinin ortalamasını, σ_x^2 sembolü x değerlerinin varyansını, σ_y^2 sembolü y değerlerinin varyansını, σ_{xy} sembolü x ve y değerlerinin

kovaryansını, c_1 ve c_2 değerleri bölme işlemini sabitlemek için kullanılan değişkenlerdir. Eş. 3.6'da c_1 değerinin nasıl hesaplandığı gösterilmektedir.

$$c_1 = (k_1 L)^2 \quad (3.6)$$

k_1 değerine başlangıçta 0,01 değerine atanmaktadır. Aynı şekilde c_2 değeri de aşağıdaki gibi hesaplanmaktadır. L değeri, 1 pikselin bit olarak değerini göstermektedir, normalde 255 değerini almaktadır. Eş. 3.7'de c_2 değerinin nasıl hesaplandığı gösterilmektedir.

$$c_2 = (k_2 L)^2 \quad (3.7)$$

k_2 değerine başlangıçta 0,03 değerine atanmaktadır. Yapılan bu hesaplar sonucunda görüntünün kalitesi ve gürültü giderme yöntemlerinin performansı ölçülmektedir.

c. Özellik benzerlik endeksi ölçümü (Feature Similarity Index Measurement-FSIM): Görüntüler arasındaki hem yapısal hem de algısal benzerlikleri dikkate alan bir ölçüttür. FSIM hesaplarırken ilk adımda, iki görüntü arasındaki yapısal benzerliği ölçmek için gabor filtreleri kullanılmaktadır. Gabor filtreleri, görüntüdeki yapılara duyarlı olan filtrelerdir. Bu filtreler, görüntüdeki farklı ölçeklere duyarlıdır. Gabor filtreleri kullanılarak her bir görüntü için özellik haritaları elde edilmektedir. Bu özellik haritaları, görüntünün farklı ölçekler ve yönlere duyarlı özelliklerini temsil etmektedir. Özellik haritaları kullanılarak, her bir görüntünün özellik istatistikleri hesaplanmaktadır. Özellik benzerlik endeksi yöntemi, iki görüntü arasındaki benzerlikleri ölçmek amacıyla özellikleri eşleyen bir yaklaşımı benimsemektedir. Görüntü özelliklerini belirlemede kullanılan bir metot olan Faz Uyumluluğu (Phase Congruency-PC) ise, görüntülerdeki ışık değişimlerinden etkilenmemektedir. Gradyan büyüklüğü (Gradient Magnitude-GM), gradyan operatörlerini ifade etmek için evrişim maskeleri kullanılmaktadır. $f(x)$ bir görüntüyü, G_x ve G_y yatay ve dikey gradyanları ifade etmektedir. $f(x)$ 'in gradyan büyüklüğü Eş. 3.8'deki gibi tanımlanmaktadır.

$$f(x) = \sqrt{G_x^2 + G_y^2} \quad (3.8)$$

Bu ölçümde, f_1 test görüntüsü ve f_2 referans görüntüsünün faz uyumları sırasıyla PC_1 ve PC_2 ile göstermektedir. İki görüntü f_1 ve f_2 'den çıkarılan faz uyumluluğu haritaları ve gradyan büyüklüğü haritaları G_1 ve G_2 iki görüntüden ayıklanmaktadır. FSIM, PC_1 , PC_2 , G_1 ve G_2 değerleri ile hesaplanmaktadır. Verilen iki görüntünün benzerliği Eş. 3.9'da gibi hesaplanabilmektedir.

$$S_{PC} = \frac{2 PC_1 PC_2 + T_1}{PC_1^2 + PC_2^2 + T_1} \quad (3.9)$$

Burada T_1 , S_{PC} 'nin kararlılığını artıran pozitif bir sabittir. T_1 değeri, PC değerlerine göre hesaplanmaktadır. Bu denklem, gerçek görüntüyle olan benzerliği ölçmek amacıyla kullanılmakta olup, 0 ile 1 arasında değerler üretmektedir. Benzer şekilde, G_1 ve G_2 'den benzerliği Eş. 3.10'daki gibi hesaplanabilmektedir.

$$S_G = \frac{2G_1 G_2 + T_2}{G_1^2 + G_2^2 + T_2} \quad (3.10)$$

Burada T_2 , gradyan büyüklük değerlerinin dinamik aralığına bağlı olan pozitif bir sabittir. S_{PC} ve S_G , f_1 ve f_2 'nin benzerlik S_L değerini hesaplamak için birleştirmektedir. Bu eşitlik S_L olarak tanımlanmakta olup, Eş. 3.11'deki gibi elde edilmektedir.

$$S_L(x) = [S_{PC}(x)]^\alpha \times [S_G(x)]^\beta \quad (3.11)$$

Burada α ve β parametreleri PC ve GM özelliklerinin önemini ayarlamak için kullanılmaktadır. SSIM ve FSIM değerlerinin hesaplanması MSE ve PSNR değerlerinin hesaplanmasının aksine daha karmaşıktır. Bunun temel sebebi, MSE ve PSNR değerleri hata tabanlı yöntemlerken, SSIM ve FSIM metriklerinin benzerlik tabanlı yöntemler olmasıdır. FSIM hesaplaması, 0 ve 1 arasında değerler üretirken, birbirine benzeyen görüntülerde bu değer 1'e daha yakın olmaktadır.

d. Ortalama hata karesinin kare kökü (Root Mean Square Error-RMSE): Gürültü giderme sonucu görüntü ile gerçek görüntü arasındaki hata miktarını ölçmek için kullanılan bir ölçüttür. RMSE, gürültü giderme algoritmasının performansını niceliksel olarak

değerlendirmek için yaygın olarak kullanılmaktadır. Hesaplama yaparken ilk adımda, gerçek görüntü ve gürültü giderme sonucu elde edilen görüntü arasında, piksel değerleri farkı hesaplanmaktadır. Bu farklar, iki görüntü arasındaki hata miktarını temsil etmektedir. Piksel farklarının kareleri alınıp, bu karelerin ortalaması hesaplanmaktadır. Sonrasında MSE değerinin karekökü alınarak RMSE hesaplanmaktadır. RMSE hesaplaması Eş. 3.12’de gösterilmektedir.

$$RMSE = \sqrt{MSE} \quad (3.12)$$

RMSE piksel farklarının karelerinin ortalamasının kareköküdür. Bu değer hata miktarının daha kolay karşılaştırılabilir bir şekilde ifade edilmesini sağlamaktadır. Daha düşük bir RMSE değeri, gürültü giderme sonucunun gerçek görüntüye daha yakın olduğunu ve daha az hata içerdiğini göstermektedir. Ancak, RMSE değeri tek başına görüntünün kalitesini tam olarak ifade etmemektedir. Yapılan çalışmada bu değer daha düşük olup diğer ölçüm değerleri daha iyi olan sonuçlar yer almaktadır. Özellikle zıt renklerde bu değer daha yüksek çıkmakta, beyaz görüntülerde kalan siyah gürültüler bu değer artmasına neden olmaktadır. RMSE değeri görüntünün parlaklık veya zıtlık gibi yapısal özelliklerini dikkate almamaktadır. Dolayısıyla, RMSE’nin yanı sıra diğer başarı ölçütlerinin de kullanılması daha sağlıklı değerlendirme yapılmasını sağlamaktadır.

e. Sinyalin yeniden oluşturma hata oranı (Signal to Reconstruction Error Rate-SRER): Sıkıştırılmış veya bozulmuş bir sinyalin gerçek sinyale olan benzerliğini değerlendirmek için kullanılmaktadır. Bu ölçüt, sinyalin sıkıştırma, kodlama veya başka bir şekilde işleminden geçirilmesi sonucu meydana gelen yeniden oluşturma hatasının sinyal gücüne oranını ifade etmektedir. Ses veya video sıkıştırma algoritmalarının performansını değerlendirmek için SRER kullanılmaktadır. SRER, sinyalin yeniden oluşturma hatasını sinyal gücüne oranlayarak, sıkıştırma sonrası elde edilen görüntünün kalitesini değerlendirmeye yardımcı olmaktadır. SRER, Eş. 3.13’deki şekilde hesaplanmaktadır.

$$SRER = 10 \times \log(P_{Sinyal} \div P_{Hata}) \quad (3.13)$$

Burada, P_{Sinyal} , orijinal görüntünün piksel değerini, P_{Hata} , gürültü giderme sonrası elde edilen görüntüdeki piksel değerini temsil etmektedir. Daha yüksek SRER değeri, daha iyi

bir benzerliği ifade etmektedir.

f. Normalize edilmiş ortak bilgi (Normalized Mutual Information-NMI), birleşimli nesne tespiti, görüntü segmentasyonu ve kümeleme gibi alanlarda kullanılan bir değerlendirme ölçütüdür. NMI, iki veri kümesi arasındaki benzerliği ölçmek için kullanılmaktadır [148]. Bu ölçüm, Shannon Entropisi ve karşılıklı bilgi teorisi kavramlarına dayanmaktadır. NMI, iki kümeleme sonucunun ne kadar iyi bir şekilde eşleştiğini değerlendirmek için kullanılmakta olup, Eş. 3.14'deki formüle göre hesaplanmaktadır.

$$NMI = MI / \sqrt{H_1 \times H_2} \quad (3.14)$$

Burada, MI, Ortak Bilgi değerini temsil etmektedir. H_1 ve H_2 , sırasıyla iki kümeleme sonucunun entropi değerlerini temsil etmekte, entropi ise veri kümesinin belirsizlik düzeyini ölçmektedir. Eş. 3.15'de entropi hesaplamasına ait formül gösterilmektedir.

$$H = - \sum_{i=0}^{255} p_i \times \log_2 p_i \quad (3.15)$$

H, entropi değeri hesaplanırken görüntünün piksel değerleri bir histograma aktarılır. p_i değeri bu histograma göre görüntünün o anki piksel değerinin histogramdaki gerçekleşme ihtimalini ifade etmektedir. Ortak bilgi MI değeri Eş. 3.16'da gösterilmektedir.

$$MI(x,y) = \sum p(x,y) \log\left(\frac{p(x,y)}{p(x)p(y)}\right) \quad (3.16)$$

Formülde yer alan x değeri tahmin edilen piksel değerini, y değeri orijinal piksel değerini ifade etmektedir. NMI değeri, 0 ila 1 arasında değişmektedir. 1'e yaklaşan bir NMI değeri, iki kümeleme sonucunun eşleştiğini, 0'a yaklaşan NMI değeri ise iki kümeleme sonucunun birbirinden bağımsız olduğunu ifade etmektedir.


Gürültü giderme sonucunun değerlendirilmesi

Videoda gürültü türlerine ait ölçüm değeri hesabı, genellikle bir modelin veya algoritmanın

videodaki gürültü türlerini ne kadar doğru tespit ettiğini ve sınıflandırdığını ölçmek için kullanılmaktadır. Yapılan karşılaştırma sonuçlarında, PSNR ve SSIM değerlerinin görüntülerin görsel olarak kıyaslama sonuçları ile paralel değerler ürettiği görülmüştür. Bu iki değer insan görsel algısına da uygun değerler ürettiği için hesaplamaların doğruluğu tespit edilirken öncelikle bu iki değer göz önünde bulundurulmuştur. FSIM değerlerinin PSNR, SSIM değerleri ile benzer kalite sonuçları üretmesine rağmen bazı görüntülerde farklı değerler de üretebildiği görülmektedir. FSIM değeri parlak yüzeylerde, benzerlik ölçüsü olarak kullanıldığında küçük görüntü değişikliklerinde bile farklı sonuçlar üretebilmektedir. Bu yüzden FSIM değeri tek başına görüntü kalitesini belirlemesi hatalı yorumlara neden olmaktadır. RMSE değerleri de uç değerlere sahip görüntülerde farklı sonuçlar verebilmektedir, bu sebeple bu değer görüntülerde tek başına bir değerlendirme ölçütü olarak kullanılması uygun olmamaktadır. Benzer şekilde NMI değerini elde ederken entropi hesabı yapmak gerekmekte ve bu değer görüntü üzerindeki piksel değerlerine bağlı farklı sonuçlar üretebilmektedir. Görüntülerde gürültü giderme sonuçlarını değerlendirirken PSNR ve SSIM değerleri ana belirleyici iki ölçüt olarak kullanılmış olup, bu değerlerin birbirlerine yakın olması durumunda RMSE, SRER, NMI ve FSIM değerleri destekleyici ölçüm değerleri olarak kullanılmıştır.

4. VIDEO ÜZERİNDE GÜRÜLTÜ GİDEREN DERİN ÖĞRENME MODELİNİN OLUŞTURULMASI


Bu çalışmada, video verilerinden gürültü gidermek amacıyla derin öğrenme modelleri kullanılarak hibrit bir model geliştirilmiştir. VGGM adı verilen bu model, 2 aşamada gürültü giderme işlemi yapmaktadır. İlk aşamada eğitilen CNN modeli (VGGM1) aynı görüntü karesinde uzaysal gürültü giderme işlemi yapmaktadır. İkinci aşamada eğitilen GAN modeli (VGGM2) ile bir önceki ve bir sonraki video çerçeveleri birleştirilerek blok gürültü giderme işlemi yapılmaktadır. Bu aşamada görüntü geçişlerinde titremenin önlenmesi sağlanmaktadır. Geliştirilen VGGM yönteminde gerçekleştirilen işlem adımları Şekil 4.1’de gösterilmektedir.



Şekil 4.1. VGGM gürültü giderme işlem adımları

Video kareleri zamansal boyutlara ayrılarak her bir kare üzerinde gürültü giderme işlemi yapılmaktadır. Zamansal gürültü giderme aşamasında gürültülü görüntü ve komuşu iki görüntü alınarak gürültü giderme işlemi yapılmaktadır. Şekil 4.2’de zamansal gürültü giderme modelinde bloklara ayrılan görüntülerdeki gürültü giderme sonucu elde edile çıktılar gösterilmektedir. Beş görüntü çerçevesi üzerinde uzaysal gürültü giderimi

yapıldıktan sonra bu görüntüler üzerinde zamansal gürültü giderme işlemi yapılarak ilk üç çerçeve görüntüden arındırılmıştır.



Şekil 4.2. Zamansal gürültü giderme modeli

Uzaysal ve zamansal gürültü giderme modeli hazırlanırken dikkat edilen derin öğrenme bileşenlerine aşağıda yer verilmektedir.

a. Veri artırımı: Modellerin geliştirilmesi aşamasında eğitim verilerinin kalitesi ve sayısının modelin başarısını etkilediği görülmüştür. Eğitim verilerinin artırmak için görüntü üretme teknikleri kullanılmıştır. Uzaysal gürültü giderme modelinin eğitimi aşamasında örnek veri sayısını artırmak için veri artırım yöntemleri uygulanmıştır. Döndürme, renk değiştirme yöntemleri ile görüntü üzerinde değişiklik yapıp, örnek görüntü sayısı artırılmıştır. Eğitim ve doğrulama verilerinde, optimum değer olarak belirlenen %20 oranında veri artırımı yapılmıştır.

b. Alıcı alanı genişletmek: Daha fazla bağlam bilgisi yakalayabilmek için alıcı alanın genişletilmesi amaçlanmıştır. Alıcı alanın genişletilmesinin bir yöntemi, ağların derinliği ve genişliğini artırmaktır. Bu durum, ancak daha yüksek hesaplama maliyetleri ve artan bellek tüketimini beraberinde getirmektedir. Bu soruna çözüm olarak, daha fazla uç bilgi sağlamada etkili olan genişletilmiş evrişimler kullanılmıştır.

c. Kayıp fonksiyonu seçimi: Kayıp fonksiyonu modelin beklenen sonuca göre ne kadar verimli çalıştığını ölçüp, gürültüsüz bir görüntü elde etmesine yardımcı olmaktadır. Kayıp fonksiyonu, modelin tahminlerini gerçek değerlerle karşılaştırarak bir tür hata ölçüsü sağlamaktadır.

d. Optimizasyon fonksiyonu seçimi: AdaGrad, RMSProp, SGD, AdaDelta ve Adam gradyan iniş algoritmaları, modelin eğitim sürecini hızlandırmak, daha iyi sonuçlar elde etmek ve aşırı uyum gibi sorunları önlemek için kullanılmaktadır.

e. Optimizasyon fonksiyonu seçimi, derin öğrenme modelinin eğitim sürecinde modelin performansının belirlenmesinde kritik bir role sahiptir. Optimizasyon fonksiyonu, modelin hata değerlerini minimize etmek için modelin parametrelerini güncellemektedir.

f. Optimize edici (Momentum): Optimize edici, optimizasyon fonksiyonundaki varyansı azaltmak için kullanılmakta olup, yakınsamayı yumuşatmaktadır. Momentum, ağırlık güncellemelerinin doğru yönde gerçekleşmesini sağlayarak daha hızlı ve daha tutarlı bir öğrenme süreci sağlamaktadır. Momentum değeri deneme yanılma ve deneyim gerektiren bir konu olmakla beraber, genellikle başlangıçta 0,9 veya 0,99 gibi yüksek değerler kullanılarak denemelere başlanmaktadır.

g. Aktivasyon fonksiyonu: Nöronların aktif veya pasif olma durumunu belirlemek üzere kullanılan aktivasyon fonksiyonları, derin sinir ağlarının eğitim süresinde ve modelin başarısında önemli bir paya sahiptir. Aktivasyon fonksiyonlarının türevleri, geri yayılım sürecinde ağırlıkların güncellenmesine ve modelin öğrenme sürecine katkı sağlamaktadır.

h. Ağırlık başlangıç değerlerinin belirlenmesi: Ağırlıkların nasıl belirlendiği modelin öğrenmesine ve hızına etki etmektedir. Tüm ağırlıkların sıfır ile başlatılması, tüm nöronların aynı şekilde çalışmasına neden olmaktadır. Her bir ağırlığın aynı değere sahip olduğu bir ağ, simetrik bir yapıya sahip olacağı için öğrenme sürecini zorlaştırabilmektedir. Çok büyük ağırlıkların kullanılması ise, aktivasyonların geriye doğru yayılımda öğrenme probleminin ortaya çıkmasına neden olmaktadır.

i. Yığın boyutu (Batch-size): Derin öğrenme işleminde yığın boyutu model eğitimi sırasında kullanılan veri örneklerinin gruplar halinde bölünmesini ifade etmektedir. Büyük veri kümesiyle çalışırken, tüm veriyi aynı anda işlemek bellek ve hesaplama gücü açısından maliyetli olmaktadır. Veriler aynı anda işlendiğinde eğitim süreci daha verimli hale gelmektedir. Genel olarak, uygun bir toplu boyut seçimi, eğitim sürecinin verimli ve etkili bir şekilde gerçekleştirilmesi için önemlidir.

j. Derin ağların oluşturulması: Daha başarılı sonuçlar elde etmek için ağların derinliğinin belirlenmesi önemli bir role sahiptir. Ancak daha derin gürültü giderme ağları daha fazla bellek kaynağı gerektirmekte ve derin ağlarda aşırı öğrenme ve kaybolan eğim sorunları ortaya çıkmaktadır. Kaybolan eğim sorununu giderebilmek ve başarılı sonuçlar elde edebilmek için model içinde katman seçimi önem kazanmaktadır.

k. Zamansal gürültü giderimi: Zamansal gürültü giderme, video ve ses dosyalarını daha net hale getirmek için kullanılmaktadır. Videolarda görüntü geçişinde titremeyi önlemek ve benzer karelerde gürültü giderimi yapabilmek için zamansal gürültü giderim modelleri ve filtreleme teknikleri kullanılmaktadır. Bazı modeller görüntü geçişlerinde hareket takibi yaparak benzer kareleri tespit etmeye çalışmakta, derin öğrenme modelleri ve geleneksel gürültü giderme yöntemleri kullanılarak benzer video kareleri üzerinde gürültüler giderilmektedir.

4.1. Uzaysal gürültü giderme (VGGM1) modelinin hazırlanması


Başarılı olan gürültü giderme modelleri incelendiğinde CNN yöntemlerinin gürültü gidermede daha iyi sonuçlar elde ettiği görülmektedir. Geliştirilen gürültü giderme modelinde CNN mimarisi kullanarak uzaysal gürültü giderme yapılmıştır. Modele girdi olarak gelen görüntülerde gürültü tahmin yöntemi kullanılarak gürültü seviyesi ölçümü yapılmıştır. Gürültü seviyesi 0 dB olarak belirlenen görüntülerde bozulma meydana gelmemesi için gürültü giderme işlemi yapılmamıştır. Gürültü seviyesini belirlemek için kullanılan yöntem aşağıda sunulmuştur.

Gürültü seviyesi ölçümü

Modele girdi olarak verilen görüntünün gürültü seviyesi ölçülerek, gürültülü olmayan görüntülerde işlem yapılmadan orijinal görüntünün çıktı olarak verilmesi sağlanmaktadır. Bu sayede gürültü giderme sırasında orijinal görüntüde herhangi bir bozulma meydana gelmemekte ve gürültü giderme işlemi süresi kısalmaktadır. Gürültü tahmini için filtre tabanlı yaklaşımlar ve yama tabanlı yaklaşımlar kullanılmaktadır. Filtre tabanlı yaklaşımlar [128-129], gürültülü görüntülerde yüksek geçiren bir filtre kullanıp, gürültülü görüntü ile filtrelenmiş görüntü arasındaki farktan gürültü varyansı hesaplanmaktadır. Yama tabanlı

yaklaşımlarda [130], görüntüler parçalara ayrıştırılmakta ve bu yamalar üzerinden gürültü seviyesi hesaplanmaktadır.

Gürültü seviyesi ölçümü için yama tabanlı bir gürültü seviyesi tahmin algoritması kullanılmıştır [131]. Bu algoritma basit hesaplamalarla düşük gürültü seviyelerinde kısa sürede gerçeğe yakın sonuçlar vermektedir. Bu yöntem kullanılarak gürültülü görüntüden yüksek frekans bileşenleri olmayan düşük dereceli yamalar seçilip temel bileşen analizi yapılarak gürültü seviyesi tahmin edilmektedir. 180x180 boyutunda CBSD400 veri kümesinde yama tabanlı gürültü giderme yöntemi kullanılarak, eklenen gürültü değerleri ile tahmin edilen gürültü değerleri Şekil 4.3’de sunulmuştur.



Şekil 4.3. Görüntülerde gürültü ölçme testi sonuçları


Kullanılan yöntem düşük gürültü seviyelerinde başarılı sonuçlar elde etmekte olup, yüksek gürültü değerlerinde tahmin değeri ile gerçek değer arasındaki farkın arttığı grafikte görülmektedir. Modele girdi olarak verilen görüntünün hangi gürültü seviyesinde olduğu bu algoritma ile tespit edilerek gürültü seviyesi 0 dB üstü olan görüntülerde gürültü giderme işlemi yapılması sağlanmıştır.

Modelin hazırlanması

Modelin hazırlanmasında kullanılan derin öğrenme bileşenleri tercihi ve elde edilen sonuçlar aşağıda belirtilmektedir.

a. Veri artırımı: Modelin eğitimi sırasında veri artırma yapıldığında, modelin daha iyi öğrenme elde ettiği ve kayıp değerlerinin düştüğü gözlemlenmiştir. Eğitim verisi artırma sonrası elde edilen gürültü giderme değerleri Tablo 1'de adım 1, 2, 3 olarak yer almaktadır.

b. Alıcı alanı genişletmek: VGGM uzaysal ağda alıcı alan genişletilerek daha fazla öznelilik elde edilerek modelin daha fazla gürültü yakalaması sağlanmıştır. Çok fazla genişletilmiş evrişim katmanını kullanılması modelin aşırı öğrenmesine eğitim aşamasında elde edilen başarılı sonuçların gerçek verilerle test sırasında aynı başarıyı yakalamamasına neden olmaktadır. Çift katman genişletilmiş evrişim eklenmesi sonucu elde edilen kayıp değerleri Şekil 4.4'de sunulmuştur.



Şekil 4.4. Çift katman genişletilmiş evrişim eklenmesi sonucu kayıp değerleri

Bu iki katmanın eklenmesi sonucu elde edilen değerler Çizelge 4.1'de 1, 5 ve 6. adımlarda sunulmaktadır.

c. Kayıp fonksiyonu seçimi: VGGM modelinde MSE kayıp fonksiyonu kullanılmıştır. Bu fonksiyon hızlı hesaplama sağlayarak daha doğru sonuç elde etme başarısına sahiptir. Yapılan denemeler sonucunda Huber kayıp işlevi, uç değerlere karşı daha az duyarlılığı olduğu için yüksek gürültülü görüntülerde daha az başarı elde ettiği, düşük gürültüde başarılı olduğu görülmüştür. En iyi sonuç MSE kayıp fonksiyonunda elde edilmiş olup, tahmin edilen değerler arasındaki farkların karelerinin toplamını en aza indirmek farklı değerlere sahip matris işlemlerinde daha doğru sonuç üretmektedir. Kayıp eğrilerinin modele uygulanması sonucu elde edilen değerler Çizelge 4.1'de 1, 6, 7, 8, ve 9. adımlarda sunulmaktadır.

d. Öğrenme optimizasyonu: ADAM optimizasyonu VGGM modelinde kullanılmıştır. Uyarlanabilir özelliği sayesinde hata değerlerine göre kendini ayarlayabilmektedir [132]. Yapılan denemeler sonucu ADAM en iyi optimize değerlerini elde etmektedir. Optimizasyon fonksiyonlarının gürültülü görüntülere uygulanması sonucu elde edilen değerler Çizelge 4.1'de 1, 10, 11, 12 ve 13. adımlarında sunulmaktadır.

e. Öğrenme hızı: Modelde momentum değeri 0,9 olarak seçildiğinde daha başarılı sonuçlar elde edilmektedir. Modelde momentum uygulanması sonucu elde edilen değerler Çizelge 4.1'de 1, 14, 15, 16, 17, 18 ve 19. adımlarında sunulmaktadır.

f. Aktivasyon fonksiyonu: Yapılan testlerde düşük gürültü seviyesinde Mish fonksiyonu, yüksek gürültü seviyesinde ise Swish fonksiyonu daha başarılı olmuştur. Yapılan testler sonucunda Mish fonksiyonun daha yüksek başarı oranına sahip olduğu için bu fonksiyon tercih edilmektedir. Mish, diğer aktivasyon fonksiyonlarına göre daha yumuşak eğrisel bir davranışa sahiptir. Bu, özellikle gradyan tabanlı optimizasyon algoritmalarının eğitimi sırasında daha düzenli öğrenmeye katkıda bulunmaktadır. Aktivasyon fonksiyonlarının modele uygulanması sonucu elde edilen değerler Çizelge 4.1'de 1, 20, 21, 22, 23, 24, 25, 26, 27 ve 28. adımlarında sunulmaktadır.

g. Ağırlık başlangıç değerlerinin belirlenmesi: Normalize edilmiş Xavier, düzgün olasılık dağılımı hesaplaması ile, modelin ilk değerlerini atamaktadır. Bu ağırlık fonksiyonu ile test ve eğitim verilerinin kayıp değerleri birbirine paralel şekilde düzenli olarak azalmaktadır. Normalize edilmiş Xavier kayıp değeri düzenli bir şekilde azaltarak diğer ağırlık değerlerine göre daha iyi bir sonuç elde etmektedir. Ağırlık fonksiyonlarının modele uygulanması sonucu elde edilen değerler Çizelge 4.1'de 1, 27, 28, 29, 30 ve 31. adımlarında sunulmaktadır.

h. Yığın boyutu: Görüntü boyutuna bağlı olarak batch size değeri daha büyük seçilebilmektedir. Yapılan çalışmada büyük gruplar halinde gürültü giderimi yapıldığında ezberleme daha fazla olmaktadır, küçük batch sayısında daha başarılı sonuç elde edilgi görülmektedir. Model üzerinde farklı batch size kullanılması sonucu elde edilen kayıp değerleri Çizelge 4.1’de 1, 32, 33 adımlarında sunulmaktadır.

i. Derin ağların oluşturulması: Görüntünün dokusunu koruyarak, sınır değerlerinin bulanıklaşmasının engellenmesi ve gürültüye ait kalıntıların en aza indirilmesi amacıyla bir model geliştirilmiştir. Kaybolan eğim sorununu giderebilmek için U-Net mimarisinin katman sayısı değiştirilerek kullanılmıştır. U-Net, kod çözücü tarafında ters evrişim işlemi gerçekleştirmekte, mimarinin kodlayıcı tarafından gelen bağlantılar sayesinde özneteliklerin kaybolmasına sebep olan darboğaz probleminin üstesinden gelinmektedir. Ağın daha fazla kaynak harcamasının önüne geçmek için iki alt ağ olarak planlanan mimari tek bir ağ üzerine kurulmuştur. Alt ağlar paralelde işlemler yaparak elde edilen görüntüler sonrasında birleştirilebilmektedir. Bu sayede dar boğaz sorunu meydana gelmemektedir. Ancak alt ağlarda yapılan işlemler ağların birbirine olan bağlarını ve parametre sayısını artırarak bellek problemleri ortaya çıkarmaktadır. Model üzerinde farklı ağ derinliklerinin kullanılması sonucu elde edilen kayıp değerleri Çizelge 4.1’de 1, 34, 35, 36, 37, 38, 39, 40 ve 41. adımlarında sunulmuştur. Gürültü değeri $\sigma = 25$ olduğu zaman modele ait parametrelerin seçimi ve elde edilen sonuçlar Çizelge 4.1’de sunulmaktadır.

Çizelge 4.1. VGGM1 ağına ait parametrelerin seçimi ve elde edilen sonuçlar

Adım	Eğitim Verisi Sayısı	Geniştirilmiş Evrişim Katman Sayısı	Kayıp Fonksiyonu	Optimizasyon Metodu	Momentum	Aktivasyon Fonksiyonu	Ağırlık Başlangıç Fonksiyonu	Yığın Boyutu	Katman Sayısı	PSNR (dB)	SSIM
1	480	2	MSE	ADAM	0,9	Mish	Normalized Xavier	16	27	27,63	0,88
2	400	2	MSE	ADAM	0,9	Sigmoid	Normalized Xavier	16	27	26,76	0,85
3	540	2	MSE	ADAM	0,9	Mish	Normalized Xavier	16	27	26,63	0,85
4	480	0	MSE	ADAM	0,9	Mish	Normalized Xavier	16	27	27,05	0,87

5	480	1	MSE	ADAM	0,9	Mish	Normalized Xavier	16	27	27,50	0,88
6	480	2	Huber	ADAM	0,9	Mish	Normalized Xavier	16	27	27,61	0,88
7	480	2	L1	ADAM	0,9	Mish	Normalized Xavier	16	27	20,88	0,68
8	480	2	MSLE	ADAM	0,9	Mish	Normalized Xavier	16	27	26,62	0,87
9	480	2	Huber	RMSProb	0,9	Mish	Normalized Xavier	16	27	25,05	0,80
10	480	2	MSE	RMSProb	0,9	Mish	Normalized Xavier	16	27	22,56	0,70
11	480	2	MSE	AdaGrad	0,9	Mish	Normalized Xavier	16	27	17,30	0,45
12	480	2	MSE	AdaDelta	0,9	Mish	Normalized Xavier	16	27	9,52	0,18
13	480	2	MSE	SGB	0,9	Mish	Normalized Xavier	16	27	17,10	0,41
14	480	2	MSE	ADAM	0,0	Mish	Normalized Xavier	16	27	24,55	0,72
15	480	2	MSE	ADAM	0,1	Mish	Normalized Xavier	16	27	25,18	0,78
16	480	2	MSE	ADAM	0,1	Mish	Normalized Xavier	16	29	26,48	0,86
17	480	2	MSE	ADAM	0,9	tanh	He	16	27	27,12	0,85
18	480	2	MSE	ADAM	0,5	Mish	Normalized Xavier	16	27	26,15	0,81
19	480	2	MSE	ADAM	0,8	Mish	Normalized Xavier	16	27	26,87	0,81
20	480	2	MSE	ADAM	0,9	tanh	Normalized Xavier	16	27	24,28	0,78
21	480	2	MSE	ADAM	0,9	ReLU	Normalized Xavier	16	27	26,97	0,86
22	480	2	MSE	ADAM	0,9	Softmax	Normalized Xavier	16	27	22,76	0,67
23	480	2	MSE	ADAM	0,9	Swish	Normalized Xavier	16	27	27,28	0,87
24	480	2	MSE	ADAM	0,9	ReLU	Normalized Xavier	16	27	24,01	0,77
25	480	2	MSE	ADAM	0,9	LeakyReLU	Normalized Xavier	16	27	24,08	0,77
26	480	2	MSE	ADAM	0,9	Mish	He	16	27	27,32	0,87
27	480	2	MSE	ADAM	0,9	tanh	Xavier	16	27	27,30	0,86
28	480	2	MSE	ADAM	0,9	ReLU	Xavier	16	27	27,32	0,86
29	480	2	MSE	ADAM	0,9	Mish	He	16	27	27,32	0,87
30	480	2	MSE	ADAM	0,9	Mish	Xavier	16	27	27,48	0,87

31	480	2	MSE	ADAM	0,9	Mish	Orthogonal	16	27	27,01	0,87
32	480	2	MSE	ADAM	0,9	Mish	Normalized Xavier	32	27	27,53	0,88
33	480	2	MSE	ADAM	0,9	Mish	Normalized Xavier	64	27	27,56	0,88
34	480	2	MSE	ADAM	0,9	Mish	Normalized Xavier	16	27	26,56	0,86
35	480	2	MSE	ADAM	0,9	Sigmoid	Normalized Xavier	16	25	26,64	0,87
36	480	2	MSE	ADAM	0,1	Swish	Xavier	16	29	25,94	0,80
37	480	2	L1	ADAM	0,1	Swish	Xavier	16	27	26,11	0,82
38	480	2	L1	ADAM	0,9	Swish	Xavier	16	27	26,29	0,82
39	480	2	L1	ADAM	0,9	Mish	Normalized Xavier	16	27	27,12	0,84
40	480	2	L1	ADAM	0,9	LeakyReLU	Normalized Xavier	32	29	27,20	0,85
41	480	2	L1	ADAM	0,1	ReLU	Normalized Xavier	32	29	25,89	0,79

VGGM1 ağında seçilen parametrelere göre elde edilen sonuçlar değerlendirildiğinde, genişletilmiş evrimsel katmanlarının kullanılması, modelin daha başarılı sonuçlar elde etmesine olanak sağladığı görülmüştür. Veri artırımı sayesinde eğitim sürecinde farklı görüntülerle karşılaşan modelin daha başarılı sonuçlar elde ettiği, eğitim verisini belirli bir sayının üzerine çıkması durumunda ise başarı oranının azaldığı görülmektedir. Ortalama kare hatası, özellikle regresyon problemleri için kullanılan bir kayıp fonksiyon olup, tahminler ile gerçek değerler arasındaki farkın karelerinin ortalama değerini hesaplamaktadır. L2 kayıp işlevi veya MSE, en küçük kareler hatası olarak da bilinmektedir. Temel olarak hedef değer ile tahmin edilen değerler arasındaki farkların karelerinin toplamını en aza indirmektir. L2 kayıp fonksiyonunun dezavantajı, uç değerleri de dikkate alması ve bu da kayıp fonksiyonunun değerini arttırmasıdır. Bu dezavantaj görüntüde yanlış piksel tahmininde modelin daha iyi tahmin yapmasına neden olmaktadır. Modelde MSE kayıp fonksiyonunun kullanılması diğer fonksiyonlara göre daha başarılı sonuçlar elde edilmesini sağlamıştır.

Geliştirilen VGGM1 derin öğrenme modelinin mimarisi


Ağ derinliği, yeterli uzaysal bilgiyi yakalamak ve gürültü giderme işlemi süresini kısaltmak için CNN katmanlarında 19, U-Net katmanlarında ise 8 olarak belirlenmiştir. CNN ağında

kullanılan kayıp fonksiyonu olarak MSE kullanılmakta ve ağırlıklar Normalized Xavier yöntemiyle başlatılmaktadır. Modelde momentum değeri olarak 0,9 kullanılmaktadır. VGGM1 ağı 50 tekrarla eğitilmektedir.

Gürültü giderme süresini kısaltmak ve yüksek gürültü seviyelerinde başarılı sonuçlar elde etmek için gürültü gideren U-Net modelinin kullanılmıştır. U-Net ağında Mish aktivasyon fonksiyonu tercih edilmiştir. En yaygın kullanılan aktivasyon fonksiyonlarından birisi olan ReLU fonksiyonu 0'a yakın değerlerde azalan eğim sorunu ile karşılaşmaktadır. Bu fonksiyonun değiştirilmesi sonucu elde edilen mish fonksiyonu daha geniş bir aralıkta değerler üretmektedir. Modelde girdi boyutu ile aynı boyutta çıktı boyutu elde edebilmek için kenar dolgusu kullanılmıştır. Evrişim işlemi sırasında, filtreler kullanıldığı için evrişim sonucunda çıktının boyutunun girdi boyutundan daha küçük olmaktadır. Bu durum, modeldeki her evrişim katmanından geçişte boyut kaybına yol açmaktadır. Kenar dolgusu sayesinde girdinin kenarlarına uygun miktarda sıfır dolgusu eklenerek, çıktı boyutunun girdi boyutuyla aynı olması sağlanmaktadır. Böylece özellik filtreleme sonucu boyut geçişlerinde bilgi kaybını azaltılmaktadır. U-Net katmanında kodlama ve kod çözme kısmında 4x4 filtreler kullanılmıştır. Mimarının kodlayıcı kısmında, her blokta evrişim, toplu normalleştirme ve Mish aktivasyonu işlemleri yapılmaktadır.

Kod çözme kısmında her blok tersine evrişim ve mish aktivasyonu kullanılmakta, kod çözme bloğunda tersine evrişim ve piksel karıştırma işlemleri gerçekleştirilmektedir. Kodlayıcı ve kod çözme katmanları arasında atlama bağlantıları mevcuttur. U-Net modelinin gürültü azaltma için kullanıldığı testler sırasında, ağdaki katman sayısı arttıkça görüntünün sıkıştırma oranının arttığı ve görüntüde bazı değer kayıplarının meydana geldiği gözlemlenmiştir. Modeldeki tekrar sayısı modelin başarısını etkilemekte ve belli bir değerin üzerindeki tekrarların modelin aşırı öğrenmesine neden olduğu görülmektedir. Atlama bağlantıları kullanılması sonucu, derinlik arttıkça, modelin öğrenmeye devam ettiği ve gürültü başarısının da arttığı görülmüştür. Bu şekilde görüntü boyutu istenen sıkıştırma düzeyine kadar azaltılabilmektedir.

Eğitim sırasında görüntü boyutu 180x180 piksel olarak kullanılmıştır. VGGM1 ağında kullanılan katmanlar Şekil 4.5'de görselleştirilmiştir.



Şekil 4.5. Geliştirilen uzaysal derin öğrenme modelinin mimarisi

Uzaysal gürültü azaltma aşamasında kullanılan CNN modeli içerisinde gürültülü ve temiz görüntüler arasındaki doğrusal olmayan eşlemeleri öğrenmek ve aşırı öğrenmeyi önlemek için U-Net mimarisi kullanılmıştır. U-Net ağı, özneliklerin kaybolmasına sebep olan darboğaz probleminin üstesinden gelmektedir. Çizelge 4.2’de modele ait katmanlar gösterilmektedir. Bu çizelgede benzer işlevleri yerine getiren ve tekrarlayan aşamalar gruplanarak katman olarak adlandırılmıştır.


Çizelge 4.2. Uzaysal model katmanları

Katman Numarası	Katmanlar
1-2 (Kodlama)	Conv2D + Mish (2)
3 (Çözümleme)	Conv2DTranspose + Mish + Concat (Layer 3)
4 (Çözümleme)	Conv2DTranspose + Mish + Conv2D + Concat (input)
5 (CNN)	Conv2D + Mish (1)
6 ... 9	Conv2D + BN + Mish (4)
10	Dilation + BN + Mish (1)
11 ... 18	Conv2D + BN + Mish (8)
19	Dilation + BN + Mish (1)
20 ... 22	Conv2D + BN + Mish (3)
23 (CNN)	Conv2D + Mish (1)
24-25 (Kodlama)	Conv2D + Mish (2)
26 (Çözümleme)	PixelShuffle + Mish + Concat (Layer 24)
27 (Çözümleme)	PixelShuffle + Mish + Conv2D + Concat (Layer 23) + Conv2D+Subtract

VGGM1 ağının 1-4 ve 24-27 katmanlarında U-Net mimarisi kullanılmıştır. U-Net modelinde önce veri boyutu küçültülmekte sonrasında sıkıştırılan veri eski boyutuna dönüştürürken tersine evrişim (Transposed Convolution-Conv2DTranspose) kullanılmaktadır. Tersine evrişim, özellik haritalarının uzamsal çözünürlüğünü artırmak için kullanılmakta olup, süper çözünürlük, görüntü sentezi ve semantik bölümlendirme gibi görevlerde kullanılmaktadır. Tersine evrişim, girdi değerleri arasına sıfırlar ekleyerek evrişim katmanlarını uygulanmaktadır. Bu süreç, daha düşük çözünürlüklü bir görüntüde ince ayrıntıların çözünürlüğünü artırmaya yardımcı olmaktadır. Geliştirilen gürültü azaltma yöntemi 27 katmandan oluşmakta olup, ilk dört katman U-Net mimarisi kullanılmış olup, ilk iki katman görüntü boyutunun azaltılıp diğer iki katmanda boyut artırılmaktadır. U-Net ağı kullanırken 3x3 ve 4x4 filtreler kullanılmış, modelin başarı oranının 4x4 filtrelerde daha iyi olduğu görülmüştür. 3x3 filtreler, 4x4 filtrelere göre daha küçük bir alıcı alana sahip olduğu

için, giriş verisinde komşu piksellerden bilgi yakalamaktadır. 4x4 filtreler ise, daha büyük bir alıcı alana sahip olduğu için, giriş verisinde daha geniş bir alandan bilgi yakalayabilmektedir.


DAVIS veri kümesi ile 180x180 ölçülerinde görüntülerde tersine evrişim kullanılarak geliştirilen CNN modelinin kayıp değerleri Şekil 4.6’da sunulmuştur.



Şekil 4.6. Tersine evrişim kullanılarak oluşturulan modelin kayıp değerleri


Şekil 4.5’de doğrulama değer kaybı ile eğitim değer kaybı bazı noktalarda farklı değerler alabilmektedir. Tersine evrişim aşamasında sıfır dolgu eklenerek görüntü tekrar oluşturulduğu için doğrulama aşamasında kayıp değerleri eğitim kaybına paralel değerler elde edememektedir. Bu iki değer paralel olarak ilerleyebilmesi için modelde piksel karıştırma özelliği ikinci U-Net ağında kullanılmıştır. U-Net ağının yukarı örnekleme kısmında bu özellik kullanılarak modelin son aşamasında veri eski boyutuna dönüştürülmüştür. Görüntünün kanal boyutları yeniden düzenlenerek görüntüye ait tensörün uzamsal boyutlarını alınıp, bunlar daha küçük uzaysal bloklara bölünmektedir. Kanallar daha sonra çıkış tensörünü oluşturmak için serpiştirilmektedir. Bu işlem, görüntünün uzamsal çözünürlüğünü artırmaya çalışırken başarılı sonuçlar elde etmesine yardımcı olmaktadır [116]. Piksel karıştırma işlemi öncesi tensor boyutu (4, 3, 3) olan bir veri, piksel

karıştırma işlemi sonrasında $(1, 6, 6)$ boyutuna dönüştürülmektedir. Yapılan işlem tensör boyutu $(C \times r^2, H, W)$ olan bir şekil bu işlem sonucunda $(C, H \times r, W \times r)$ olan bir şekle dönüştürülmektedir. C değeri kanal sayısını, H değeri tensörün yüksekliğini ve W değeri tensörün genişliğini ifade etmektedir. R değeri tensörün boyutunu dönüştürme katsayısı olarak kullanılmaktadır. Yapılan işlem Şekil 4.7’de sunulmuştur. Şekilde verilen örnekte 4 boyutlu bir girdi kullanılarak, çıktıda görüntünün genişliği ve uzunluğu iki katına çıkarılmaktadır.



Şekil 4.7. Piksel karıştırma işlemi

180x180 ölçülerindeki DAVIS veri kümesi kullanılarak, piksel karıştırma özelliği eklenen CNN modelinin kayıp değerleri Şekil 4.8’de sunulmuştur. Piksel karıştırma özelliğinin, rastgele 0 değeri ekleyerek tersine evrişim uygulama işlemine göre daha başarılı sonuçlar elde ettiği görülmektedir.



Şekil 4.8. VGGM1 ağına piksel karıştırma özelliği eklenmesi

VGGM1 modeline piksel karıştırma özelliği eklenerek 180x180 boyutlarına sahip DAVIS veri kümesi üzerinde gürültü giderme sonucu elde edilen sonuçlar Çizelge 4.3’de gösterilmektedir.

Çizelge 4.3. VGGM1 modeline piksel karıştırma özelliği eklenmesi

Piksel Karıştırma	PSNR (dB)	SSIM	FSIM	RMSE
Yok	26,98	0,88	0,98	0,00001545
Var	27,99	0,91	0,98	0,00000976

Yapılan çalışma sonucu FSIM değeri aynı olduğu halde PSNR, SSIM ve RMSE değerlerinde iyileşme olmaktadır. FSIM yöntemi gabor filtreleri kullanarak, iki görüntü arasındaki benzerliği bulmaktadır. Görüntüde bazı görüntüye ait piksel değerlerinin orijinal piksel değerlerinden uzaklaştığı, bazı görüntü alanlarına ait piksel değerlerinin orijinal değerlere yaklaştığı için, FSIM değerinin değişmediği görülmektedir. Piksel karıştırma özelliğinin kullanılması sayesinde, elde edilen değerlerin iyileştiği ve görüntünün orijinal görüntüye göre benzerliğinin arttığı görülmektedir. VGGM1 ağının son katmanında U-Net ağı, 24. ve 25. katman boyut azaltmak için, 26. ve 27. katman boyut artırmak için kullanılmıştır.

4.2. Zamansal gürültü giderme (VGGM2) modelinin hazırlanması

Zamansal gürültü giderme, videoların farklı kareleri üzerinde gürültü giderme işleminin gerçekleştirildiği bir yöntemdir. Uzaysal gürültü giderme işlemi tek bir karedeki gürültüyü hedeflerken, zamansal gürültü giderme işlemi videonun farklı kareleri arasındaki ilişkileri göz önünde bulundurarak gürültüyü azaltmayı amaçlamaktadır. Görüntülerde gürültü giderme ve modelin eğitim süresini düşürmek ve yüksek çözünürlüklü görüntülerde daha az donanım kaynağı kullanmak amacıyla zamansal gürültü giderme aşamasında GAN modeli kullanılmıştır. GAN modelinin tercih edilmesinin sebepleri aşağıda belirtilmiştir:

- Geliştirilen CNN tabanlı modelin eğitim süresi 100 dakikayı aşmaktadır. Bu süreden daha kısa sürede eğitilebilecek bir modelin geliştirilmesi planlanmıştır.
- Yüksek çözünürlüklü görüntülerde daha az bellek kullanacak bir modelin geliştirilmesi planlanmıştır. CNN tabanlı modelde hesaplanan parametre sayının çok olması nedeniyle yüksek çözünürlükteki görüntülerde bellek yetmemesi sorunu ile karşılaşmıştır.
- GAN modelleri, verileri öğrenme yetenekleri sayesinde karmaşık gürültü desenlerini öğrenme kapasitesine sahiptirler. Çeşitli gürültü giderme modellerinde karmaşık gürültü türlerini etkili bir şekilde gidermek için kullanılmışlardır. Gürültü giderme süresini kısaltmak ve yüksek gürültü seviyelerinde başarılı sonuçlar elde etmek için uzaysal gürültü giderme aşamasında GAN modeli tercih edilmiştir. GAN modelinde, gürültülü görüntü ve orijinal görüntü ayırt edici modelde kontrol edilerek, üretici kısımda oluşturulan görüntünün orijinal görüntüye dönüşümü sağlanmaktadır.

a. Modelin üretici kısmının oluşturulması

Uzaysal gürültü giderme modelinin üretici çekişmeli ağ kısmında basit bir derin öğrenme mimarisi kullanılmıştır. Geliştirilen gürültü giderme yapısında, üretilen görüntünün orijinal görüntüye bağlı olarak oluşturulması için derin evrişimli üretken çekişmeli ağ kullanılarak gürültüsüz görüntü elde edilmeye çalışılmıştır. Üretken çekişmeli ağlar, gürültü giderme sırasında detayları ve yapıyı koruyabilmektedirler. Ayırt edici ağ, gerçek ve üretilmiş verileri karşılaştırarak detayların ve yapısal özelliklerin korunmasını sağlayabilmektedir.

Geliştirilen gürültü giderme yapısında üretilen görüntünün orijinal görüntüye bağlı olarak oluşturulması için Pix2Pix [149] modeli baz alınarak üretici model oluşturulmuştur. Pix2Pix

GAN modeli görüntüler arasında dönüşümler gerçekleştirmek için üretilmiş bir model olup, gürültü giderme amacıyla U-Net mimarisi ile üretici ağ içinde kullanılmıştır. U-Net atlama bağlantıları girdi katmanındaki görüntüyü alarak boyut küçültme işlemi yapmaktadır. U-Net ağının çıktı katmanında görüntü tekrar aynı boyutuna döndürülmekte ve daha sonra derin evrişimli üretken çekişmeli ağ modeli mimarisinde VGGNet modelinden esinlenilerek, sadece evrişim ve aktivasyon katmanları kullanılmaktadır. VGG 19, evrişim ve aktivasyon fonksiyonlarına sahip, başarılı sonuçlar elde eden bir sınıflandırma modelidir.

Ağın üretici kısmında ilk olarak blok gürültü giderme işlemi yapılmaktadır. Sıralı video kareleri art arda getirilerek bir blok oluşturulmakta ve gürültü giderme işlemine bu blok üzerinde yapılmaktadır. Yapılan çalışmada art arda 3 kare birbirine eklenerek tek bir tensör haline getirilmiştir. Blok gürültü giderme, her bloğun benzer kareler içerdiği durumlarda uyarlmalı gürültü azaltma sağlamaktadır. Bir önceki ve bir sonraki karelerin çok hızlı hareket etmediği durumlarda benzer kareler gruplanmış olmaktadır. Bu sayede filtreler benzer karelere eşit olarak uygulandığından, görüntü özellikleri korunmakta görüntünün genel kalitesi artırmakta ve görüntü geçişindeki titremeler önlenmiş olmaktadır.


Yapılan denemelerde görüntü boyutları 180 x 180 olarak seçilmiştir. VGGM2 modeli kullanılarak 25 dB gürültü eklenmiş CBSD68 veri kümesi ile üretici ağ modeli üzerinde yapılan çalışmalarda elde sonuçlar Çizelge 4.4’de gösterilmektedir. Modelde farklı hiper parametreler denenmiş ve mimari denemeler sonucunda 16 katmana sahip, girdi boyutunun aynı boyutta çıktı üretmesi için gereken kenar dolgusunun ayarlandığı bir modele dönüştürülmüştür.

Çizelge 4.4. VGGM2 ağının oluşturulma sürecinde yapılan test sonuçları

No	U-Net Katman Sayısı	Tekrar Sayısı	Adım Adedi	Eğitim Verisi Sayısı	Genişletilmiş Evrişim Katmanı	Filtre Boyutu	Evrişim Katmanı Sayısı	Aktivasyon Fonksiyonu	Nöron Devre Dışı Bırakma	PSNR (dB)	SSIM
1	2	30	1	60	Yok	3x3	10	LeakyReLU	Yok	23,65	0,78
2	3	20	2	60	Yok	4x4	10	Sigmoid	Yok	22,32	0,74
3	4	30	1	60	Yok	3x3	10	LeakyReLU	Yok	21,09	0,70
4	1	30	1	60	Yok	3x3	10	LeakyReLU	Yok	22,84	0,75
5	3	10	2	68	Yok	3x3	10	LeakyReLU	Yok	22,37	0,74
6	2	20	2	60	Yok	4x4	10	ReLU	Yok	22,31	0,74
7	2	40	2	60	Yok	3x3	10	LeakyReLU	Yok	23,02	0,78
8	2	30	2	60	Yok	3x3	10	LeakyReLU	Yok	21,48	0,69
9	2	30	1	60	Yok	3x3	10	tanh	Yok	21,49	0,70
10	2	30	0	60	Yok	3x3	10	LeakyReLU	Yok	22,52	0,75
11	2	30	0	68	Yok	3x3	10	LeakyReLU	Yok	22,01	0,73
12	2	40	1	60	Var	3x3	10	Mish	Yok	22,65	0,74
13	2	40	2	60	Var	3x3	10	Swish	Yok	22,71	0,74
14	2	40	1	60	Yok	3x3	10	ReLU	Yok	22,13	0,72
15	2	30	1	60	Var	3x3	10	LeakyReLU	Yok	22,25	0,74
16	3	10	1	68	Yok	5x5	10	Sigmoid	Yok	21,69	0,71
17	2	30	1	60	Yok	3x3	10	Swish	Yok	21,31	0,77
18	2	30	1	60	Yok	3x3	10	Mish	Yok	20,42	0,77
19	2	30	2	60	Var	4x4	10	LeakyReLU	Yok	21,38	0,71
20	2	10	2	60	Yok	4x4	10	LeakyReLU	Yok	20,08	0,61
21	3	30	1	68	Yok	3x3	10	ReLU	Yok	22,67	0,75
22	4	30	2	68	Yok	4x4	9	ReLU	Yok	21,63	0,71
23	4	30	2	68	Yok	4x4	11	LeakyReLU	Yok	22,54	0,74
24	4	30	2	68	Yok	4x4	10	ReLU	Yok	21,63	0,71
25	2	40	1	60	Var	3x3	10	Mish	Yok	22,65	0,74
26	2	40	2	60	Var	3x3	10	Swish	Yok	22,71	0,74
27	2	40	1	60	Yok	3x3	10	ReLU	Yok	22,13	0,72
28	2	30	1	60	Var	3x3	10	LeakyReLU	Yok	22,25	0,74
29	2	30	2	60	Yok	3x3	10	tanh	Yok	20,38	0,71
30	2	30	1	68	Yok	3x3	10	Sigmoid	Yok	22,56	0,74
31	2	30	1	68	Yok	3x3	10	Sigmoid	Var	21,68	0,71

Üretici ağ oluşturulurken yapılan denemelerde üretici ağda katman sayısı artırılırsa, görüntünün aşırı öğrenmekte ve görüntüde bazı değer kayıpları olduğu görülmektedir.

VGGM2 modelinde eğitim verisi artırımı yapılmış ancak belirli değerden sonra artırılan eğitim verileri modelin başarısını olumsuz yönde etkilemiştir. Kullanılan filtre boyutu arttıkça yumuşatma miktarı artmakta, küçük boyutlu filtreler ise görüntü sıkıştırma işlemindeki başarıyı düşürmektedir. ADAM optimizasyon fonksiyonu VGGM1 modelinde olduğu gibi VGMM2 modelinde de kullanılmış olup, bu fonksiyon adapte edilebilirliği sayesinde hata değerlerine göre kendini ayarlayabilmektedir. U-Net ağı, boyut azaltma aşamasın görüntü boyutunu azalttığı için çok fazla U-Net katmanını kullanılması veri kaybına neden olmaktadır. Seçilen bu hiper parametrelere göre oluşturulan üretici ağı ait model Şekil 4.9'da yer almaktadır.



Şekil 4.9. Üretici ağ mimarisi

VGGM2 üretici ağındaki katmanlar Çizelge 4.5'de sunulmuştur. Katmanlar işlevlerine göre gruplanmış olup, model 16 katmandan oluşmaktadır.

Çizelge 4.5. Üretici ağ modeli katmanları

Katman Numarası	Katmanlar
1 (U-Net)	Conv2D
2...3 (U-Net)	Conv2D + LeakyReLU (2)
4 (U-Net)	Conv2DTranspose + BN + LeakyReLU + Concat
5 (U-Net)	Pixel Shuffle + Conv2D + Concat + Conv2D
6...15 (Evrişim)	Conv2D + LeakyReLU (10)
16	Subtract

VGGM2 ağıda ilk olarak evrişim katmanı kullanılmaktadır. Evrişim katmanından sonra U-Net ağıının boyut azaltma işlemi, evrişim ve LeakyReLU katmanları yer almaktadır. Boyut artırma işlemi için tersine evrişim, toplu normalizasyon ve LeakyReLU işlemleri yapılmaktadır. Ara katmanların çıktıları sonraki katmanda girdi olarak kullanılarak, önceki katmandaki verilerin bir sonraki katmana aktarılması sağlanmaktadır. Boyut artırma işleminin son aşamasında piksel karıştırma işlemi yapılarak elde edilen veriler ile boyut artırma işlemi yapılmıştır. Sonrasında evrişim ve katman birleştirme işlemleri yapılmış elde edilen veri boyutunun istenilen ölçüye gelmesi için tekrar evrişim katmanı kullanılmıştır. Son katmanda, evrişim ve LeakyReLU katmanları ile gürültü verisi ortaya çıkarılmıştır. İlk veriden gürültü verisi çıkartılarak gürültü giderilmiş görüntü elde edilmiştir.

b. Modelin ayırt edici kısmının oluşturulması

VGGM2 ayırt edici kısmı ile üretilen resmin orijinal resme benzer olup olmadığı ayırt edilmeye çalışılmaktadır. PatchGAN görüntüden görüntüye dönüşümlerde kullanılan yaklaşımlardan bir yaklaşım olup, Pix2Pix gibi görüntü sentezi işlemlerinde görüntü kalitesini artırmak veya daha gerçekçi sonuçlar elde etmek için kullanılmaktadır [150]. PatchGAN sistemi, gerçek ve sahte görüntüleri ayırt etmek için bütün resme bakmak yerine, resmi küçük yama parçalara bölüp, parça bazında değerlendirme yapmaktadır. VGGM2'nin ayırt edici kısmında PatchGAN modeli kullanılmış olup, modelin ilk kısmında üretilen görüntü ve gerçek görüntüleri girdi olarak almaktadır. Bu iki girdi vektörünü birleştirerek tek bir vektör elde edilmektedir. Ayırt edici model içinde (Conv2D -> BatchNorm -> LeakyReLU) aşamaları yer almaktadır. Bu aşamalarda Conv2D aşamasında iki boyutlu evrişim için kullanılmaktadır. 2 boyutlu evrişim katmanı, girdi verisi olarak görüntüyü almaktadır. Bu görüntü, siyah-beyaz olduğu zaman ayırt edici modelin girdi katmanı tek bir kanal içerirken, renkli bir görüntülerde her biri bir renk kanalını temsil eden üç kanala sahip olmaktadır. Bu katmanda 3x3 filtreler kullanılarak görüntüye ait özellikler ortaya çıkartılmaktadır. Toplu normalizasyon, ağı her katmanındaki çıktıları ölçeklendirilerek, aşırı uyumun azaltılması amaçlamaktadır. Bu sayede daha derin ağlar oluşturarak, daha büyük öğrenme oranlarının yakalanması sağlanmaktadır.

Ayırt edici ağ oluşturulurken yapılan denemelerde, ağdaki katman sayısı artırılırsa, model aşırı öğrenmekte ve gürültü giderme sonuçlarında değer kayıpları oluşmaktadır. Ayırt edici ağın oluşturulma sürecinde yapılan denemelere ait sonuçlar Çizelge 4.6’da sunulmuştur.

Çizelge 4.6. Ayırt edici ağın oluşturulma sürecinde yapılan denemelere ait sonuçlar

Adım	Genişletilmiş Evrişim Katmanı Sayısı	Optimizasyon Metodu	Aktivasyon Fonksiyonu	Momentum	Ağırlık Başlangıç Fonksiyonu	Yığın Boyutu	Toplam Katman Sayısı	PSNR (dB)	SSIM
1	0	ADAM	LeakyReLU	0,9	Normalized Xavier	1	4	23,65	0,78
2	1	ADAM	LeakyReLU	0,9	Normalized Xavier	1	4	22,46	0,74
3	2	ADAM	LeakyReLU	0,9	Normalized Xavier	1	4	22,23	0,74
4	0	RMSProb	LeakyReLU	0,9	Normalized Xavier	1	4	21,92	0,75
5	0	AdaGrad	LeakyReLU	0,9	Normalized Xavier	1	4	20,05	0,71
6	0	SGB	LeakyReLU	0,9	Normalized Xavier	1	4	22,50	0,70
7	2	ADAM	LeakyReLU	0,9	Normalized Xavier	1	4	22,61	0,78
8	0	ADAM	LeakyReLU	0,9	Normalized Xavier	1	4	23,06	0,77
9	2	AdaDelta	LeakyReLU	0,9	Normalized Xavier	1	4	20,13	0,71
10	2	RMSProb	Sigmoid	0,9	Xavier	1	4	22,76	0,76
11	2	ADAM	Orthogonal	0,9	He	16	6	20,82	0,72
12	2	ADAM	Sigmoid	0,9	Normalized Xavier	16	4	21,62	0,75
13	0	RMSProb	LeakyReLU	0,9	Normalized Xavier	1	4	21,92	0,75
14	0	RMSProb	Softmax	0,9	He	2	6	21,10	0,21
15	0	ADAM	tanh	0,9	Normalized Xavier	1	4	22,12	0,76
16	0	ADAM	Swish	0,9	He	16	4	22,34	0,76
17	0	ADAM	LeakyReLU	0,9	Xavier	1	4	22,51	0,76
18	2	RMSProb	Sigmoid	0,9	Xavier	1	4	22,76	0,76
19	0	ADAM	Sigmoid	0,5	Normalized Xavier	2	4	22,56	0,78
20	0	ADAM	tanh	0,9	Normalized Xavier	2	4	22,30	0,78
21	2	AdaDelta	Sigmoid	0,9	Normalized Xavier	4	4	20,43	0,71
22	0	RMSProb	Softmax	0,9	Normalized Xavier	2	6	21,10	0,71
23	2	ADAM	Sigmoid	0,0	He	2	4	21,55	0,72
24	2	ADAM	Mish	0,1	Xavier	1	4	23,18	0,78
25	2	ADAM	tanh	0,9	Xavier	1	4	22,28	0,77
26	2	ADAM	Swish	0,9	Normalized Xavier	16	4	22,97	0,76
27	2	AdaDelta	Sigmoid	0,9	Xavier	4	4	20,43	0,75
28	0	ADAM	Mish	0,0	He	2	4	22,55	0,75
29	0	ADAM	Mish	0,1	Normalized Xavier	1	4	23,18	0,72
30	0	ADAM	tanh	0,9	Normalized Xavier	1	4	22,12	0,76
31	0	ADAM	LeakyReLU	0,9	Normalized Xavier	16	4	20,15	0,71
32	0	ADAM	LeakyReLU	0,9	Normalized Xavier	8	4	20,54	0,71
33	0	ADAM	LeakyReLU	0,9	Normalized Xavier	4	4	21,05	0,72
34	0	ADAM	LeakyReLU	0,9	Normalized Xavier	2	4	21,45	0,73
35	0	ADAM	LeakyReLU	0,9	Normalized Xavier	1	4	22,12	0,74


36	0	ADAM	LeakyReLU	0,9	Normalized Xavier	1	2	20,02	0,71
37	0	ADAM	LeakyReLU	0,9	Normalized Xavier	1	4	23,21	0,76
38	0	ADAM	LeakyReLU	0,9	Normalized Xavier	1	6	22,12	0,75
39	0	ADAM	LeakyReLU	0,9	Xavier	1	4	22,36	0,75
40	0	ADAM	ReLU	0,1	Normalized Xavier	1	4	21,79	0,73

Yapılan denemeler sonucu genişletilmiş evrişim katmanının, modelin gürültü giderme sonuçlarını olumsuz etkilediği ve modelin öğrenme sürecini yavaşlattığı görülmektedir. Optimizasyon katmanının seçimi sırasında yapılan denemelerde ADAM optimizasyon yöntemi modelin öğrenme sürecini hızlandırmakta ve modelin başarılı sonuçlar elde etmesini sağlamaktadır. Aktivasyon fonksiyonları hangi verilerin aktive edileceğini belirlemekte ve aşırı öğrenmeyi engellemektedirler. LeakyReLU fonksiyonu modelin gürültü giderme aşamasında daha başarılı sonuçlar elde etmesini sağlamaktadır. Normalized Xavier ile ağırlık değerlerinin atanması modelin daha iyi değerlerle gürültü gidermesine yardımcı olmaktadır. Modelin katman sayısı arttıkça daha kötü sonuçlar elde edildiği için katman sayısı 4 olarak belirlenmiştir. Seçilen hiper parametrelere göre oluşturulan modele ait katmanlar Çizelge 4.7’de sunulmuştur.

Çizelge 4.7. Ayırt edici ağ modeli


Katman Numarası	Katmanlar
1	Conv2D + BatchNorm
2	Conv2D + BatchNorm + LeakyReLU
3	Conv2D + BatchNorm + LeakyReLU
4	Conv2D

VGGM2 ayırt edici modelinin ilk katmanında evrişim ve toplu normalizasyon yapılmaktadır. 2. ve 3. katmanlarda evrişim ve toplu normalizasyon yapılmakta ve aktivasyon katmanı olarak LeakyReLU kullanılmaktadır. Son katman boyut azaltma için kullanılarak bu katmada evrişim katmanı yer almaktadır. Ayırt edici modeldeki katmanlar Şekil 4.10’da sunulmuştur. Modelin çıktısı olarak 39x39’luk bir filtre elde edilmektedir.



Şekil 4.10. VGGM2 ağında ayırt edici model mimarisi


Ayırt edici model kayıp fonksiyonu girişte gerçek görüntü ve oluşturulan görüntüyü alarak hesaplama yapmaktadır. Kayıp değeri, orijinal görüntü verilerinin ve tüm elemanları bir olan dizinin sigmoid çapraz entropi kaybı şeklinde hesaplanmaktadır. Üretilen kayıp değeri, tahmin edilen görüntü ve tüm elemanları sıfır değerine sahip bir dizinin sigmoid çapraz entropi kaybıdır. Toplam kayıp değeri bu iki kayıp değerleri toplanarak hesaplanmaktadır. Modelin eğitimi sonrası hesaplanan kayıp değerleri Şekil 4.10'da sunulmuştur.



Şekil 4.11. Üretici çekişmeli ağın eğitimi sırasında elde edilen kayıp değerleri

VGGM2 ağı eğitilirken başlangıçta oluşturulan görüntü gerçekten çok uzak olmakta, bu nedenle ayırt edici ağ daha iyi kayıp değerleri elde etmektedir. Üretici ağ ilk eğitim aşamalarında düzgün olmayan görüntüler ürettiği için, ilk eğitim aşamalarında üretici kaybı rastgele davranmaktadır. Eğitimin sonuna doğru üretici kayıp değeri iyileşmeye başlamakta ve gerçeğe yakın görüntüler elde edilmektedir. Eğitimin son aşamalarında ayırt edicinin performansı düşmektedir. Oluşturulan VGMM2 modelinde ayırt edici kaybı zaman içerisinde azalmakta, üretici kaybı artmaktadır. Üretici çekişmeli ağı eğitimi sırasında elde edilen üretici ve ayırt edici kayıp grafiği incelendiğinde grafikteki bu artış ve düşüşler eğitim aşamasının başarılı geçtiğini göstermektedir.

VGGM2 modeli tasarlanırken modele girdi olarak verilen 3 ardışık görüntü yerine 5 görüntü kullanılarak da çalışma yapılmıştır. Modele 5 görüntüyü girdi alan çalışmada renklerde ve görüntüde bozulmalar meydana gelmektedir. Elde edilen görüntüler Resim 4.1’de sunulmuştur.



Resim 4.1. VGGM2 modelinde beş girdi kullanılması

Görüntü geçişinde titremenin önlenmesi

Gürültü giderimi için yapılan bazı çalışmalarda video görüntülerinin geçişi sırasında titremeleri önlemek için hareket tespiti yapılmaktadır. Her pikselin belirli bir zamandaki konumu, diğer bir zamandaki konumuyla karşılaştırılarak nesnenin hareketi hesaplanmaktadır. Hareket tahmini için kullanılan optik akış yöntemlerinde, nesne veya kamera hareketlerini tespit etmeye yarayan algoritmalar kullanılmaktadır. Gürültü giderme için kullanılan hareket tahmini içeren düşük gürültü değerlerine sahip bir görüntüde, ani değişen sahne içeriğinde bulanıklaşmayı önlemek için adaptif ağırlıklı ortalama filtresi kullanılmaktadır [151]. Bu yöntem hızlı yakınlaştırma ve kamera görüşünde değişiklikler olduğunda, aniden değişen sahne içeriği içeren görüntüleri filtrelemek için kullanılmaktadır. Başka bir çalışmada, video karelerinin çözünürlüğünü artırmak için hareket tabanlı bir yöntem geliştirilerek, nesne sınırları ve kenar bilgisinin daha yüksek kalitede oluşturulması sağlanmaktadır [152].

Hareket tahmini uzun hesaplamalar gerektirdiği ve geliştirilen yöntemin her görüntüde aynı çözümü sunamamasından dolayı bazı araştırmacılar hareket tahmini yerine görüntü karelerindeki pikseller arasında eşleştirme yaparak, eşleşen bloklardaki ağırlıklı ortalamayı alarak gürültü gidermektedirler. Hareket tahmini hesaplama problemlerini aşmak için, hareket tahmini olmayan birçok video giderme algoritması da geliştirilmiştir. Bu türde geliştirilen yöntemde başarılı bir örnek yerel olmayan ortalama yöntemidir. Bu yöntemlerde, gürültü giderme işlemi, her pikselin 2 boyutlu veya 3 boyutlu komşuluğunun ağırlıklı ortalaması bulunarak yapılmaktadır.

Yapılan çalışmada görüntü geçişinde titremeyi önlemek için yerel olmayan ortalamalar ile VGGM2 modelinin başarı değerleri kıyaslanmıştır. Yerel olmayan ortalamalar, kenarları ve görüntü detaylarını koruyarak başarılı gürültü giderme sonuçları sağlamaktadır [153]. Arama penceresi boyutu, yama boyutu, ağırlık fonksiyonu, düzenleme parametresi ve benzer yamaların sayısı, belirli bir görüntü ve gürültü giderme görevine bağlı olarak en iyi sonuçları elde etmek için ayarlanmaktadır. Yerel olmayan ortalamalar yöntemi ile gürültü giderilmesi yapılacak görüntünün boyutu, benzer yamaların belirlenmesi için kullanılacak pencere boyutunu seçmede önemli bir girdi oluşturmaktadır. Yapılan testlerde eğitim verisine ait


görüntünün boyutu 180x180 şeklinde belirlenmiştir. Filtre gücü, optimal başarı için belirlenmesi gereken başka bir parametredir. Daha yüksek filtre gücü gürültüyü daha iyi bir şekilde gidermekte, ancak aynı zamanda görüntünün detaylarını da kaybetmektedir. Yapılan denemelerde daha küçük arama pencereleri kullanılarak görüntüye ait ayrıntılar korunmakta ancak gürültüler görüntüden tam olarak arındırılamamaktadır. Daha büyük filtreleme seviyesi kullanılarak gürültü daha iyi bir şekilde ortadan kaldırılmakta ancak görüntüye ait ayrıntılar ortadan kaybolmaktadır. Yerel olmayan ortalamalar yöntemindeki parametre seçimleri ve çalışmanın sonuçları Çizelge 4.8’de sunulmuştur.

Çizelge 4.8. Yerel olmayan ortalamalar yöntemindeki hiper parametre seçimi

Filtreleme Seviyesi	Arama Pencere Genişliği	İşlem Süresi (sn)	PSNR	SSIM
4	21	1,8	22,61	0,74
5	21	2,3	22,66	0,74
7	25	2,4	22,73	0,75
7	29	2,4	22,70	0,75
7	23	2,1	22,71	0,75

Yerel olmayan ortalamalar yönteminde filtre seviyesi, arama pencere genişliği gibi görüntünün boyutu ve gürültü seviyesine bağlı olarak ayarlanması gereken parametreler bulunmaktadır. Filtre sayısı 7, arama pencere genişliği 23 kullanıldığı zaman optimum gürültü giderme sonucu elde edilmektedir.

CBSD400 veri kümesi üzerine 10 dB gürültü eklenerek yerel olmayan ortalamalar yöntemi ile gürültü giderme işlemi sonrası elde edilen görüntüler Resim 4.2’de sunulmuştur.




Resim 4.2. Yerel olmayan ortalamalar yöntemi sonucu oluşan görüntüler

180x180 boyutlarında Vimeo veri kümesine ait görüntüler kullanılarak önce VGGM1 modeli ile gürültü giderimi yapıldıktan sonra elde edilen görüntülerin yerel olmayan ortalamalar ve VGGM2 kullanılarak zamansal gürültü giderme işlemi yapılması sonucu elde ölçümlere ait sonuçlar Çizelge 4.9’da kıyaslanmaktadır.

Çizelge 4.9. Yerel olmayan ortalamalar yöntemi ile VGGM2'nin kıyaslanması

Yöntem	Gürültü Seviyesi	PSNR (dB)	SSIM
VGGM1 + VGGM2	$\sigma = 10$ dB	33,45	0,96
VGGM1 + NLM		32,63	0,96
VGGM1 + VGGM2	$\sigma = 20$ dB	31,28	0,94
VGGM1 + NLM		31,21	0,94
VGGM1 + VGGM2	$\sigma = 30$ dB	27,96	0,93
VGGM1 + NLM		26,36	0,92
VGGM1 + VGGM2	$\sigma = 40$ dB	24,80	0,84
VGGM1 + NLM		24,12	0,84
VGGM1 + VGGM2	$\sigma = 50$ dB	22,94	0,71
VGGM1 + NLM		22,47	0,71
VGGM1 + VGGM2	$\sigma = 60$ dB	23,28	0,79
VGGM1 + NLM		23,36	0,79
VGGM1 + VGGM2	$\sigma = 70$ dB	24,09	0,80
VGGM1 + NLM		24,17	0,80
VGGM1 + VGGM2	$\sigma = 80$ dB	23,45	0,78
VGGM1 + NLM		24,01	0,78
VGGM1 + VGGM2	$\sigma = 90$ dB	22,82	0,74
VGGM1 + NLM		23,01	0,74
VGGM1 + VGGM2	$\sigma = 100$ dB	21,96	0,72
VGGM1 + NLM		21,72	0,72

Yapılan çalışmada VGGM1 modeli sonrası VGGM2 zamansal modelinin kullanılması çoğu gürültü seviyesinde daha iyi sonuçlar vermektedir. İlk aşamada VGGM1 modeli kullanılarak 50 dB gürültüye sahip 180x180 boyutundaki görüntülerde gürültü giderildikten sonra elde edilen görüntülerde ikinci aşamada VGGM2 yöntemi ile gürültü giderme işlemi sonrası elde edilen görüntüler Resim 4.3'de sunulmuştur.



Resim 4.3. VGGM1 ve VGGM2 modelleri kullanılarak gürültü giderme

Farklı bir veri kümesi kullanılarak, yerel olmayan ortalamalar yöntemi ve VGGM2 yöntemi kıyaslanmıştır. Yerel olmayan ortalamalar yönteminde OpenCV kütüphanesi kullanılmış olup, 180x180 boyutundaki CBSD400 veri kümesi üzerinde 50 dB gürültü eklenen görüntülerde, gürültü giderme sonrası elde edilen görüntülerin PSNR değerlerinin, yerel

olmayan ortalamalar yönteminin uygulanması sonucu ortalama 1 dB oranında artış olduğu gözlenmiştir. Benzer çalışma VGGM2 modeli ile de yapılmış olup, [0-50] dB gürültü seviyelerinde bu modelin daha iyi sonuçlara ulaştığı görülmüştür.

Tüm sonuçlar karşılaştırıldığında daha az gürültüye sahip görüntülerde gürültü giderilmeye çalışıldığında, VGGM2 modelinin daha başarılı olduğu, gürültü değerleri 60-90 dB aralığında olduğu zaman yerel olmayan ortalamalar yönteminin daha iyi sonuçlar elde ettiği görülmüştür. Yerel olmayan ortalamalar yöntemi gürültü azaltmada iyi bir performans elde etmesine rağmen pencere boyutu, filtre gücü gibi elle ayarlanan parametrelere sahip olması ve GAN yönteminin daha iyi sonuçlar üretebilmesi nedeniyle zamansal gürültü giderme işleminde VGGM2 modelinin kullanımına karar verilmiştir.



5. DENEYSEL ÇALIŞMALAR

VGGM ağı gürültüyle bozulmuş video verilerinden gürültüyü kaldırıp, gerçek sinyalleri, uzaysal ve zamansal işleme yoluyla geri kazanmaktır. Uzaysal ve zamansal video gürültü giderme için mevcut yaklaşımlar genellikle hareketli bir nesnenin görüntü içinde değişmesi ya da hızlı hareket ettiğinde bulanık görünmeye başlaması ile optik akış hesaplamasının bozulmasına neden olmaktadır. VGGM’de önce görüntü, sonra video üzerinde gürültü giderilerek iki aşamalı bir model geliştirilmiştir. İlk aşamada görüntü karelerinde uzaysal gürültü giderme yapılmaktadır. İkinci aşama olan zamansal gürültü giderme aşamasında, bir önceki ve sonraki görüntü çerçeveleri dahil ederek daha iyi gürültü giderme olanağı sağlanmaktadır. Bu iki aşamalı ağı, donanımsal yetersizlikler nedeniyle ayrı ayrı eğitilmiştir. Son aşamada görüntüler arası titreme önlenerek görüntü geçişleri daha düzgün hale getirilmektedir. İlerleyen aşamalarda modelin çalıştırılma aşamaları ve diğer modellerle yapılan kıyaslamalar sunulmaktadır.

5.1. Çalışma Yapılan Veri Kümeleri

Gürültü giderme modelinin farklı senaryolarda etkili bir şekilde çalışmasını sağlamak için farklı veri kümeleri ile çalışması sağlanmıştır. Veri kümeleri, gerçek dünyadan elde edilen videolar ve görüntülerden oluşmaktadır. Hareketli nesneler, ani olarak değişen görüntü sahneleri ve farklı görüntüleri içeren veri kümeleri daha iyi sonuçlar elde etmeye yardımcı olmaktadır. Kullanılan veri kümelerine ait detaylı bilgi aşağıdaki bölümde sunulmuştur.

5.1.1. Set12 veri kümesi

Set12 veri kümesi, görüntü işleme ve gürültü giderme testlerinde yaygın olarak kullanılan, 12 tane test görüntüsünden oluşan bir görüntü koleksiyonudur. İlk yedi görüntünün boyutları 256×256 , son beş görüntünün boyutları ise 512×512 'dir. Bu görüntülere ait örnek resimler Resim 5.1’de sunulmuştur.



Resim 5.1. Set12 veri kümesine ait örnek görüntüler

5.1.2. DAVIS veri kümesi

Davis [154] veri kümesi video görüntülerinin görüntü karelerine ayrıştırılıp görüntü işlemede kullanılması için oluşturulan bir veri kümesidir. Davis veri kümesinde 60'ı eğitim, 30'u doğrulama, 60'ı test olmak üzere toplam 150 video bulunmaktadır. Videolar gerçek hayattaki olayların kaydedilmesi ile oluşmaktadır. Resim 5.2'de modeli eğitmek için kullanılan veri kümesine ait örnek görüntüler sunulmuştur.



Resim 5.2. DAVIS veri kümesine ait örnek görüntüler

5.1.3. Derf veri kümesi

Derf veri kümesi, video üzerinde yapılan çalışmalarda yaygın olarak kullanılan video parçalarını içermektedir. Veri kümesi doğa, insan ve manzara videolarını içermektedir. Resim 5.3'de modeli eğitmek için kullanılan veri kümesine ait örnek görüntüler sunulmuştur.



Resim 5.3. Derf veri kümesine ait örnek görüntüler

Derf veri kümesinden seçilen eğitim ve test videoları saniyede 30 çerçeve içermektedir. Eğitim verisi olarak “city, foreman” verileri kullanılmıştır. Test verisi olarak “crew” verisi kullanılmıştır. Her bir veri kümesi 300 video karesi içermektedir. Eğitim verisi toplamda 600 kare, test verisi 300 kare içermektedir. Modelin eğitimi ve testi sırasında YUV4MPEG formatındaki veriler RGB formatına çevrilerek kullanılmıştır.

5.1.4. CBSD400 veri kümesi

CBSD400 veri kümesi 400 tane renkli doğa görüntülerinden oluşmaktadır [155]. Bu veri kümesi eğitim verisi olarak kullanılmakta, test verisi olarak CBSD68 veri kümesi kullanılmaktadır. CBSD68, 68 tane renkli doğa görüntülerinden oluşan test verileridir. Resim 5.4’de modeli eğitmek için kullanılan veri kümesine ait örnek görüntüler sunulmuştur.



Resim 5.4. CBSD400 veri kümesine ait örnek görüntüler

5.1.5. Vimeo veri kümesi

Vimeo [156] veri kümesi, video süper çözünürlük ve gürültü giderme alanlarında kullanılan geniş bir veri kümesidir. Vimeo veri kümesi, birçok farklı video karesini içeren yüksek çözünürlüklü videolardan oluşmakta ve video işleme algoritmalarının değerlendirilmesi için kullanılmaktadır. Vimeo veri kümesi, çeşitli senaryolarda çekilmiş yüksek çözünürlüklü videolar içermektedir. Bu çeşitlilik, modelin farklı türlerde ve koşullarda etkili bir şekilde çalışmasını sağlamaktadır. Resim 5.5’de modeli eğitmek için kullanılan veri kümesine ait örnek görüntüler sunulmuştur.



Resim 5.5. Vimeo veri kümesine ait örnek görüntüler

5.1.6. BSD400 veri kümesi

Berkeley bölümlleme veri kümesi (Berkeley Segmentation Dataset 400-BSD400), 400 tane gri renkte doğa, şehir manzarası ve nesnelere ait görüntülerinden oluşmaktadır. BSD400 görüntü segmentasyonu alanında yaygın olarak kullanılan bir veri kümesidir. Görüntü işleme ve bilgisayarlı görü araştırmalarında segmentasyon algoritmalarının geliştirilmesi ve değerlendirilmesi için kullanılmaktadır. Modelin testi aşamasında BSD68 veri kümesi kullanılmıştır. BSD68, 68 tane gri renkte doğa görüntülerinden oluşmaktadır. Resim 5.6’da modeli eğitmek için kullanılan veri kümesine ait örnek görüntüler sunulmuştur.



Resim 5.6. BSD400 veri kümesine ait örnek görüntüler

Kullanılan eğitim ve test veri kümeleri

Davis 2017, CBSD400, Vimeo, Derf, Set12, BSD400 olmak üzere altı veri kümesi üzerinde gürültü giderme deneyleri gerçekleştirilmiştir. Davis 2017 eğitim veri kümesinde, 480 adet veriden oluşan bir küme kullanılmıştır. Eğitim verisi olarak kullanılan veri kümesindeki klasör adları ve görüntü sayıları; Car-turn - 80, Mbike-trick - 79, Motorcross-bumps - 60, Sheep - 68, Soccerball - 48, Train - 80, Upside-down - 65'dir. Test veri kümesi olarak Bus klasöründe yer alan 80 adet görüntü kullanılmıştır. İkinci veri kümesi olan Vimeo, gerçek yaşam görüntülerinden oluşmaktadır. Vimeo veri kümesi, ardışık görüntülere ait 7 alt klasörden oluşmaktadır. Bu veri kümesinde, Vimeo görüntülerinin 00001 ve 00002 dosyasındaki görüntülerden oluşan 420 tane görüntü eğitim kümesi kullanılmıştır. Vimeo veri kümesinde, 0003 klasöründeki 0004, 0007, 0008, 0012, 0016, 0019, 0022, 0025, 0029 ve 0031 numaralı klasörlerde yer alan toplam 70 görüntü test verisi olarak kullanılmıştır. Üçüncü veri kümesi olan CBSD400, 400 görüntüden oluşmaktadır. Derf veri kümesi görüntü işleme ve görüntü geçişlerinin test edilmesi amacıyla kullanılmaktadır. Derf veri kümesinde yer alan city30 ve foreman30 videoları toplam 600 tane video karesine sahiptirler. Bu videolar eğitim verisi olarak kullanılmıştır. Derf veri kümesinde yer alan crew videosu test verisi olarak kullanılmış olup, bu klasörde 300 adet görüntü bulunmaktadır. Toplamda 1900 adet renkli görüntü eğitim verisi olarak kullanılmıştır. Veri artırım oranı %20 olarak belirlendiği için renkli görüntülerde eğitim ve doğrulama verisi olarak toplamda 2280 görüntü kullanılmıştır. Eğitim veri oranı %80, doğrulama veri kümesi oranı %20 olarak belirlenmiştir. Gri renklerin testlerini yapabilmek için BSD400 veri kümesi ve BSD68 test veri kümesi kullanılmıştır. Önerilen yöntemlerin gürültü giderme performansını test etmek

için PSNR, SSIM, FSIM, RMSE, SRE, NMI ölçüm yöntemleri kullanılmıştır.

5.2. Deneysel Sonuçlar

VGGM, test veri kümesine farklı gürültü türleri eklenerek uygulanmış, elde edilen sonuçlara ait görseller ilerleyen bölümlerde karşılaştırılmıştır.

5.2.1. Kullanılan donanım

İlk etapta AMD Radeon Pro 5300M GPU'ya sahip, 2,6 GHz 6-Core Intel Core i7 işlemcili, 16 GB 2667 MHz DDR4 belleğe sahip bir bilgisayarda çalışma yapılmıştır. Kullanılan ilk donanım CPU ve RAM açısından uygun olmasına rağmen, yapılan çalışmada GPU ısınma sorunu nedeniyle farklı bir donanıma geçiş yapılmıştır. 1xTesla K80, compute 3.7, 2496 CUDA core içeren, 12GB GDDR5 VRAM GPU, 1xsingle core hyper threaded Xeon Processors @2.3Ghz işlemcili, 13 GB RAM 2667 MHz DDR4 belleğe sahip bir donanım üzerinde çalışma yapılmıştır.

5.2.2. VGGM'nin diğer modellerle kıyaslanması

VGGM alanında başarı elde etmiş derin öğrenme yöntemleri ve geleneksel gürültü giderme yöntemleri ile kıyaslanmıştır. Farklı veri kümeleri ile yapılan kıyaslamalarda modelin düşük gürültülerde başarılı sonuçlar elde ettiği görülmektedir. VGGM, BRDNet, SCUNet, FastDVDNet, DnCNN ve VideNN derin öğrenme modelleriyle modelleri ile kıyaslanmıştır. Geleneksel gürültü giderme yöntemlerinden Bilateral filtre, temel bileşen analizi, dalgacık dönüşümü, BM3D ve Wiener filtresi kıyaslama için kullanılmıştır.

Set12 veri kümesi ile yapılan çalışma

Geleneksel gürültü giderme yöntemleri görüntü işleme alanlarında uzun süredir kullanılan, matematiksel ve istatistiksel temellere dayanan yöntemlerdir. Bu yöntemler genellikle filtreleme ve sinyal dönüşüm yöntemlerini kullanmaktadırlar. Set12 veri kümesi kullanılarak, VGGM geleneksel gürültü giderme yöntemleri ile karşılaştırılmıştır. Elde edilen sonuçlar Çizelge 5.1'de sunulmuştur.

Çizelge 5.1. Set12 veri kümesi kullanılarak gürültü giderme sonuçları

Yöntem	Gürültü Değeri (dB)	PSNR	SSIM
VGGM	30	29,37	0,892
Bilateral Filtre	30	27,88	0,712
Temel Bileşen Analizi	30	26,68	0,596
Dalgacık Dönüşümü	30	21,74	0,316
BM3D	30	31,26	0,845
Wiener Filtresi	30	27,81	0,707

Yapılan kıyaslama sonucunda geliştirilen VGGM yöntemi yapısal benzerlik endeksine göre daha iyi değerler elde etmektedir. Yapısal benzerlik endeksi görüntüdeki parlaklık, kontrast ve yapısal benzerlik değerlerini kıyaslamaktadır. Bu değerler kıyaslandığında VGGM'nin diğer modellerden 0,1 daha fazla SSIM değerine sahip olduğu görülmektedir. BM3D yöntemi benzer görüntü karelerini gruplayarak gürültü giderme işlemi yapmaktadır. Bu yöntem PSNR değeri olarak en iyi sonucu elde etmektedir.

BSD400 veri kümesi ile yapılan çalışma

Yapılan çalışmada siyah beyaz görüntüler kullanılarak VGGM modeli, BRDNet modeli ve evrişimsel gürültü gideren otokodlayıcı modeli ve DnCNN modeli birbirleriyle eğitim süresi ve gürültü giderme başarısı başlıklarında kıyaslanmıştır. Elde edilen sonuçlarda DnCNN yönteminin diğer yöntemlere göre orijinal görüntüye daha yakın bir başarı elde ettiği görülmektedir. BRDNet yöntemi PSNR değerine göre üçüncü başarılı sonucu elde etmektedir. Yöntemin daha derin bir mimariye sahip olması nedeniyle modelin eğitim süresi diğer yöntemlere göre daha uzun sürmektedir. CDAE yöntemi diğer yöntemlere göre orijinal görüntüye biraz uzak bir sonuç elde etse de mimarinin basitliği nedeniyle eğitim süresi kısa sürmektedir. VGGM diğer yöntemlere göre daha uzun bir eğitim süresine sahiptir. VGGM, DnCNN yönteminden sonra ikinci başarılı sonucu elde etmektedir. Eğitim süreleri ve elde edilen başarı oranları Çizelge 5.2'de sunulmuştur.

Çizelge 5.2. BSD400 veri kümesi ile $\sigma=25$ dB gürültü seviyesinde gürültü giderme

Yöntem	Eğitim Süresi (sn)	Eğitim Kayıp Değeri	Test Kayıp Değeri	PSNR (dB)	SSIM	Toplam Parametre
VGGM	3900	0,0011	0,0010	33,71	0,95	1,432,712
BRDNet	1800	0,0026	0,0023	25,81	0,80	1,118,805
CDAE	50	0,0030	0,0027	25,59	0,82	314,625
DnCNN	650	0,0010	0,0009	34,49	0,97	558,016


Yapılan çalışmada BRDNet yönteminin, eğitim süresinin uzun olduğu, modelin eğitim sürecinde daha fazla belleğe ihtiyaç duyduğu görülmüştür. DnCNN yöntemi BRDNet yöntemi kıyaslandığında, DnCNN modelinin eğitim süresinin daha kısa olduğu ve orijinal resme yakınlık açısından başarılı sonuçlar elde ettiği görülmektedir. BRDNet mimarisinde iki farklı model üzerinde gürültü giderimi yapıldıktan sonra son aşamada görüntüler birleştirilerek gürültü giderimi tamamlanmaktadır. Model derin bir ağa sahip olduğu için eğitim süresi olarak ikinci sırada yer almaktadır. CDAE yöntemi hızlı eğitim süresi ile ön plana çıkmaktadır. Otokodlayıcılar veriyi önce sıkıştırıp sonra orijinal veri boyutuna dönüştürdüğü için kullanılan parametreler diğer modellere göre daha az olmakta ve eğitim süresi diğerlerinden daha kısa sürmektedir.

VGGM daha derin bir mimariye sahip olduğu için eğitim süresi diğerlerine göre daha uzun sürmektedir. Düşük gürültü seviyelerinde VGGM, DnCNN modelinden sonra ikinci başarılı sonucu elde etmektedir. 180x180 boyutlarında BSD400 eğitim veri kümesi kullanılarak $\sigma=25$ dB gürültü seviyesinde gürültü giderme işlemi sonucu elde edilen görüntüler Resim 5.7’de sunulmuştur.


Orijinal Görüntü



Gürültülü Görüntü



VGGM



DnCNN



CDAE





Resim 5.7. BSD400 veri kümesinde gürültü giderme

Görüntülerde DnCNN yöntemi ile yapılan gürültü giderme işleminde orijinal görüntüye daha yakın sonuçlar elde edilmektedir. VGGM ile yapılan gürültü giderme sonucunda gürültü kalıntılarının olduğu görülmektedir. BRDNet ve CDAE benzer sonuçları elde etmektedir, buna paralel olarak iki modelin ürettiği görüntülerde gürültü tam olarak giderilememekte ve görüntü üzerinde gürültü kalıntıları yer almaktadır.

Vimeo veri kümesi ile yapılan çalışma

Renkli görüntüler ile yapılan çalışmada gürültü giderme sırasında 180x180 görüntü boyutlarına sahip Vimeo veri kümesi kullanılmıştır. Vimeo veri kümesindeki görüntülere farklı seviyelerde Gauss gürültüsü eklenerek gürültü giderme işlemi yapılmıştır. Gürültü giderme işlemi sonuçları Çizelge 5.3’de yer almaktadır.

Çizelge 5.3. Vimeo veri kümesi ile gürültü giderme


Model	PSNR	SSIM	FSIM	RMSE	SRER	NMI
$\sigma=10$ dB						
VGGM	33,45	0,96	0,98	0,00000595	27,60940518	1,31988876
DnCNN	31,62	0,96	0,96	0,00000658	29,94891832	1,26481931
FastDVDNet	38,75	0,97	0,98	0,00000370	28,73818615	1,47420992
SCUNet	32,32	0,93	0,96	0,00000683	29,19934567	1,31023457
ViDeNN	36,01	0,97	0,98	0,00000375	28,81461964	1,37967875
$\sigma=20$ dB						
VGGM	31,28	0,94	0,98	0,00000670	26,51251097	1,28100650
DnCNN	28,50	0,88	0,94	0,00000919	28,91471904	1,21844920
FastDVDNet	36,14	0,96	0,81	0,00000816	29,42698117	1,41383780
SCUNet	31,01	0,90	0,85	0,00001020	28,46563232	1,22453432
ViDeNN	32,78	0,95	0,98	0,00000546	27,19880515	1,30970825
$\sigma=30$ dB						
VGGM	27,96	0,93	0,97	0,00000785	25,84463736	1,26539911

DnCNN	27,57	0,85	0,93	0,00000976	25,60464560	1,21524364
FastDVDNet	34,56	0,94	0,78	0,00000910	26,95832594	1,36728302
SCUNet	30,28	0,88	0,73	0,00001020	26,24969337	1,26575533
ViDeNN	30,78	0,94	0,97	0,00000690	26,20117441	1,27062415
$\sigma = 40$ dB						
VGGM	24,80	0,84	0,93	0,00001772	22,31818627	1,15976109
DnCNN	25,78	0,86	0,90	0,00001266	27,68365936	1,20183748
FastDVDNet	31,50	0,91	0,96	0,00000938	25,91240181	1,29212799
SCUNet	28,05	0,86	0,94	0,00000989	26,45223221	1,28343232
ViDeNN	29,25	0,92	0,96	0,00000824	25,43972099	1,24162612
$\sigma = 50$ dB						
VGGM	22,94	0,71	0,91	0,00001746	22,35371852	1,13447810
DnCNN	24,07	0,86	0,89	0,00001549	26,01237444	1,18954434
FastDVDNet	30,94	0,90	0,74	0,00001014	22,20597940	1,27439129
SCUNet	27,35	0,78	0,69	0,00001180	28,74564596	1,21104815
ViDeNN	28,07	0,90	0,95	0,00000946	24,84573300	1,21933855
$\sigma = 60$ dB						
VGGM	23,28	0,79	0,94	0,00001678	22,61964692	1,14339676
DnCNN	23,61	0,83	0,88	0,00001790	26,23484544	1,13836454
FastDVDNet	29,62	0,88	0,92	0,00002083	26,96939781	1,25531418
SCUNet	25,76	0,85	0,90	0,00001790	25,48590480	1,18572409
ViDeNN	27,07	0,88	0,95	0,00001061	24,34607659	1,20172489
$\sigma = 70$ dB						
VGGM	24,09	0,80	0,94	0,00001640	22,68025209	1,16675618
DnCNN	23,59	0,83	0,88	0,00001890	26,21848328	1,12952568
FastDVDNet	29,21	0,86	0,91	0,00000823	29,34231944	1,24043889
SCUNet	23,55	0,82	0,88	0,00001901	26,22983478	1,12567458
ViDeNN	26,18	0,85	0,94	0,00001178	23,89812518	1,18720548
$\sigma = 80$ dB						
VGGM	23,45	0,78	0,93	0,00001705	22,46940346	1,14968402
DnCNN	23,19	0,82	0,87	0,00001930	26,20343453	1,12885443
FastDVDNet	27,87	0,82	0,89	0,00001546	29,09311029	1,22085701
SCUNet	23,54	0,81	0,82	0,00001449	22,90645323	1,18065343
ViDeNN	25,32	0,83	0,93	0,00001300	25,47850984	1,17491554
$\sigma = 90$ dB						
VGGM	22,82	0,74	0,92	0,00001772	22,26718184	1,12774747
DnCNN	22,79	0,80	0,86	0,00002080	26,01435457	1,12792385
FastDVDNet	27,20	0,78	0,77	0,00001748	24,33056552	1,20021257
SCUNet	21,80	0,72	0,61	0,00003051	21,67656433	1,13906643
ViDeNN	24,38	0,80	0,92	0,00001449	23,02029919	1,16353475
$\sigma = 100$ dB						
VGGM	21,96	0,72	0,81	0,00002955	21,90164551	1,13943164
DnCNN	22,29	0,79	0,84	0,00002270	25,96653362	1,14738346
FastDVDNet	25,63	0,79	0,86	0,00002084	27,96033125	1,17881298
SCUNet	21,59	0,71	0,60	0,00003186	21,53600689	1,12222803
ViDeNN	23,37	0,77	0,81	0,00003625	22,53674612	1,15140495

Vimeo veri kümesi ile yapılan çalışmada FastDVDNet yöntemi diğer yöntemlere göre daha başarılı sonuçlar elde etmektedir. Modelin mimarisinde kullanılan gürültü haritaları diğer modellerde bulunmamakta olup, gürültü haritaları, modele giderilecek gürültü hakkında ön bilgi vermektedir. Modelin eğitimi sırasında gürültü haritaları kullanılarak, gerçek gürültü


dağılımına benzer gürültüler elde edilebilmektedir. Modelin tüm gürültü seviyelerinde başarı elde etmesindeki en önemli faktörlerden bir diğeri de zamansal ve uzaysal modelin tek bir seferde eğitilmesi ve modelin tek seferde ağırlık değerlerinin hesaplanmasıdır.

Vimeo test veri kümesi kullanılarak yapılan gürültü giderme çalışmasındaki, PSNR değerleri kıyaslaması Şekil 5.1’de, SSIM değerlerinin kıyaslanması Şekil 5.2’de, FSIM değerlerinin kıyaslanması Şekil 5.3’de, RMSE değerlerinin kıyaslanması Şekil 5.4’de, SRER değerlerinin kıyaslanması Şekil 5.5’de, NMI değerlerinin kıyaslanması Şekil 5.6’da çubuk grafik olarak sunulmuştur.




Şekil 5.1. Vimeo veri kümesi kullanılarak PSNR değerlerinin kıyaslanması

Hazırlanan modelde RAM ve GPU kısıtından dolayı uzaysal ve zamansal model ayrı ayrı eğitilmiş olup, uzaysal modeldeki ağırlık değerleri zamansal modele bağlı olarak değişmemektedir. PSNR değerleri göz önünde bulundurulduğunda VGGM, 0-30 dB gürültü aralığında DnCNN modeline göre daha iyi sonuçlar elde etmesine rağmen, ilerleyen gürültü seviyelerinde aşırı öğrenme ve yüksek gürültüye adapte olamamasından dolayı düşük başarı oranlarına sahip olmaktadır. 20 dB gürültü eklenmiş görüntüler incelendiğinde DnCNN yönteminde gürültü kalıntılarına rastlanılmaktadır. İkinci başarılı PSNR değerlerini ViDeNN modeli elde etmektedir.



Şekil 5.2. Vimeo veri kümesi kullanılarak SSIM değerlerinin kıyaslanması


ViDeNN, Vimeo veri kümesinde SSIM değerleri dikkate alındığında ikinci başarılı sonucu elde etmektedir. Modelin mimarisinde 2 aşamalı gürültü giderme işlemi yapılmakta ve model tek bir parça halinde eğitilmektedir. Bu model FastDVDNet modelinden sonra ikinci başarılı sonuçları elde etmektedir.



Şekil 5.3. Vimeo veri kümesi kullanılarak FSIM değerlerinin kıyaslanması


SCUNet mimarisinde görüntüler arası eşleştirme yapılarak benzer görüntüler üzerinde gürültü giderme işlemi yapılmaktadır. Bu model yüksek gürültü seviyelerinde daha düşük başarılar elde etmektedir. Bu model gürültü giderme performansını artırmak için seyrek kodlama ve derin öğrenme tekniklerinin birleşimini kullanmaktadır. Seyrek kodlama görüntüdeki gürültüyü tahminlemek için kullanılan bir vektörü ifade etmektedir. SCUNet seyrek kodlama ve U-Net mimarisini kullanarak gürültü giderme işlemi yapmaktadır. Bu

model FSIM değerleri göz önünde bulundurulduğunda yüksek gürültü seviyelerinde kenar ve dokuları tam olarak oluşturamamaktadır.




Şekil 5.4. Vimeo veri kümesi kullanılarak RMSE değerlerinin kıyaslanması

RMSE, modelin gürültü giderme performansını değerlendirmek için kullanılan bir ölçüdür ve modelin tahminlerinin gerçek değerlerden ne kadar uzak olduğunu göstermektedir. Daha düşük bir RMSE değeri, daha iyi bir model performansını temsil etmektedir. Dolayısıyla, bir modelin diğerlerinden daha düşük bir RMSE değeri elde etmesi, bu modelin daha iyi tahminler yaptığını göstermektedir. RMSE hesaplanırken, modelin tahminlerinin gerçek değerlerle arasındaki farkların karelerinin toplamının ortalamasının karekökü alınır. Gürültü giderme sonuçları incelendiğinde FastDVDNet ve ViDeNN modellerinin daha düşük RMSE değerlere sahip olduğu görülmektedir. VGGM 0 - 30 dB aralığında FastDVDNet ve ViDeNN modellerinden sonra iyi sonuçlar elde etmektedir.



Şekil 5.5. Vimeo veri kümesi kullanılarak SRER değerlerinin kıyaslanması

SRER, sinyal işleme veya sıkıştırma işlemi sırasında sinyalin ne kadar iyi bir şekilde yeniden oluşturulduğunu değerlendirmek için kullanılmaktadır. Yüksek SRER değerleri, daha iyi bir yeniden oluşturma veya sıkıştırma performansını temsil etmektedir. DnCNN modeli 10, 40 ve 90 dB gürültü değerlerinde en iyi SRER değerlerine sahip olmaktadır. Model farklı gürültü seviyelerine adapte olması sebebiyle bu başarıyı elde etmektedir. 50 dB gürültüde SCUNet modeli başarılı sonuç elde etmekte olup, diğer gürültü seviyelerinde FastDVDNet modeli başarılı sonuçlar elde etmektedir.



Şekil 5.6. Vimeo veri kümesi kullanılarak NMI değerlerinin kıyaslanması

DnCNN modeli 19 katmandan oluşan evrişimli sinir ağına sahiptir. Bu model NMI değerleri kıyaslandığında düşük gürültülerde diğer modeller kadar başarı elde edemese de gürültü miktarı arttıkça elde edilen değerler diğer modellere yaklaşmaktadır. Vimeo veri kümesinde görüntüler 7 ardışık kareden oluşmakta ve sonrasında başka hareketli görüntüye geçilmektedir. Bu veri kümesinde görüntü geçişleri diğer veri kümelerine göre daha kısa sürede gerçekleşmektedir. Hızlı görüntü geçişlerinde gürültü giderme işlemi yapıldığında FastDVDNet'in diğer modellere göre başarılı sonuçlar elde ettiği görülmektedir.

Vimeo veri kümesi kullanılarak 180x180 görüntü boyutlarında 20 dB gürültü eklenmiş görüntülerde farklı gürültü giderme modelleri kullanılarak gürültü giderme işlemi sonrası elde edilen görüntüler Resim 5.8'de sunulmuştur.

Orjinal Görüntü



Gürültülü Görüntü




VGGM



DnCNN





Resim 5.8. Vimeo veri kümesinde gürültü giderme işlemi

Görüntülerin görsel olarak kıyaslanması sonucu, PSNR ve SSIM değerlerine paralel olarak FastDVDNet modeli ile gürültü giderme sonucu elde edilen görsellerde daha başarılı görüntüler elde edildiği görülmektedir. FSIM görüntüler arasındaki hem yapısal hem de algısal benzerlikleri dikkate alan bir ölçüttür. FSIM değerlerinin PSNR ve SSIM değerleri ile benzer kalitede sonuçlar üretmesine rağmen bazı görüntülerde daha düşük veya yüksek değerler üretebildiği görülmüştür. $\sigma = 10$ dB gürültü seviyesinde VGGM daha iyi FSIM değerine sahip olmasına rağmen PSNR ve SSIM değerleri daha düşük kalmaktadır. FSIM değeri parlak yüzeylerde, benzerlik ölçüsü olarak kullanıldığında küçük görüntü değişikliklerinde bile farklı sonuçlar üretebilmektedir. Bu yüzden FSIM değerinin tek başına görüntü kalitesi ölçütü olarak değerlendirilmesi hatalı yorumlara neden olmaktadır. RMSE

değerleri de uç değerlere sahip görüntü ve gürültü değerlerinde farklı sonuçlar verebilmektedir. $\sigma = 90$ dB gürültü seviyesinde DnCNN yöntemi daha iyi NMI değeri elde etmesine rağmen diğer ölçüm değerleri daha düşük kalmaktadır. Bu sebeple bu iki değer görüntülerde tek başına bir değerlendirme ölçütü olarak kullanılması uygun olmamaktadır. Benzer şekilde NMI değerini elde ederken entropi hesabı yapmak gerekmektedir. Bu değer görüntü üzerindeki piksel değerlerine göre farklılık gösterebilmektedir. $\sigma = 10$ dB gürültü seviyesinde VGGM daha iyi NMI değerine sahip olmasına rağmen diğer ölçüm değerleri daha düşük kalmaktadır. Yapılan testlerde PSNR ve SSIM değerleri ana belirleyici iki ölçüt olarak kullanıp bu değerlerin birbirlerine yakın olması durumunda destekleyici olarak RMSE, SRER, NMI ve FSIM değerleri kullanılmıştır.

DAVIS veri kümesi ile yapılan çalışma

Gürültü giderme sırasında 180x180 boyutlarına sahip DAVIS veri kümesi kullanılmıştır. DAVIS veri kümesindeki görüntülere farklı seviyelerde Gauss gürültüsü eklenerek gürültü giderme işlemi yapılmıştır. Gürültü giderme işlemi sonuçları Çizelge 5.4’de yer almaktadır.


Çizelge 5.4. DAVIS veri kümesi ile gürültü giderme

Model	PSNR	SSIM	FSIM	RMSE	SRER	NMI
$\sigma = 10$ dB						
VGGM	31,78	0,93	0,98	0,00000683	29,26974930	1,26987463
DnCNN	30,77	0,91	0,96	0,00000490	29,99472868	1,26182283
FastDVDNet	38,11	0,96	0,99	0,00000277	35,43981756	1,45502321
SCUNet	30,72	0,95	0,99	0,00001812	29,87664987	1,27439879
ViDeNN	33,53	0,96	0,98	0,00000487	31,44241704	1,35137601
$\sigma = 20$ dB						
VGGM	29,17	0,92	0,97	0,00000851	29,42367443	1,25779684
DnCNN	27,18	0,88	0,95	0,00001346	27,38648844	1,18074927
FastDVDNet	35,37	0,94	0,96	0,00001065	33,06740303	1,39300627
SCUNet	29,15	0,94	0,95	0,00000968	28,98664246	1,26498802
ViDeNN	30,20	0,93	0,97	0,00000717	29,80603207	1,28517021
$\sigma = 30$ dB						
VGGM	28,76	0,82	0,95	0,00001054	28,76694030	1,22958473
DnCNN	26,41	0,86	0,92	0,00001325	27,50226580	1,23433250
FastDVDNet	34,67	0,92	0,96	0,00001165	30,36740301	1,23300625
SCUNet	28,75	0,83	0,94	0,00001357	29,03066201	1,25098663
ViDeNN	28,15	0,90	0,96	0,00000911	28,82660867	1,24722737
$\sigma = 40$ dB						
VGGM	22,05	0,76	0,93	0,00001928	25,87198471	1,16344878
DnCNN	24,48	0,80	0,88	0,00001241	27,88163958	1,20122600
FastDVDNet	32,56	0,89	0,93	0,00001203	29,66815767	1,33523720
SCUNet	26,41	0,83	0,92	0,00001325	28,02044902	1,23085424

ViDeNN	26,69	0,87	0,80	0,00001479	28,12833890	1,22122650
$\sigma = 50$ dB						
VGGM	21,80	0,75	0,84	0,00002067	25,88018375	1,15805674
DnCNN	22,85	0,73	0,84	0,00001760	26,28163958	1,14966463
FastDVDNet	32,08	0,88	0,91	0,00001554	29,46261563	1,32096365
SCUNet	24,22	0,77	0,89	0,00001829	26,80453220	1,19428053
ViDeNN	25,63	0,84	0,93	0,00001220	27,60900776	1,20256580
$\sigma = 60$ dB						
VGGM	21,45	0,74	0,85	0,00002185	25,68064858	1,14680543
DnCNN	21,20	0,73	0,89	0,00002190	25,34285421	1,12125532
FastDVDNet	31,25	0,86	0,91	0,00001709	29,05493732	1,30470135
SCUNet	23,54	0,74	0,87	0,00001824	26,59839211	1,08459834
ViDeNN	24,75	0,82	0,92	0,00001352	27,16755387	1,18669149
$\sigma = 70$ dB						
VGGM	20,95	0,73	0,90	0,00002432	25,50102832	1,13046062
DnCNN	20,93	0,72	0,88	0,00002175	25,32578679	1,13191219
FastDVDNet	29,65	0,80	0,91	0,00002411	28,53668005	1,23679482
SCUNet	22,05	0,73	0,84	0,00001603	25,69343993	1,08432345
ViDeNN	24,03	0,79	0,87	0,00001468	26,80476419	1,17428092
$\sigma = 80$ dB						
VGGM	20,18	0,73	0,83	0,00001393	25,42066400	1,12072550
DnCNN	20,79	0,71	0,85	0,00001478	25,26640364	1,12476800
FastDVDNet	28,33	0,76	0,89	0,00001378	28,13405078	1,22157992
SCUNet	21,35	0,73	0,83	0,00001260	25,35969211	1,08968323
ViDeNN	23,36	0,77	0,81	0,00001487	26,46538701	1,16303266
$\sigma = 90$ dB						
VGGM	20,98	0,72	0,82	0,00002169	25,60213221	1,13083434
DnCNN	20,59	0,71	0,82	0,00002687	25,12164679	1,11988646
FastDVDNet	27,62	0,73	0,85	0,00001148	27,96645895	1,19565763
SCUNet	20,56	0,70	0,81	0,00001780	26,02487538	1,11498301
ViDeNN	22,76	0,75	0,82	0,00001702	26,16048722	1,15468792
$\sigma = 100$ dB						
VGGM	21,45	0,71	0,81	0,00002067	25,65137099	1,13916560
DnCNN	20,43	0,71	0,80	0,00001780	25,01865561	1,11396234
FastDVDNet	26,55	0,67	0,84	0,00001246	27,66175553	1,21103088
SCUNet	20,42	0,68	0,80	0,00001740	25,00257597	1,11363498
ViDeNN	22,12	0,72	0,82	0,00001833	25,84814133	1,14524906


DAVIS veri kümesi ile yapılan çalışmada FastDVDNet yöntemi diğer yöntemlere göre daha başarılı sonuçlar elde etmektedir. DAVIS veri kümesi Vimeo veri kümesinden farklı olarak görüntü geçişlerinin daha az olduğu, video karelerinde benzer yamaların daha fazla olduğu bir yapıya sahiptir.

DAVIS veri kümesi kullanılarak yapılan gürültü giderme çalışmasına ait sonuçların, PSNR değerlerinin kıyaslanması Şekil 5.7’de, SSIM değerlerinin kıyaslanması Şekil 5.8’de, FSIM değerlerinin kıyaslanması Şekil 5.9’da, RMSE değerlerinin kıyaslanması Şekil 5.10’da, SRER değerlerinin kıyaslanması Şekil 5.11’de, NMI değerlerinin kıyaslanması Şekil 5.12’de çubuk grafik olarak sunulmuştur.




Şekil 5.7. DAVIS veri kümesi kullanılarak PSNR değerlerinin kıyaslanması

PSNR, gürültü giderme sonrası elde edilen görüntünün orijinal resme olan benzerliğini piksel değeri olarak karşılaştırmasını yapmaktadır. Gürültü giderme modelleri, gürültüyü azaltmak için bazen sinyaldeki detayları kaybetmektedirler. Bu, PSNR değerini artırabilirken, yeniden oluşturulan sinyalin orijinal sinyalden daha farklı olmasına yol açabilmektedir. Görüntü geçişlerinin daha az olduğu DAVIS test veri kümesinde ikinci başarılı sonuçları ViDeNN modeli elde etmektedir. ViDeNN modelinin mimarisinde 2 aşamalı gürültü giderme işlemi yapılmakta olup, DnCNN mimarisine benzer evrişim katmanları kullanılmaktadır. Model DnCNN mimarisinden farklı olarak iki aşamalı gürültü giderme işlemi yapmakta ve DnCNN modelinden daha başarılı sonuçlar elde etmektedir.




Şekil 5.8. DAVIS veri kümesi kullanılarak SSIM değerlerinin kıyaslanması

VGGM yönteminin PSNR değerleri diğer modellere göre nispeten düşük kalsa da SSIM değeri olarak daha iyi sonuçlar elde etmektedir. Bunun nedeni olarak, SSIM, insan görsel algısını taklit etmeye çalışırken, PSNR daha çok matematiksel bir hata ölçüm yöntemi olmasıdır. İnsan gözü, özellikle yapısal bilgileri ve dokuları koruyan hafif bozulmaları fark etmeyebilmekte, bu yüzden bir görüntü yüksek SSIM değerine sahip olabilmektedir. Ancak, aynı görüntü, özellikle gürültü varsa, düşük bir PSNR değerine sahip olabilmektedir.




Şekil 5.9. DAVIS veri kümesi kullanılarak FSIM değerlerinin kıyaslanması

DAVIS veri kümesinde gürültü giderme işlemi sonrasında FastDVDNet modeli başarılı sonuçlar elde etmektedir. SCUNet modeli, DAVIS veri kümesinde görüntü geçişleri daha az olduğu için bu model Vimeo kümesine göre daha başarılı sonuçlar elde etmektedir. SCUNet mimarisi kayan pencereler kullanarak video karelerindeki benzer pikselleri gruplayarak toplu gürültü giderme işlemi yapmaktadır.




Şekil 5.10. DAVIS veri kümesi kullanılarak RMSE değerlerinin kıyaslanması

VGMM, Vimeo veri kümesinde olduğu gibi 0-30 dB gürültü seviyelerinde başarılı RMSE sonuçları elde etmektedir. İlerleyen gürültü seviyelerinde gürültü giderme sonrası görüntülerde renk bozulmaları olmakta ve gürültü kalıntıları artmaktadır. Modelin eğitimi sırasında yüksek gürültülü veriler kullanılmasına rağmen model belirli bir gürültü seviyesinden sonra daha az başarılı sonuçlar elde etmektedir.



Şekil 5.11. DAVIS veri kümesi kullanılarak SRER değerlerinin kıyaslanması

SRER, yeniden oluşturma algoritmasının performansını orijinal görüntü ile gürültü giderme sonucu elde edilen görüntü arasındaki hatayı hesaplayarak ölçmektedir. DAVIS veri kümesi kullanılarak DnCNN modeli ile gürültü giderimi yapıldığında, Vimeo veri kümesi kullanılarak elde edilen sonuçlara benzer değerler elde edilmektedir. DAVIS veri kümesinde görüntüler gerçek dünyadaki hareketli nesnelere ait kesitlerden oluşmaktadır. Görüntü geçişleri diğer veri kümelerine göre daha uzun sürede gerçekleşmektedir.



Şekil 5.12. DAVIS veri kümesi kullanılarak NMI değerlerinin kıyaslanması

Görüntü geçişlerinin az olduğu DAVIS veri kümesinde gürültü giderme işlemi yapıldığında FastDVDNet'in diğer modellere göre başarılı sonuçlar elde ettiği görülmektedir. Geliştirdiğimiz model 0 - 30 dB gürültüler arasında başarılı sonuçlar elde etmektedir. Gürültü seviyeleri arttığında elde edilen başarı düşmekte ancak yine de diğer modellere yakın sonuçlar elde edilmektedir. DAVIS veri kümesi kullanılarak 180x180 boyutlarında 40 dB gürültü eklenmiş görüntülerde farklı modeller kullanılarak gürültü giderme işlemi sonrası elde edilen görüntüler Resim 5.9'da sunulmuştur.





Resim 5.9. DAVIS veri kümesinde gürültü giderme işlemi

Elde edilen görüntülerin görsel olarak kıyaslanması sonucu PSNR ve SSIM değerlerine paralel olarak FastDVDNet modeli ile gürültü giderme sonucu elde edilen görüntülerde daha başarılı görseller elde edilmektedir. FSIM değerleri incelendiğinde FastDVDNet

modeli ile birlikte ViDeNN modelinin başarılı sonuçlar elde ettiği görülmektedir. SSIM, görüntüler arasındaki benzerlikleri dikkate alan bir ölçüt olup, SSIM değerleri incelendiğinde yine FastDVDNet modelinin başarılı sonuçlar elde ettiği görülmektedir. RMSE gürültü giderme sonucu görüntü ile gerçek görüntü arasındaki hata miktarını ölçmek için kullanılan bir ölçüt olup, RMSE değerleri kıyaslandığında FastDVDNet ve ViDeNN değerlerinin SCUNet, ViDeNN ve VGGM'den daha başarılı sonuçlar elde ettiği görülmektedir. $\sigma = 30$ dB gürültü seviyesinde SCUNet yöntemi daha iyi NMI değeri elde etmesine rağmen diğer ölçüm değerleri daha düşük kalmaktadır. $\sigma = 20$ dB gürültü seviyesinde ViDeNN modeli daha iyi değerlere sahiptir. Değerler genel olarak incelendiğinde FastDVDNet yöntemi daha başarılı sonuçlar elde etmektedir. Görüntüler incelendiğinde SCUNet ve DnCNN yöntemlerinde gürültü kalıntılarının olduğu diğer modellerin gürültüyü daha iyi giderdiği görülmektedir.

CBSD400 veri kümesi ile yapılan çalışma

Gürültü giderme sırasında 180x180 boyutlarına sahip CBSD400 veri kümesi kullanılmıştır. CBSD400 veri kümesindeki görüntülere farklı seviyelerde Gauss gürültüsü eklenerek gürültü giderme işlemi yapılmıştır. Gürültü giderme işlemi sonuçları Çizelge 5.5'de yer almaktadır.

Çizelge 5.5. CBSD400 veri kümesi ile gürültü giderme


Model	PSNR	SSIM	FSIM	RMSE	SRER	NMI
$\sigma = 10$ dB						
VGGM	30,28	0,92	0,81	0,00000720	29,24969337	1,26575533
DnCNN	30,60	0,91	0,80	0,00000754	29,76642208	1,22489643
FastDVDNet	35,52	0,96	0,82	0,00000480	30,54643463	1,37604520
SCUNet	32,98	0,92	0,77	0,00000519	30,13666236	1,30830528
ViDeNN	34,24	0,97	0,81	0,00000441	30,45879120	1,33186345
$\sigma = 20$ dB						
VGGM	29,12	0,92	0,88	0,00000869	29,39834687	1,24428074
DnCNN	30,51	0,89	0,75	0,00000840	29,25166634	1,22050622
FastDVDNet	31,74	0,91	0,77	0,00001650	30,65252790	1,29464971
SCUNet	29,88	0,89	0,75	0,00001001	28,95346746	1,27423565
ViDeNN	31,71	0,93	0,76	0,00000678	29,95220868	1,29547283
$\sigma = 30$ dB						
VGGM	27,10	0,88	0,76	0,00001102	28,34840055	1,20934696
DnCNN	29,10	0,89	0,73	0,00001020	29,94022643	1,26977502
FastDVDNet	30,01	0,90	0,78	0,00000953	29,24565356	1,22354544
SCUNet	27,17	0,85	0,72	0,00001072	28,37606699	1,23917307
ViDeNN	28,64	0,90	0,84	0,00000866	28,91604004	1,22503521
$\sigma = 40$ dB						
VGGM	21,99	0,74	0,84	0,00001947	25,84453572	1,15226345

DnCNN	24,77	0,84	0,74	0,00001646	24,51352421	1,20315910
FastDVDNet	28,34	0,84	0,73	0,00001004	28,94904868	1,23001984
SCUNet	25,77	0,79	0,71	0,00001224	28,02454115	1,18459452
ViDeNN	28,42	0,87	0,83	0,00001026	28,20305411	1,20011756
$\sigma = 50$ dB						
VGGM	20,34	0,73	0,82	0,00002354	23,68086045	1,13081043
DnCNN	26,74	0,85	0,76	0,00001136	28,19645760	1,19811293
FastDVDNet	27,46	0,80	0,67	0,00001028	28,60464560	1,21523646
SCUNet	24,51	0,70	0,67	0,00001996	27,77312922	1,16054963
ViDeNN	26,19	0,84	0,83	0,00001159	27,68384604	1,18244366
$\sigma = 60$ dB						
VGGM	19,52	0,74	0,71	0,00002588	24,97282865	1,10577625
DnCNN	26,25	0,84	0,76	0,00001201	27,95978748	1,19098707
FastDVDNet	26,68	0,85	0,75	0,00001213	27,01695717	1,19733201
SCUNet	23,12	0,79	0,65	0,00001853	26,23434564	1,11234545
ViDeNN	25,32	0,81	0,70	0,00001284	27,24840439	1,16796543
$\sigma = 70$ dB						
VGGM	20,14	0,73	0,89	0,00002401	23,60283471	1,14349876
DnCNN	25,78	0,86	0,79	0,00001243	27,68323432	1,21090643
FastDVDNet	26,69	0,77	0,65	0,00001276	27,21714988	1,20155841
SCUNet	21,55	0,71	0,61	0,00002001	25,98343453	1,13454545
ViDeNN	24,62	0,79	0,88	0,00001393	26,89907720	1,15635782
$\sigma = 80$ dB						
VGGM	20,32	0,71	0,90	0,00002365	25,49369764	1,11499777
DnCNN	25,29	0,81	0,90	0,00001340	27,49019014	1,17470186
FastDVDNet	24,99	0,70	0,62	0,00001122	27,26986291	1,17015979
SCUNet	21,10	0,69	0,60	0,00002034	25,94323533	1,11343221
ViDeNN	23,98	0,76	0,88	0,00001502	26,57891556	1,14655656
$\sigma = 90$ dB						
VGGM	21,42	0,71	0,88	0,00002267	25,80564673	1,12574755
DnCNN	24,51	0,70	0,67	0,00001622	27,47312943	1,16052085
FastDVDNet	24,43	0,75	0,60	0,00001422	24,08825306	1,16088540
SCUNet	19,80	0,59	0,60	0,00001021	26,64653432	1,10103454
ViDeNN	23,39	0,74	0,87	0,00001607	26,28834436	1,13753807
$\sigma = 100$ dB						
VGGM	21,72	0,72	0,88	0,00002029	25,82481108	1,13129656
DnCNN	24,16	0,77	0,74	0,00001524	26,92952160	1,15525238
FastDVDNet	23,41	0,60	0,60	0,00001650	25,47695008	1,14273260
SCUNet	19,60	0,66	0,58	0,00003073	27,69430375	1,10069010
ViDeNN	22,81	0,72	0,86	0,00001718	26,00498029	1,12997123

CBSD400 veri kümesi kullanılarak eğitilen VGGM modeli, CBSD68 test verisi ile diğer modellerle kıyaslanmıştır. CBSD400 veri kümesi ile yapılan çalışmada FastDVDNet yöntemi diğer yöntemlere göre daha başarılı sonuçlar elde etmektedir. Düşük gürültü seviyelerinde ViDeNN, yüksek gürültü seviyelerinde DnCNN yöntemlerinin başarı elde ettiği görülmektedir.


CBSD400 veri kümesi kullanılarak yapılan gürültü giderme çalışmasına ait sonuçlarda, PSNR değerlerinin kıyaslaması Şekil 5.13'de, SSIM değerlerinin kıyaslanması Şekil

5.14’de, FSIM değerlerinin kıyaslanması Şekil 5.15’de, RMSE değerlerinin kıyaslanması Şekil 5.16’da, SRER değerlerinin kıyaslanması Şekil 5.17’de, NMI değerlerinin kıyaslanması Şekil 5.18’de çubuk grafik olarak sunulmuştur.




Şekil 5.13. CBSD400 veri kümesi kullanılarak PSNR değerlerinin kıyaslanması

CBSD400 veri kümesi ile yapılan testlerde VGGM’nin, Vimeo veri kümesi ile yapılan testlere göre elde edilen PSNR değerleri biraz daha düşmüştür. Vimeo ve CBSD400 veri kümesi benzer teknik özelliklere sahip olsa da içerdikleri sahnelerin içeriği (nesnelerin hareketi, sahnenin karmaşıklığı, renk dağılımı vb.) farklı olduğu için, videoların içeriğindeki bu farklılıklar, modelin gürültüyü azaltma şeklini etkilemektedir. Vimeo veri kümesindeki hareketli nesneler daha az olduğu için bu modelde daha başarılı sonuçlar elde etmesine rağmen, ani geçişlere sahip CBSD400 veri kümesinde modelin performansını düşmektedir.




Şekil 5.14. CBSD400 veri kümesi kullanılarak SSIM değerlerinin kıyaslanması

FastDVDNet yöntemi farklı gürültü seviyelerinde daha iyi SSIM değerlerine sahiptir. FastDVDNet modeli geniş bir veri kümesi kullanılarak eğitilmesinden dolayı bu veri kümesinde de başarılı sonuçlar elde etmektedir.




Şekil 5.15. CBSD400 veri kümesi kullanılarak FSIM değerlerinin kıyaslanması

ViDeNN modeli DnCNN mimarisine göre daha derin bir ağı sahip olduğu için farklı görüntü ve gürültü türlerine kolay adapte olabilmektedir. Bu model DnCNN ve SCUNet modellerine göre daha başarılı FSIM sonuçları elde etmektedir.




Şekil 5.16. CBSD400 veri kümesi kullanılarak RSME değerlerinin kıyaslanması

FastDVDNet modeli başarılı RMSE sonuçları elde etse bile, bazı gürültü seviyelerinde diğer modellerden daha kötü sonuçlar almaktadır. Veri kümesindeki nesnelerin hareketi, sahnenin karmaşıklığı, renk dağılımı ve gürültü seviyelerinde modelin davranışları bu sonuçları etkilemektedir.



Şekil 5.17. CBSD400 veri kümesi kullanılarak SRER değerlerinin kıyaslanması

DnCNN modeli farklı görüntülerde gürültü giderme için eğitildiğinden dolayı CBSD400 veri kümesinde SRER değeri olarak başarılı sonuçlar elde etmektedir. VGGM, Vimeo veri kümesinde olduğu gibi 0-30 dB gürültü seviyelerinde başarılı sonuçları elde etmektedir. İlerleyen gürültü seviyelerinde gürültü giderme sonrası modelin başarısı düşmektedir.



Şekil 5.18. CBSD400 veri kümesi kullanılarak NMI değerlerinin kıyaslanması

DAVIS veri kümesi farklı görüntülere ait görüntülerden oluşmaktadır. Bu veri kümesinde gerçek dünyaya ait görüntüler yer almakta olup, görüntü geçişlerinin sürekli olduğu bir yapıya sahiptir. 180x180 görüntülere 60 dB Gauss gürültüsü eklenerek farklı gürültü giderme modelleri kullanılarak elde edilen gürültü giderilmiş görüntüler Resim 5.10'da sunulmuştur.

Orjinal Görüntü



Gürültülü Görüntü




VGGM



DnCNN





Resim 5.10. CBSD400 veri kümesinde gürültü giderme işlemi

Görüntüler incelendiğinde VGGM ile gürültü giderme sonrasında elde edilen ölçüm değerlerinin düştüğü görüntülerde gürültü kalıntıları ve görüntülerde bozulmaların arttığı görülmektedir. PSNR ve SSIM değerlerine paralel olarak FastDVDNet modeli ile gürültü giderme sonucu elde edilen görüntülerde daha başarılı görseller elde edilmektedir. DNCNN modelinin $\sigma = 100$ dB gürültü seviyesinde RMSE ve NMRSE değerleri incelendiğinde başarılı sonuçlar elde ettiği görülmektedir. SSIM değerleri incelendiğinde yine FastDVDNet modelinin başarılı sonuçlar elde ettiği görülmektedir. SRER ve NMI değerleri incelendiğinde DnCNN modeli $\sigma = 30$ dB gürültü seviyesinde başarılı sonuçlar elde etmektedir.

Derf veri kümesi ile yapılan çalışma

Gürültü giderme sırasında 180x180 boyutlarına sahip Derf veri kümesi kullanılmıştır. Derf veri kümesindeki görüntülere farklı seviyelerde Gauss gürültüsü eklenerek gürültü giderme işlemi yapılmıştır. Gürültü giderme işlemi sonuçları Çizelge 5.6’da yer almaktadır.


Çizelge 5.6. Derf veri kümesi ile gürültü giderme

Model	PSNR	SSIM	FSIM	RMSE	SRER	NMI
$\sigma = 10$ dB						
VGGM	33,23	0,96	0,98	0,00000524	29,60940518	1,31239873
DnCNN	28,60	0,87	0,96	0,00000912	27,37443098	1,22146877
FastDVDNet	34,94	0,97	0,96	0,00000755	30,12237728	1,24534886
SCUNet	34,82	0,97	0,94	0,00000417	30,30781396	1,36203436
ViDeNN	34,99	0,97	0,98	0,00000430	30,52879440	1,34786105
$\sigma = 20$ dB						
VGGM	30,52	0,93	0,97	0,00000729	28,56389940	1,27741914
DnCNN	25,41	0,83	0,95	0,00001585	27,70423143	1,20270076
FastDVDNet	34,44	0,93	0,86	0,00000606	30,06143899	1,34449232
SCUNet	30,71	0,86	0,88	0,00000669	29,05166641	1,29050685
ViDeNN	32,30	0,94	0,87	0,00000585	29,16875400	1,28724434
$\sigma = 30$ dB						
VGGM	29,47	0,91	0,91	0,00000891	28,42684021	1,26494021
DnCNN	27,12	0,86	0,82	0,00001053	28,97437790	1,23912366
FastDVDNet	32,87	0,90	0,83	0,00000916	29,67121394	1,30915975
SCUNet	29,50	0,88	0,81	0,00000983	29,02843283	1,28347239
ViDeNN	30,59	0,91	0,85	0,00000713	28,31005061	1,25295242
$\sigma = 40$ dB						
VGGM	22,72	0,71	0,82	0,00002002	24,15546915	1,14477998
DnCNN	27,42	0,87	0,72	0,00001051	28,53010276	1,20759574
FastDVDNet	32,21	0,89	0,71	0,00000884	29,59524545	1,29883448
SCUNet	28,80	0,87	0,71	0,00001060	28,62323232	1,21837211
ViDeNN	29,20	0,89	0,73	0,00000838	27,61828676	1,22746186
$\sigma = 50$ dB						
VGGM	21,22	0,70	0,88	0,00002026	24,17645430	1,14232675
DnCNN	27,87	0,85	0,73	0,00000988	26,89845991	1,20148289
FastDVDNet	30,82	0,85	0,89	0,00001246	28,63558419	1,26519923
SCUNet	28,79	0,79	0,61	0,00001279	27,24125217	1,23040443
ViDeNN	28,08	0,86	0,72	0,00000953	27,05707676	1,20686247
$\sigma = 60$ dB						
VGGM	20,49	0,70	0,90	0,00002308	23,66077582	1,12926578
DnCNN	27,35	0,84	0,72	0,00001048	26,63888862	1,19325890
FastDVDNet	29,96	0,83	0,86	0,00000805	27,20556574	1,24795226
SCUNet	27,43	0,84	0,72	0,00001050	26,65476572	1,19518261
ViDeNN	27,17	0,84	0,71	0,00001059	26,59012250	1,18995814
$\sigma = 70$ dB						
VGGM	21,05	0,69	0,89	0,00002015	24,13431232	1,10234221
DnCNN	26,91	0,83	0,71	0,00001103	26,62221625	1,18515934
FastDVDNet	28,65	0,78	0,84	0,00001001	26,52043666	1,17509472
SCUNet	26,65	0,82	0,70	0,00001110	26,42173722	1,18618127
ViDeNN	26,36	0,82	0,70	0,00001162	26,17199301	1,17515073

$\sigma = 80$ dB						
VGGM	20,85	0,68	0,88	0,00002216	23,11750197	1,10449037
DnCNN	24,76	0,82	0,71	0,00001642	24,58806242	1,20824220
FastDVDNet	28,36	0,77	0,83	0,00001388	26,99407072	1,21468781
SCUNet	24,23	0,80	0,70	0,00001702	25,56232322	1,21376236
ViDeNN	25,61	0,80	0,74	0,00001268	25,78453643	1,16288578
$\sigma = 90$ dB						
VGGM	20,38	0,68	0,87	0,00002376	23,10653326	1,10056534
DnCNN	24,10	0,77	0,74	0,00001288	26,91081771	1,14988770
FastDVDNet	27,32	0,72	0,81	0,00001077	26,86699035	1,19415754
SCUNet	23,62	0,57	0,53	0,00001429	27,82831853	1,14782884
ViDeNN	24,91	0,78	0,78	0,00001374	25,42347300	1,15231258
$\sigma = 100$ dB						
VGGM	20,96	0,72	0,87	0,00002013	22,90860343	1,13874532
DnCNN	22,31	0,79	0,74	0,00002175	25,54253361	1,14145442
FastDVDNet	26,12	0,66	0,79	0,00001483	26,25874734	1,17148616
SCUNet	22,15	0,78	0,74	0,00002149	25,54054142	1,14113433
ViDeNN	24,16	0,76	0,88	0,00001498	25,04815657	1,14268922


Derf veri kümesinde YUV formatında video görüntüleri yer almaktadır. Videolar aynı görüntüye ait 300 ve daha fazla karelerden oluşmaktadır. Derf veri kümesi ile yapılan çalışmada FastDVDNet yöntemi diğer yöntemlere göre daha başarılı sonuçlar elde etmektedir.

Vimeo veri kümesi kullanılarak yapılan gürültü giderme çalışmasına ait sonuçların, PSNR değerleri kıyaslaması Şekil 5.19'da, SSIM değerlerinin kıyaslanması Şekil 5.20'de, FSIM değerlerinin kıyaslanması Şekil 5.21'de, RMSE değerlerinin kıyaslanması Şekil 5.22'de, SRER değerlerinin kıyaslanması Şekil 5.23'de, NMI değerlerinin kıyaslanması Şekil 5.24'de çubuk grafik olarak sunulmuştur.




Şekil 5.19. Derf veri kümesi kullanılarak PSNR değerlerinin kıyaslanması

FastDVDNet modelinin PSNR değerlerine göre, diğer veri kümelerine benzer sonuçları elde etmesinde; modelin gürültü haritası ve iki aşamalı gürültü gidermeyi kullanmasının faydalı olduğu görülmektedir. DnCNN modeli farklı görüntülerle çalışabilmesi amacıyla oluşturulduğu için Derf veri kümesinde başarılı sonuçlar elde etmektedir. Derf veri kümesinde benzer kareler fazla olup gruplanan görüntü sayısı diğer veri kümelerine göre daha fazla olmaktadır.




Şekil 5.20. Derf veri kümesi kullanılarak SSIM değerlerinin kıyaslanması

SCUNet modeli daha başarılı SSIM değerlerine sahiptir. SCUNet modeli Swin dönüşüm altyapısı kullanmaktadır. Bu altyapıda görüntüler sabit boyutlu yamalar yerine pencereler olarak işlenmektedir. Bu pencereler, her dönüşüm bloğu içinde kaydırılır, böylece model, yerel özellikleri daha etkili bir şekilde yakalayabilmektedir. SCUNet modeli SSIM ölçümlerindeki parlaklık, kontrast ve yapı gibi genel özelliklere göre daha iyi sonuçlar elde etmektedir.




Şekil 5.21. Derf veri kümesi kullanılarak FSIM değerlerinin kıyaslanması

FSIM, kenar ve doku gibi ince detaylara SSIM'den daha duyarlı olup, bu nedenle daha detaylı bir analiz sağlayabilmektedir. FSIM sonuçlarına göre VGGM başarılı sonuçlar elde etmektedir.




Şekil 5.22. Derf veri kümesi kullanılarak RMSE değerlerinin kıyaslanması

VGGM 0 dB ile 30 dB arasında daha az RMSE değerlerine sahipken ilerleyen gürültü seviyelerinde aşırı öğrenmeye bağlı olarak hata oranı artmakta ve daha yüksek RMSE değerleri elde etmektedir. Yüksek gürültü seviyelerinde FastDVDNet modelinin başarılı sonuçlar elde ettiği görülmektedir. RMSE değeri, gerçek görüntü ile elde edilen görüntü arasında piksel farklılıkları arttıkça büyümektedir. VGGM yöntemi kullanılarak gürültü giderme yapıldığında, gürültü seviyesi 40 dB üzerine çıktığı değerlerde, RMSE değerinin de arttığı gözlenmiştir.



Şekil 5.23. Derf veri kümesi kullanılarak SRER değerlerinin kıyaslanması

SRER değerleri kıyaslandığında, ViDeNN yöntemi 10 dB'e kadar olan gürültülerde daha başarılı sonuç elde etmiştir. ViDeNN, derin bir ağ yapısına sahiptir. Bu model Derf veri kümesinde diğer veri kümelerine göre, düşük gürültü seviyelerinde, başarılı sonuçlar elde etmiştir.




Şekil 5.24. Derf veri kümesi kullanılarak NMI değerlerinin kıyaslanması

SCUNet modeli Derf veri kümesinde gürültü giderimi yaparken daha fazla benzer kareleri gruplayabilmektedir. Ancak model FastDVDNet ve ViDeNN mimarilerine göre daha az katman kullandığı için başarı oranı daha düşük kalmaktadır. VGGM, diğer veri kümelerinde olduğu gibi 0-30 dB gürültü aralığında başarılı sonuçları elde etmektedir. İlerleyen gürültü seviyelerinde gürültü giderme sonrası başarı oranı düşmektedir. Derf veri kümesi kullanılarak 80 dB gürültü eklenmiş 180x180 boyutlarındaki görüntülerde, farklı gürültü giderme modelleri kullanılarak gürültü giderme işlemi sonrası elde edilen görüntüler Resim 5.11'de sunulmuştur.



Gürültülü Görüntü



VGGM



DnCNN



FastDVDNet





Resim 5.11. Derf veri kümesinde gürültü giderme işlemi

Derf veri kümesinde VGGM yöntemi kullanılarak gürültü giderme işlemi yapıldığında, gürültü seviyesi arttıkça, elde edilen başarı değerlerinin düştüğü, görüntülerde gürültü kalıntıları ve görüntülerde bozulmaların arttığı görülmektedir. PSNR ve SSIM değerlerine paralel olarak FastDVDNet modeli ile gürültü giderme sonucu elde edilen görüntülerde daha başarılı görseller elde edildiği görülmektedir. FSIM değerleri incelendiğinde VGGM modelinin $\sigma = 10$ ve 20 dB gürültü seviyesinde başarılı sonuçlar elde ettiği görülmektedir. SSIM değerleri incelendiğinde ViDeNN modelinin $\sigma = 10$ ve 20 dB gürültü seviyesinde başarılı sonuçlar elde ettiği görülmektedir. NMI değeri incelendiğinde SCUNet modelinin $\sigma = 10$ dB gürültü seviyesinde başarılı sonuçlar elde ettiği görülmektedir. SRER değeri incelendiğinde DnCNN modelinin $\sigma = 70$ dB gürültü seviyesinde başarılı sonuçlar elde ettiği görülmektedir. RMSE, NMRSE değerleri incelendiğinde SCUNet modelinin $\sigma = 10$ dB gürültü seviyesinde başarılı sonuçlar elde ettiği görülmektedir.

5.2.3. Geliştirilen hibrit derin öğrenme modelinin çalışma zamanının analizi

NVIDIA Tesla K40 GPU kullanarak, Berkeley segmentasyon veri kümesinde DnCNN modelinin eğitimi yaklaşık 12 saat sürmektedir [86]. SCUNet modelinin GPU kullanılarak

400 görüntüye sahip Berkeley veri kümesi üzerindeki eğitim süresi bir gün kadar sürmektedir. Gerçek eğitim süresi, kullanılan belirli donanım ve yazılım yapılandırmalarına bağlı olarak değişebilmektedir. Eğitim süresini azaltmak için araştırmacılar transfer öğrenimi, veri büyütme ve model sıkıştırma gibi çeşitli teknikleri araştırmaktadırlar. Benzer şekilde, eğitim veri kümesinin boyutunu artırmak ve modelin performansını iyileştirmek için rastgele kırpma, çevirme ve döndürme gibi veri artırma teknikleri kullanılmakta, modeldeki parametrelerin ve işlemlerin sayısını azaltmak için atlama, bilgi damıtma gibi model sıkıştırma teknikleri kullanılabilmektedir.

Videolarda, video karesinin hızı, kameranın saniyede yakaladığı video karelerinin sayısına eşittir. Video üretiminde, bir videonun kare hızı, saniye başına kare olarak ifade edilmektedir. Bazı video kare hızları, video üretimi için yaygın olarak kullanılmaktadır. Sinema videoları için saniyede 24 kare (Frame Per Second-fps), standart videolar için 30 fps, ağır çekim videolar için 60 fps şeklinde kullanılmaktadır. Gürültü giderme modelinin işlem süresi, videonun gerçek zamanlı işlenebilmesi için önemli bir ölçüttür. Gerçek zamanlı görüntü işleyebilmek için, modelin görüntüyü giriş videosunun kare hızından daha kısa bir zaman diliminde işleyebilmesi gerekmektedir. Gerçek zamanlı modeller, düşük gecikme süresi ve düşük hesaplama karmaşıklığı ile giriş video karelerini en düşük gecikme ile çıkışa iletmelidir. Giriş videosu saniyede 24 kare hızında olursa, gerçek zamanlı gürültü giderme modeli her kareyi işleyebilmeli ve gürültü giderilmiş görüntüyü 41 milisaniye veya daha kısa sürede çıkarabilmelidir. Görüntülerde gürültü giderme işlemleri yapıldığında elde edilen ortalama işlem süreleri Çizelge 5.7’de sunulmuştur.

Çizelge 5.7. Modellerin DAVIS test verisi ile gürültü giderme işlem süreleri

Model	Gürültü Giderme Ortalama Süresi (milisaniye)	Katman Sayısı
VGGM	63	47
FastDVDNet	215	38
ViDeNN	90	40
DnCNN	27	19
SCUNet	230	35

Elde edilen değerler, 24 fps ve 30 fps videoları da gürültü giderme işleminin gerçek zamanlı yapılabilmesi için sadece DnCNN modelinin kullanılabileceğini ortaya çıkarmaktadır.

DnCNN modeli katman sayısı olarak diğer modellere göre daha az katman sayısına sahip olduğu için daha hızlı sürede gürültü giderebilmektedir. VGGM 47 katmandan oluşmakta olup, DnCNN modelinden sonra ikinci hızlı gürültü giderme süresine sahiptir. Modelin gürültü giderme süreleri modelin katman sayısına ve katmanlarda yapılan işlemlere bağlı olarak değişmektedir. En uzun gürültü giderme süresi SCUNet modelinde gerçekleşmektedir. ViDeNN modeli katman sayısı fazla olmasına rağmen kısa sürede gürültü giderme işlemi yapabilmektedir.

5.2.4. Görüntülerin görsel olarak kıyaslanması

Yapılan çalışmada düşük gürültü seviyelerinde gürültülerin başarılı bir şekilde giderildiği görülmektedir. Oluşturulan model ile CBS400 veri kümesi üzerinde 180x180 boyutundaki görüntülerde farklı gürültü seviyelerinde gürültü giderme çalışması yapılmıştır. Çalışma sonrası elde edilen görüntüler Resim 5.12’de sunulmuştur. Bu gürültü seviyelerinde görüntü üzerindeki düz alanlardaki gürültü giderildikten sonra bulut gibi renk geçişi olmayan alanların pürüzsüz olması sağlanmıştır. Gürültü seviyesi arttıkça bazı dokularda gürültü kalıntıları giderilememiş, görüntü üzerinde yeni gürültüler de ortaya çıkmıştır.

Orijinal Görüntü








Gürültülü Görüntü





Gürültü Giderilmiş Görüntü



$$\sigma = 10 \text{ dB}$$

 $\sigma = 20 \text{ dB}$  $\sigma = 30 \text{ dB}$  $\sigma = 40 \text{ dB}$  $\sigma = 50 \text{ dB}$

 $\sigma = 60 \text{ dB}$  $\sigma = 70 \text{ dB}$  $\sigma = 80 \text{ dB}$  $\sigma = 90 \text{ dB}$



$$\sigma = 100 \text{ dB}$$

Resim 5.12. CBSD400 veri kümesinde gürültü giderme işlemi

VGGM kullanılarak elde edilen görüntüler incelendiğinde 0 dB ve 30 dB arası gürültüye sahip görüntülerde başarılı sonuçlar elde edildiği görülmektedir. Gürültü seviyesi arttıkça gürültü kalıntıları, görüntü ve dokulardaki bozulmalar göze çarpmaktadır. $\sigma = 40$ ve 80 dB olan gürültülerde dokulardaki bozulmalar ve renk değişimleri oluşmaktadır. $\sigma = 50$ dB gürültü seviyesinde bulut gibi parlak alanlarda gürültü kalıntılarının olduğu görülmektedir.

5.2.5. Modellerin eğitim verisi sayılarının kıyaslanması

VGGM ve diğer modeller eğitim verisi sayısı açısından kıyaslanmış olup, bu değerler Çizelge 5.8’de sunulmuştur.

Çizelge 5.8. Modellerin eğitim verisi sayılarının kıyaslanması

Yöntem	Eğitim Verisi
VGGM	1900
CDAE	1900
DnCNN	1900
FastDVDNet	4219
SCUNet	8394
ViDeNN	4744

VGGM, DnCNN, CDAE, FastDVDNet, SCUNet ve ViDeNN modelleri ile karşılaştırılmıştır. Bu modeller farklı veri kümeleri ile eğitilmişlerdir. DnCNN ve CDAE modeli, VGGM ile aynı veri kümesi kullanılarak 1900 tane görüntü ile eğitilmiştir. SCUNet

modeli, eğitim için Waterloo keşif veritabanını [157], DIV2K [158] ve Flickr2K'yı [159] kullanmıştır. Waterloo keşif veritabanı, 4744 bozulmamış doğal görüntü ve 94880 bozuk görüntü içermektedir. DIV2K veri kümesi farklı sahnelere sahip 1000 görüntü içermektedir. Flickr2K veri kümesi, 2650 adet renkli görüntü içermektedir. FastDVDNet modelinin eğitimi için DAVIS veri kümesi kullanılmıştır. FastDVDNet modelinin eğitimi için 4219 adet veri kullanılmıştır. VideNN modelinin eğitimi için waterloo araştırma veritabanındaki 4744 adet eğitim verisi kullanılmıştır.

Elde edilen sonuçlara göre FastDVDNet, VideNN ve SCUNet modelleri öne çıkmaktadır. Bu modeller, daha iyi sonuçlar elde etmek için derin sinir ağlarını ve daha fazla eğitim verisini kullanmaktadırlar. Hem VGGM modeli hem de CDAE ve DnCNN modelleri, 1900 adet görüntü ile eğitilmiştir. FastDVDNet ve ViDeNN geliştirilen modelden iki kat daha fazla eğitim verisi kullanmaktadır. SCUNet modeli en fazla eğitim verisini kullanmaktadır. VGGM, DnCNN ve CDAE mimarilerinden daha fazla katmana sahiptir. Elde edilen sonuçlara göre ağ mimarisi ve eğitim veri boyutunun başarılı sonuç giderme açısından kritik öneme sahip olduğu görülmektedir.

5.2.6. Modelin farklı veri kümeleri ile eğitim sonuçları

Eğitim veri kümesini değiştirdiğimizde elde edeceğimiz başarıyı ölçmek için SCUNet modelinin eğitimi için kullanılan Waterloo, DIV2K ve Flickr2K eğitim veri kümeleri kullanılmıştır. Yapılan çalışmada modelin eğitim süresini etkileyen faktörler incelenerek modelin başarısı ölçülmüştür. Modelin eğitim süresini belirleyen önemli faktörler incelendiğinde modelin eğitim kümesi, modelin mimarisi, kullanılan donanım, modelin derinliği ve tekrar sayısının modelin eğitim süresini etkilediği görülmüştür. Modelin katman sayısı ve her katmandaki nöron sayısı gibi özellikler modelin karmaşıklığını belirlemekte olup, daha karmaşık modellerin eğitim süreleri daha uzun olmaktadır. 20 dB gürültü eklenerek görüntüler üzerinde gürültü giderimi yapıldığında, modelin eğitim süresi ve modelin başarısı Çizelge 5.9'da sunulmuştur.

Çizelge 5.9. Seçilen parametrelere göre modelin eğitim süresi ve başarı oranları

Test Adımı	Aktivasyon Fonksiyonu	Tekrar Sayısı	Eğitim Verisi Sayısı	Eğitim Süresi (dakika)	PSNR	SSIM
1	ReLU	50	1900	88	29,01	0,91
2	Mish	50	1900	100	30,52	0,93
3	ReLU	40	1900	76	28,12	0,86
4	Mish	40	1900	82	29,04	0,91
5	ReLU	20	1900	39	28,01	0,85
6	Mish	20	1900	45	28,97	0,90
7	ReLU	20	2850	50	28,01	0,86
8	Mish	20	2850	55	29,08	0,91
9	ReLU	50	2850	102	30,51	0,93
10	Mish	50	2850	121	31,47	0,93
11	ReLU	60	2850	122	28,13	0,86
12	Mish	60	2850	143	29,10	0,91
13	ReLU	50	8394	Bellek yetersiz gelmiştir.		
14	Mish	50	8394	Bellek yetersiz gelmiştir.		
15	ReLU	20	8394	Bellek yetersiz gelmiştir.		
16	Mish	20	8394	Bellek yetersiz gelmiştir.		

180x180 boyutunda 8.394 tane resim ile Google Colab ortamında yapılan eğitim sürecinde, ortamın sağladığı 12,7 GB bellek yetersiz kalmış, program yarıda kalarak, eğitim aşaması tamamlanamamıştır. Derin öğrenme modelinin eğitim süresini etkileyen faktörler dikkate alındığında modele olan etkisi aşağıdaki başlıklarda incelenmiştir.

1. Veri Kümesi Büyüklüğü: Daha büyük veri kümeleri, modelin daha iyi genelleme yapmasına imkân sağlamakta, ancak modelin eğitim süresi de veri sayısına göre artış göstermektedir. Testlerin 2. ve 10. adımı incelendiğinde, VGGM 1900 tane eğitim verisi ile 100 dakikada eğitilebilirken, eğitim verisi sayısını %50 artırdığımızda eğitim süresinin %21 artış göstererek 121 dakikaya çıktığı gözlemlenmiştir. Modelin başarısı 20 dB gürültü eklenen görüntüde PSNR değeri olarak 30,52 dB iken, farklı veri kümesi kullanılarak eğitim verisi sayısını %50 artırdığımızda başarı oranı %3,1 artarak 31,47 dB'e yükselmiştir.

2. Modeldeki Tekrar Sayısı: Modelde kullanılan tekrar sayısı değeri değiştirilerek eğitim süresi ve modelin başarısı test edilmiştir. Yapılan testlerde modeldeki tekrar sayısı arttıkça

modelin başarısı artmakta, belirli bir değere ulaştıktan sonra modelde aşırı öğrenme arttığı için modelin başarısı da düşmektedir. Test sürecindeki 10 ve 12. adımlarda modelin tekrar sayısı arttığı halde başarı oranının düştüğü görülmektedir.


3. Donanım: Bellek ve GPU modelin eğitiminde belirleyici iki önemli unsurdur. Modelin daha fazla eğitim verisi ile eğitilebilmesi, daha derin model mimarisinin oluşturulabilmesi için bu kaynakların yeterli miktarlarda olması gerekmektedir. Kullanılan GPU özelliklerine bağlı olarak, derin öğrenme modelinin eğitim süresi önemli ölçüde azalmaktadır.

4. Aktivasyon Fonksiyonu: Kullanılan aktivasyon fonksiyonun eğitim süresini etkilediği ve modelin başarısında önemli bir faktör olduğu görülmektedir. Test aşamasının 9. ve 10. adımlarında farklı aktivasyon fonksiyonları kullanılmıştır. Mish fonksiyonu daha fazla derin öğrenme düğümünü aktive ederek hesaplamaya katmaktadır. Daha fazla düğümün aktive olması, işlem sayısını artırarak eğitim süresini uzatmakta, ancak aktif edilen düğüm sayısı arttığı için daha başarılı sonuçlar elde edilmektedir.

5.2.7. Farklı gürültü türlerinde modelin performansı

VGGM yönteminin, farklı gürültü türlerine sahip görüntülerde gürültü giderme işlemindeki başarısının ölçülmesi için, DAVIS veri kümesine gauss, poisson, tuz, karabiber ve benek gürültüsü eklenmiş sonrasında elde edilen değerler ve görüntüler kıyaslanmıştır. Farklı gürültü türlerinde yapılan çalışma hakkında aşağıdaki bölümde bilgi verilmektedir.

a. Gauss gürültüsü: VGGM, gauss gürültüsü ile eğitilerek gürültü giderme işlemi yapılmıştır. VGGM'nin eğitimi aşamasında elde edilen kayıp değerleri Şekil 5.25'de sunulmuştur.



Şekil 5.25. Gauss gürültüsü ile eğitilen modelde kayıp değerleri

Modelin eğitimi sırasında eğitim ve doğrulama verilerinin kayıp değerleri birbirlerine paralel olarak azalmaktadır. 180x180 boyutundaki DAVIS veri kümesine 30 dB gauss gürültüsü eklenerek VGGM ile gürültü giderme sonucu elde edilen görüntüler Resim 5.13’de sunulmuştur.

Orijinal Görüntü



Gürültülü Görüntü



Gürültü Giderilmiş Görüntü





Resim 5.13. Gauss gürültüsünde gürültü giderme işlemi

Yol üzerindeki çizgiler incelendiğinde kenar ve dokuların korunamadığı görülmektedir. Görüntünün tamamına bakıldığında otobüsün üstü ve yol gibi düz zeminlerde gürültü giderilmesinin başarılı olduğu görülmektedir. Gürültünün orijinal görüntü renklerine benzer değerlere sahip olduğu ağaç gibi alanlarda gürültünün orijinal görüntüden ayırt edilemediği ve gürültünün tamamen giderilemediği görülmektedir.

Yapılan ölçümlerde 30 dB Gauss gürültüsüne sahip görüntülerde modelin elde ettiği sonuçlar Çizelge 5.10’da sunulmuştur.


Çizelge 5.10. 30 dB Gauss gürültüsüne sahip görüntülerde gürültü giderme

PSNR (dB)	SSIM	FSIM	RMSE
25,45	0,91	0,96	0,00001668

Elde edilen sonuçlar ve görseller incelendiğinde modelin bu gürültü seviyesinde başarılı sonuçlar elde ettiği görülmektedir. VGGM, Gauss gürültüsü ile eğitildiği için bu gürültü

türünde PSNR, SSIM, FSIM ve RMSE değerleri diğer gürültü türlerine göre daha başarılı olmaktadır.

b. Poisson gürültüsü: Yapılan çalışmada lambda değeri 100 olarak belirlenerek DAVIS veri kümesine gürültü eklenmiştir. Eklenen gürültü maksimum piksel değeri olan 255 değeri ile λ değerinin oranlanması sonucu elde edilen değerler dizisidir. VGGM'nin eğitimi aşamasında elde edilen kayıp değerleri Şekil 5.26'da gösterilmektedir.



Şekil 5.26. Poisson gürültüsü ile eğitilen modelde kayıp değerleri

Elde edilen grafikte test ve eğitim kayıplarının aynı paralellikte olmadığı görülmektedir. DAVIS veri kümesine $\lambda = 100$ değerinde poisson gürültüsü eklenerek gürültü giderme sonrası elde edilen görüntü Resim 5.14'de gösterilmektedir.





Resim 5.14. Poisson gürültüsünde gürültü giderme işlemi


Gürültü giderme aşamasında çok parlak alanlarda beyaz renklerin kaldığı görülmektedir. Daha az ışığa maruz kalmış alanlarda model başarılı sonuçlar elde etmektedir. Görüntünün geneli incelendiğinde modelin poisson gürültüsüne sahip görüntülerde gauss gürültüsü eklenmiş görüntüye göre daha az başarılı sonuçlar elde ettiği görülmektedir. Modelin poisson gürültüsüne sahip görüntülerin bazı alanlarında doku bozulmalarına neden olduğu görülmektedir. Gürültü giderme sonucu elde edilen sonuçlar Çizelge 5.11’de gösterilmektedir.

Çizelge 5.11. $\lambda = 100$ değerinde gürültü giderme sonucu elde edilen sonuçlar

PSNR (dB)	SSIM	FSIM	RMSE
22,60	0,88	0,95	0,00001844

Elde edilen sonuçlara göre model gauss ve benek gürültüsüne göre daha düşük başarı elde etmiştir. Gürültü dağılımının diğer gürültü türlerine göre farklı olması dokulardaki kayıpları artırdığı sonuçlardan da görülmektedir.

c. Tuz gürültüsü: Yapılan çalışmada görüntüye ait piksel değerleri $[0, 1]$ aralığında normalize edilmiştir. DAVIS veri kümesi kullanılarak görüntü üzerindeki piksellerin %10'unun değiştirilmiş olup, bu piksellerin değeri maksimum değer olan 1 olarak atanmıştır. Model bu gürültüye sahip eğitim verilerine göre eğitilmiştir. VGGM'nin eğitimi aşamasında elde edilen kayıp değerleri Şekil 5.27'de gösterilmektedir.



Şekil 5.27. Tuz gürültüsü ile eğitilen modelde kayıp değerleri

180x180 boyutundaki DAVIS veri kümesinde piksellerin %10'una tuz gürültüsü eklenmesi sonrası gürültü giderme işlemi yapılarak elde edilen görüntüler Resim 5.15'de gösterilmektedir.



Resim 5.15. Tuz gürültüsü gürültünde gürültü giderme işlemi


Gürültü giderme sonrasında çok parlak alanlarda ışık kalıntıları olduğu görülmektedir. Daha az ışığa maruz kalmış alanlarda model başarılı sonuçlar elde etmektedir. Görüntünün tamamı dikkate alındığında modelin tuz gürültüsüne sahip görüntülerde de kullanılabileceği görülmektedir. 180x180 boyutundaki DAVIS veri kümesindeki piksellerin %10'una tuz gürültüsü eklenerek gürültü eklenerek VGGM ile gürültü giderme sonucu elde edilen sonuçlar Çizelge 5.12'de gösterilmektedir. Elde edilen sonuçlara göre model tuz

gürültüsünde, poisson gürültüsüne göre daha başarılı sonuçlar elde etmiş ancak gauss gürültüsüne göre elde edilen değerler daha küçük kalmıştır.

Çizelge 5.12. %10 tuz gürültüsüne sahip görüntülerde gürültü giderme sonuçları

PSNR (dB)	SSIM	FSIM	RMSE
23,67	0,77	0,95	0,00001601

d. Karabiber gürültüsü: Görüntülere karabiber gürültüsü eklenerek, görüntü üzerindeki piksellerin %10'u değiştirilmiş, bu piksellerin değeri en düşük piksel değeri olan 0 olarak atanmıştır. Model bu gürültüye sahip eğitim verilerine göre eğitilmiştir. VGGM'nin eğitimi aşamasında elde edilen kayıp değerleri Şekil 5.28'de sunulmuştur.



Şekil 5.28. Karabiber gürültüsü ile eğitilen modelde kayıp değerleri

180x180 boyutundaki Davis veri kümesi kullanılarak piksellerin %10'una karabiber gürültüsü eklenmiş görüntülerde gürültü giderme sonrası elde edilen görüntü Resim 5.16'da sunulmuştur.



Resim 5.16. Karabiber gürültüsünde gürültü giderme işlemi


Gürültü giderme aşamasında karabiber gürültüsünün yoğun olduğu alanlarda gürültü kalıntıları olduğu görülmektedir. Daha az gürültüye maruz kalmış alanlarda model başarılı sonuçlar elde etmektedir. Modelin karabiber gürültüsüne sahip görüntülerde daha az başarı elde ettiği görülmektedir. 180x180 boyutundaki DAVIS veri kümesindeki piksellerin %10'una karabiber gürültüsü eklenerek VGGM ile gürültü giderme sonucu elde edilen sonuçlar Çizelge 5.13'de gösterilmiştir.

Çizelge 5.13. %10 karabiber gürültüsüne sahip görüntülerde gürültü giderme

PSNR (dB)	SSIM	FSIM	RMSE
23,83	0,76	0,95	0,00001571

Düşük gürültü seviyelerinde model başarılı sonuçlar elde etmesine rağmen, gürültünün yoğun olduğu otobüsün üstü ve yol kısımlarında model bozulan görüntüyü düzeltmede zorlanmaktadır. Elde edilen sonuçlara göre gauss ve benek gürültüsü giderme sonuçlarına göre daha düşük değerlerin elde edildiği görülmektedir.

e. Benek gürültüsü: Yapılan çalışmada görüntü üzerindeki piksel değerleri $[0, 1]$ aralığında normalize edilmiştir. Oluşturulan gürültü 0 ortalama, 0,02 varyansa sahip olup, görüntü üzerinde oluşturulan pikseller eklenmiştir. Model bu gürültüye sahip eğitim verilerine göre eğitilmiştir. VGGM'nin eğitimi aşamasında elde edilen kayıp değerleri Şekil 5.29'da sunulmuştur.



Şekil 5.29. Benek gürültüsü ile eğitilen modelde kayıp değerleri

Test ve eğitim aşamasında kayıp değerinin benzer sonuçlar vermesi, modelin farklı veri kümeleri ile de uyumlu çalışabileceğini göstermektedir. Benek gürültüsünü gidermek için VGGM kullanılmış olup, 180x180 boyutundaki DAVIS veri kümesindeki piksellere 0 ortalama, 0,02 varyansa sahip Benek gürültüsü eklenerek görüntülerde gürültü giderme sonucu elde edilen sonuçlar Çizelge 5.14’de gösterilmektedir.

Çizelge 5.14. 0 ortalama, 0,02 varyansa sahip benek gürültüsü giderme sonuçları

PSNR (dB)	SSIM	FSIM	RMSE
24,97	0,94	0,99	0,00000822

Benek gürültüsü bir görüntü üzerinde rastgele veya düzensiz dağılmış parlak veya koyu lekelerin oluşturduğu gürültüyü ifade etmektedir. Benek gürültüsü gauss gürültüsüne benzer bir dağılıma sahip olduğu için elde edilen sonuçlar gauss gürültü giderimi sonrası elde edilen değerlerle benzerlik göstermektedir. Görüntüler incelendiğinde gürültü giderme işleminin başarılı bir şekilde yapıldığı görülmüştür. 180x180 boyutundaki Davis veri kümesi kullanılarak piksellere 0 ortalama, 0,02 varyansa sahip benek gürültüsü eklenip, gürültü giderme işlemi sonrası elde edilen görüntüler Resim 5.17’de sunulmuştur.

Gürültülü Görüntü



Gürültü Giderilmiş Görüntü



Orijinal Görüntü





Resim 5.17. Benek gürültüsünde gürültü giderme işlemi

Benek gürültüsü, genellikle bir görüntüdeki piksellerde ortaya çıkan değişiklikler veya sapmalar olarak tanımlanmaktadır. Bu gürültü, sensör hataları, iletim sırasında oluşan bozulmalar, düşük ışık koşulları veya diğer çeşitli faktörlerden kaynaklanabilmektedir. Oluşturulan görüntülerde benek gürültüsü, görüntüdeki piksellerin parlak veya koyu noktalara dönüşmesiyle meydana gelmektedir. Gürültü giderme aşamasında benek gürültüsü görüntünün tamamına yayılmadığı için başarılı sonuçlar elde ettiği görülmektedir. VGGM benek gürültüsüne sahip görüntülerde kullanıldığında başarılı sonuçlar elde etmektedir.



6. SONUÇ VE ÖNERİLER

Bu çalışmada video görüntülerinden gürültüyü kaldırmak için CNN ve GAN derin öğrenme mimarileri kullanılarak hibrit bir model önerilmiştir. Bu yöntemlerin farklı gürültü seviyelerindeki davranışları incelenmiş ve farklı veri kümeleriyle yapılan deneylerin sonuçları karşılaştırılmıştır. Farklı veri kümeleri kullanılarak video görüntülerindeki gürültüyü azaltmak için derin öğrenme yöntemlerini kullanan hibrit bir model geliştirilmiştir. CNN ağı içerisinde U-Net mimarisini içeren derin öğrenme modeli kullanılmış ve çıktıları GAN modeline aktararak gürültü giderme işlemi yapılmıştır. Bu yaklaşım aşırı öğrenme riskini azaltmış ve gürültü giderme performansını artırmıştır.

Bu çalışma sırasında kullanılan hiper parametrelerin, geliştirilen derin öğrenme modelinin performansı üzerindeki etkileri ayrıntılı olarak incelenmiştir. Bu analiz, modelin eğitiminin nasıl optimize edileceği ve gürültülü videolardan gürültü daha iyi bir şekilde nasıl giderilebileceği konusunda yol göstermiştir. Modelin derinliği üzerinde yapılan testler sonucunda belirlenen en uygun derinlik seviyesi, modelin karmaşık gürültü desenleri üzerinde daha etkili olmuştur. Öğrenme hızının etkisi incelenmiş, öğrenme hızı seçimi modelin ne kadar hızlı veya yavaş öğrendiğini değerlendirmek için kullanılmıştır.

Yüksek gürültü seviyelerinde PSNR değerlerinin düştüğü, görüntülerde gürültü kalıntılarının yer aldığı görülmektedir. VGGM yönteminde, yüksek gürültü seviyelerinde aşırı öğrenme sorunu ortaya çıkmakta, bu seviyelerdeki gürültülerde daha karmaşık ve hesaplama yoğun yöntemler geliştirmek için modelin mimarisini gözden geçirmek gerekmektedir.

CNN mimarisini kullanan FastDVDNet yönteminin diğer yöntemlere göre başarılı sonuçlar elde ettiği görülmektedir. VGGM, 0 – 30 dB arası gürültü seviyelerinde FastDVDNet yönteminden sonra diğer gürültü giderme yöntemlerine göre iyi sonuçlar (+0.15 dB ve +0.35 dB) elde etmektedir. Ancak VGGM'nin gürültü giderme süresi, gerçek zamanlı gürültü giderme işlemi için gerekli işlem süresini aşmakta ve gürültü seviyesi arttıkça etkinliği düşmektedir.

Derin öğrenmeye dayalı çalışmalarda farklı gürültü türleri ve farklı görüntü çözünürlüklerinde belirli bir derin öğrenme modelinin başarı elde edemediği gözlenmiştir. Farklı gürültü seviyeleri ve farklı çözünürlükteki görüntüler için farklı derin öğrenme yöntemlerinin daha başarılı olduğu görülmüştür. Video üzerindeki gürültüler incelendiğinde gürültülerin özelliklerinin birbirlerinden oldukça farklı olduğu ve tek gürültü giderme modelinin tüm gürültü türlerinde, gürültüleri gidermede yetersiz kaldığı görülmüştür.

Gürültü giderme alanında derin öğrenme yöntemleri son dönemde başarılı sonuçlar elde etse de, Fourier dönüşümü, dalgacık dönüşümü gibi görüntü bilgilerinin frekans bilgisine çevrilerek görüntünün farklı frekans bileşenleri analiz edilerek yapılan filtrelemeler daha hızlı hesaplama süreleri nedeniyle halen kullanılmaya devam edilmektedir. Görüntü işleme alanına giren bu filtreleme tekniklerinin derin öğrenme yöntemleri ile birlikte kullanılması hesaplama sürelerini kısaltarak gürültü giderme aşamasında daha başarılı sonuçlar elde edilmesini sağlayacaktır.

Yapılan deneysel çalışmalarda, derin öğrenme modellerinin eğitim süresince daha fazla bellek ve GPU'ya ihtiyaç duyduğunu göstermiştir. Modeli birden fazla GPU'ya veya CPU'ya dağıtarak farklı kısımların aynı anda çalışmasını sağlamak modelin performansını artırmıştır. Öte yandan, daha büyük modellerin davranışını taklit edecek daha küçük modelleri eğitmek, gerçek modelin performansını korurken daha az kaynak ile eğitim sürecindeki deneme zamanını kısaltacaktır. Ayrıca gelecekteki çalışmalarda, gerçek ve gürültülü görüntü çiftlerinin eksikliği, sistem kaynaklarının kısıtlı olması, eğitim süresi ve orijinal görüntüye yakınlığın korunması gibi kısıtlar dikkate alınarak farklı gürültü seviyelerinde görüntülerdeki gürültüyü azaltma yöntemlerinin araştırılmasını gerektirmektedir. Yapılacak çalışmalarda, sistem kaynaklarını optimize ederken eşleştirilmiş verilere olan ihtiyacı en aza indirip, etkili bir şekilde gürültüyü azaltabilecek yöntemlerin geliştirilmesine yönelik çalışmalar yapılması derin öğrenme yöntemlerinin daha başarılı sonuçlar elde etmesine olanak sağlayacaktır.

Daha düşük gürültü seviyesinde başarı elde edebilmek için VGGM modeli 5-55 dB gürültü aralığında eğitilmiştir. Ancak modelin farklı gürültü seviyelerinde daha başarılı sonuçlar elde etmesi için, hareket tahmin algoritmaları kullanılarak, görüntüde yer alan nesnelerin

geçmiş ve gelecekteki konumlarını tahmin edilip, görüntü bloklarının oluşturulması, modelin daha başarılı sonuçlar elde etmesine olanak sağlayacaktır.

Model farklı veri kümeleriyle eğitildiğinde, modelin genelleme yeteneğinin artarak daha iyi sonuçlar elde ettiği görülmektedir. Modelin farklı veri kümeleri ile eğitilebilmesi için donanım kaynağının artırılması gerekmektedir. Donanım kaynağının artırılması, tek bir model üzerine mimarinin kurulabilmesine de olanak sağlayacaktır. Bu sayede model daha büyük veri kümelerini hızlı bir şekilde işleyebilecektir.

Transfer öğrenme yöntemi gürültü giderme modelinde kullanılarak, modelin bir görevde öğrendiği temel özellikler başka benzer bir görevde kullanarak daha iyi performans elde etmesi sağlanacaktır. Gürültü giderme modelini, önceden eğitilmiş bir modelle başlatarak veya önceden eğitilmiş modelin bir kısmı kullanılarak farklı görüntülerde daha başarılı bir model elde edilebileceği düşünülmektedir.

KAYNAKLAR

1. Chen, H., He, B., Wang, H., Ren, Y., Lim, S. N., Shrivastava, A. (2021). Nerv: Neural representations for videos. *Advances in Neural Information Processing Systems*, 34, 21557-21568.
2. Zhang, K., Ren, W., Luo, W., Lai, W. S., Stenger, B., Yang, M. H., Li, H. (2022). Deep image deblurring: A survey. *International Journal of Computer Vision*, 130(9), 2103-2130.
3. Goyal, B., Dogra, A., Agrawal, S., Sohi, B. S., Sharma, A. (2020). Image denoising review: From classical to state-of-the-art approaches. *Information fusion*, 55, 220-244.
4. Girshick, R., Donahue, J., Darrell, T., Malik, J. (2016). Region-based convolutional networks for accurate object detection and segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 38(1): 142-158.
5. Sagheer, S. V. M., George, S. N. (2020). A review on medical image denoising algorithms. *Biomedical signal processing and control*, 61, 102036.
6. Lu, G., Zhang, X., Ouyang, W., Xu, D., Chen, L., Gao, Z. (2019). Deep non-local kalman network for video compression artifact reduction. *IEEE Transactions on Image Processing*, 29, 1725-1737.
7. Buades, T., Lou, Y., Morel, J. M., Tang, Z. (2009). A note on multi-image denoising. *International workshop on local and non-local approximation in image processing*, 1-15.
8. Pramanik, A., Sarkar, S., Maiti, J. (2021). A real-time video surveillance system for traffic pre-events detection. *Accident Analysis and Prevention*, 154, 106019.
9. Franklin, R. J., Dabbagol, V. (2020). Anomaly detection in videos for video surveillance applications using neural networks. *Fourth International Conference on Inventive Systems and Control (ICISC)*, 632-637.
10. Tian, C., Fei, L., Zheng, W., Xu, Y., Zuo, W., Lin, C. W. (2020). Deep learning on image denoising: An overview. *Neural Networks*, 131, 251-275.
11. Gu, S., Timofte, R. (2019). A brief review of image denoising algorithms and beyond. *Inpainting and Denoising Challenges*, 1-21.
12. Limshuebchuey, A., Duangsoithong, R., Saejia, M. (2020). Comparison of image denoising using traditional filter and deep learning methods. *17th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*, 193-196.
13. Liu, B., Liu, J. (2019). Overview of image denoising based on deep learning. *In Journal of physics: conference series*, 1176, 022010.

14. Izadi, S., Sutton, D., Hamarneh, G. (2023). Image denoising in the deep learning era. *Artificial Intelligence Review*, 56(7), 5929-5974.
15. Rota, C., Buzzelli, M., Bianco, S., Schettini, R. (2023). Video restoration based on deep learning: a comprehensive survey. *Artificial Intelligence Review*, 56(6), 5317-5364.
16. Bi, Z. (2022). Comprehensive Survey on Video Denoise Methods.
17. Elad, M., Kwar, B., Vaksman, G. (2023). Image denoising: The deep learning revolution and beyond-a survey paper. *SIAM Journal on Imaging Sciences*, 16(3), 1594-1654.
18. Charmouti, B., Junoh, A. K., Mashor, M. Y., Ghazali, N., Ab Wahab, M., Muhamad, W. Z. A. W., Beroual, A. (2019). An overview of the fundamental approaches that yield several image denoising techniques. *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, 17(6), 2959-2967.
19. Su, J., Xu, B., Yin, H. (2022). A survey of deep learning approaches to image restoration. *Neurocomputing*, 487, 46-65.
20. Wu, W., Chen, M., Xiang, Y., Zhang, Y., Yang, Y. (2023). Recent progress in image denoising: A training strategy perspective. *IET Image Processing*.
21. Kaur, A., Dong, G. (2023). A Complete Review on Image Denoising Techniques for Medical Images. *Neural Processing Letters*, 1-44.
22. Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Farhan, L. (2021). Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8, 1-74.
23. Saxena, C., Kourav, D. (2014). Noises and image denoising techniques: a brief survey. *International journal of Emerging Technology and advanced Engineering*, 4(3), 878-885.
24. Kong, Z., Deng, F., Zhuang, H., Yang, X., Yu, J., He, L. (2023). A Comparison of Image Denoising Methods. *arXiv preprint*, arXiv:2304.08990.
25. Abiri, N., Linse, B., Edén, P., Ohlsson, M. (2019). Establishing strong imputation performance of a denoising autoencoder in a wide range of missing data problems. *Elsevier*, 137-146.
26. Zhou, C., Paenroth, R. (2017). Anomaly Detection with Robust Deep Autoencoders. *ACM KDD*, 665-674.
27. Wen, B., Ravishankar, S., Bresler, Y. (2017). VIDOSAT: High-dimensional Sparsifying Transform Learning for Online Video Denoising. *IEEE Transactions on Image Processing*, 28(4), 1691-1704.

28. Chang, Y. (2019). Research on demotion blur image processing based on deep learning, *J. Vis. Commun. Image R. Elsevier*, 60, 371–379.
29. Erol A., Gürbüz M., Gangal, A. (2016). Video Görüntülerindeki Periyodik Gürültülerin Yok Edilmesi. *Researchgate*, 535-537.
30. Gondara, L. (2016). Medical image denoising using convolutional denoising autoencoders. *IEEE 16th International Conference on Data Mining Workshops*, 241-246.
31. Kokil, P., Pratap, T. (2021). Additive white gaussian noise level estimation for natural images using linear scale-space features. *Circuits, Systems, and Signal Processing*, 40(1), 353-374.
32. Islam, M. T., Rahman, S. M., Ahmad, M. O., Swamy, M. N. S. (2018). Mixed Gaussian-impulse noise reduction from images using convolutional neural network. *Signal Processing: Image Communication*, 68, 26-41.
33. Khmag, A., Al Haddad, S. A. R., Ramlee, R. A., Kamarudin, N., Malallah, F. L. (2018). Natural image noise removal using nonlocal means and hidden Markov models in transform domain. *The Visual Computer*, 34, 1661-1675.
34. Das, A. K. (2014). Review of image denoising techniques. *International Journal of Emerging Technology and Advanced Engineering*, 4(8), 519-522.
35. Jain, P., Tyagi, V. (2016). A survey of edge-preserving image denoising methods. *Information Systems Frontiers*, 18, 159-170.
36. Shrestha, S. (2014). Image denoising using new adaptive based median filters. *arXiv preprint*, arXiv:1410.2175.
37. Thakur, R. S., Chatterjee, S., Yadav, R. N., Gupta, L. (2021). Image de-noising with machine learning: A review. *IEEE Access*, 9, 93338-93363.
38. Chen, C., Chen, Q., Xu, J., Koltun, V. (2018). Learning to see in the dark. *IEEE conference on computer vision and pattern recognition*, 3291-3300.
39. Rao, Y., Chen, L. (2012). A Survey of Video Enhancement Techniques. *J. Inf. Hiding Multimed. Signal Process.*, 3(1), 71-99.
40. Weizheng, X., Chenqi, X., Zhengru, J., Yueping, H. (2020). Digital Image Denoising Method Based on Mean Filter. *International Conference on Computer Engineering and Application (ICCEA)*, 857-859.
41. Tania, S., Rowaida, R. (2016). A Comparative Study of Various Image Filtering Techniques for Removing Various Noisy Pixels in Aerial Image. *International Journal of Signal Processing, Image Processing and Pattern Recognition*, 9(3), 113-124.

42. Pratt, W. K. (1972). Generalized Wiener Filtering Computation Techniques. *IEEE Transactions on Computers*, C-21(7), 636-641.
43. Lee, Y., Kassam, S. (1985). Generalized median filtering and related nonlinear filtering techniques. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 33(3), 672-683.
44. Yin, L., Yang, R., Gabbouj, M., Neuvo, Y. (1996). Weighted median filters: a tutorial. *IEEE Transactions on Circuits and Systems II Analog and Digital Signal Processing*, 43(3), 157-192.
45. Tomasi, C., Manduchi R. (1998). Bilateral filtering for gray and color images. *Sixth international conference on computer vision IEEE*, 839-846.
46. Estrela, V. V., Magalhães, H. A., Saotome, O. (2016). Total Variation Applications in Computer Vision. *arXiv*, arXiv:1603.09599.
47. Rudin, L., Osher, S., Fatemi, E. (1992). Nonlinear Total Variation based Noise Removal Algorithms. *Physica D*, vol 60, 259-268.
48. Esedoglu, S., Osher, S. (2004). Decomposition of Images by the Anisotropic Rudin-Osher-Fatemi Model. *Communications on Pure and Applied Mathematics*, 57, 1609-1626.
49. Chan, T. F., Esedoglu, S., Park, F., Yip, A. (2004). Recent developments in total variation image restoration. *Mathematical Models of Computer Vision*, CAM Report 05-01, Department of Mathematics, UCLA.
50. Buades, A., Coll, B., Morel, J. M. (2005). A non-local algorithm for image denoising. *IEEE computer society conference on computer vision and pattern recognition*, 2(2), 60-65.
51. Ehret, T., Arias, P. (2020). Implementation of the VBM3D Video Denoising Method and Some Variants. *Image Processing On Line*, 374-395.
52. İnternet: Mäkinen, Y., Azzari, L., Monge, E., Maggioni, M., Danielyan, A., Dabov, K., Foi, A., Katkovnik, V., Egiazarian, K. (2019). Image and video denoising by sparse 3D transform-domain collaborative filtering. URL: <https://www.cs.tut.fi/~foi/3D-DFT> Son Erişim Tarihi: 21.02.2023.
53. Dabov, K., Foi, A., Katkovnik, V., Egiazarian, K. (2009). BM3D image denoising with shape-adaptive principal component analysis. *SPARS'09- Signal Processing with Adaptive Sparse Structured Representations*, Inria Rennes.
54. Fan, L., Zhang, F., Fan, H. (2019). Brief review of image denoising techniques. *Visual Computing for Industry, Biomedicine, and Art*, 2(7).
55. Dabov, K., Foi, A., Katkovnik, V., Egiazarian K. (2007). Image Denoising by Sparse 3-D Transform-Domain Collaborative Filtering. *IEEE Transactions on Image Processing*, 16(8), 2080-2095.

56. Maggioni, M., Boracchi, G., Foi, A., Egiazarian, K. (2012). Video denoising, deblocking, and enhancement through separable 4-D nonlocal spatiotemporal transforms. *IEEE Transactions on Image Processing*, 21(9), 3952–3966.
57. Arias, P., Morel, J. M. (2018). Video Denoising via Empirical Bayesian Estimation of Space-Time Patches. *J Math Imaging Vis*, 60, 70–93.
58. Khawase, S., Kamble, S., Thakur, N., Patharkar, A. (2017). An Overview of Block Matching Algorithms for Motion Vector Estimation. *Intelligent and Computing in Engineering*, 217–222.
59. Delon, J., Houdard, A. (2018). Gaussian Priors for Image denoising, Denoising of Photographic Images and Video Fundamentals. *Open Challenges and New Trends. Denoising of Photographic Images and Video*, 125-149
60. Russel, S., Norvig, P. (2010). *Artificial Intelligence A Modern Approach*, Third Edition, Pearson Education, 804-807
61. Wright, J., Yang, A. Y., Ganesh, A., Sastry, S. S., Ma, Y. (2009). Robust face recognition via sparse representation. *IEEE Transactions on Pattern analysis and Machine Intelligence*, 31(2), 210-227.
62. Deng, W., Hu, J., Guo, J. (2012). Extended SRC: Undersampled face recognition via intraclass variant dictionary. *IEEE Trans. Pattern Anal. Mach. Intell*, 34(9), 1864-1870.
63. Zhang, L., Zhou, W. (2009). On the sparseness of 1-norm support vector machines. *Neural Networks*, 23(3), 373-385.
64. Gao, S., Tsang, I.W.H., Chia, L. T. (2010). Kernel sparse representation for image classification and face recognition, *11th Eur. Conf. Comput. Vis.*, 6314, 1-14.
65. Xu, S., Yang, X., Jiang, S. (2017). A fast nonlocally centralized sparse representation algorithm for image denoising. *Signal Processing*, 99-112.
66. Ji, H., Liu, C. Q., Shen, ZW., Xu, Y. H. (2010). Robust video denoising using low rank matrix completion. *IEEE computer vision and pattern recognition*, 1791–1798.
67. Gu, S. H., Xie, Q, Meng, D. Y, Zuo, W. M, Feng, X. C., Zhang, L. (2017). Weighted nuclear norm minimization and its applications to low level vision. *Int J Comput Vis*, 121(2), 183–208.
68. Ji, H., Huang, S. B., Shen, Z. W., Xu, Y. H. (2011). Robust video restoration by joint sparse and low rank matrix approximation. *SIAM J Imaging Sci*, 4(4), 1122–1142.
69. Aharon, M., Elad, M., Bruckstein, A. (2006). K-SVD: An Algorithm for Designing Overcomplete Dictionaries for Sparse Representation. *IEEE Transactions on Signal Processing*, 54(11), 4311-4322.

70. Gu, S., Zhang, L., Zuo, W. Feng, X. (2014). Weighted nuclear norm minimization with application to image denoising. *IEEE conference on computer vision and pattern recognition*, 2862–2869.
71. Mallat, S. (1998). *A Wavelet Tour of Signal Processing*. Academic Press, Elsevier, 5-37
72. Bhuiyan, M., Ahmad, M., Swamy, M. (2008). Wavelet-based image denoising with the normal inverse Gaussian prior and linear MMSE estimator. *Iet Image Processing*, 203-217.
73. Hyvarinen, A., Oja, E., Hoyer, P., Hurri, J. (1998). Image feature extraction by sparse coding and independent component analysis. *IEEE 14th international conference on pattern recognition*, 1268–1273.
74. Nigam, V., Luthra, S., Bhatnagar, S. (2010). A Comparative Study of Thresholding Techniques for Image Denoising. *International Conference on Computer and Communication Technology*, 173-176.
75. Donoho, D. L., Johnstone, I. M. (1995). Adapting to unknown smoothness via wavelet shrinkage. *Journal of the American Statistical Association*, 90(432), 1200-1224.
76. Donoho, D. L. (1995). Denoising by soft-thresholding. *IEEE Trans. Information Theory*, 41(3), 613-627.
77. Biswas, M., Om, H. (2012). A New Soft-Thresholding Image Denoising Method. *2nd International Conference on Communication, Computing and Security*, 6, 10-15.
78. Chang. S. G., Yu, B., Vetterli, M. (2000). Adaptive wavelet thresholding for image denoising and compression. *IEEE Transactions on Image Processing*, 9(9), 1532-1546.
79. Starck, J., Fadili, J., Murtagh, F. (2007). The Undecimated Wavelet Decomposition and its Reconstruction. *IEEE Transactions On Image Processing*, 16(2).
80. Starck, J. L., Elad, M., Donoho, D. L. (2004). Redundant multiscale transforms and their application for morphological component analysis. *Adv. Imag. Electron Physics*, 287-348.
81. Barbero, M., Hofmann, H., Wells, N. (1991). DCT source coding and current implementations for HDTV. *EBU Technical Review*.
82. Lukin, V. V., Fevraleov, D. V., Nikolay, N., Abramov, S. (2010). Astola Discrete cosine transform-based local adaptive filtering of images corrupted by nonstationary noise. *Journal of Electronic Imaging*, 19(2).
83. Kim, J., Lee, J. K., Lee, K. M. (2016). Accurate image super-resolution using very deep convolutional networks. *IEEE conference on computer vision and pattern recognition*, 1646–1654.

84. Wang, X., Chan, K., Yu, K., Dong, C., Loy, C. C. (2019). EDVR: Video restoration with enhanced deformable convolutional networks. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, 1954-1963.
85. Lefkimmiatis, S. (2018). Universal denoising networks: A novel cnn architecture for image denoising, *CVPR*, 3204–3213.
86. Zhang, K., Zuo, W., Chen, Y., Meng, D., Zhang L. (2017). Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising. *IEEE Transactions on Image Processing*, 26(7), 3142-3155.
87. Lehtinen, J., Munkberg, J., Hasselgren, J., Laine, S., Karras, T., Aittala, M., Aila, T. (2018). Noise2Noise: Learning image restoration without clean data. *ICML*, 80, 2965–2974.
88. Batson, J., Royer, L. (2019). Noise2self: Blind denoising by self-supervision, *arXiv*, arXiv:1901.11365.
89. Krull, A., Buchholz, T., Jug, F. (2019). Noise2void - learning denoising from single noisy images, *CVPR*, arXiv:1811.10980.
90. Alimovskia, E., Erdemira, G. (2021). Veri Artırma Tekniklerinin Derin Öğrenmeye Dayalı Yüz Tanıma Sisteminde Etkisi. *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 3(1), 76-80.
91. Fabio, P., Christina, V., Sandra, A., Eduardo, V. (2018). Data augmentation for skin lesion analysis. *ISIC skin image analysis workshop and challenge*, MICCAI.
92. Li, Y., Li, Z., Kejun, K. (2013). A novel image restoration method assisted by reference image in dual-energy CT. *IEEE Nuclear Science Symposium and Medical Imaging Conference*, 1-4.
93. Wu, Y., Zhao, W., Zhang, Q. (2013). The improvement of audio noise reduction system based on LMS algorithm. *International Conference on Computer Sciences and Applications*, 590-594.
94. LeCun, Y., Bengio, Y., Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
95. Ha, V. K., Ren, J., Xu, X., Zhao, S., Xie, G., Vargas, V. M. (2018). Deep Learning Based Single Image Super-Resolution: A Survey. *Advances in Brain Inspired Cognitive Systems BICS Springer*, 10989.
96. Liu, H., Ruan, Z., Zhao, P., Dong, C., Shang, F., Liu, Y., Yang, L. (2020). Video Super Resolution Based on Deep Learning: A Comprehensive Survey. *Computer Vision and Pattern Recognition*, arXiv:2007.12928.
97. Farooque, M. A., Rohankar, J. S. (2013). Survey on various noises and techniques for denoising the color image. *International Journal of Application or Innovation in Engineering and Management (IJAEM)*, 2(11), 217–221.

98. Tian, C., Xu, Y., Fei, L., Yan, K. (2019). Deep Learning for Image Denoising: A Survey. *ICGEC 2018 Advances in Intelligent Systems and Computing*, 834.
99. Jeon, W., Jeong, W., Son, K., Yang, H. (2018). Speckle noise reduction for digital holographic images using multi-scale convolutional neural networks. *Optics Letters*, 43(17), 4240–4243.
100. Liu, S., Deng, W. (2015). Very deep convolutional neural network based image classification using small training sample size. *IAPR Asian Conference on Pattern Recognition (ACPR)*, 730-734.
101. Yu, F., Koltun, V., Funkhouser, T. (2017). Dilated residual networks. *Computer Vision and Pattern Recognition (CVPR)*, arXiv: 1705.09914.
102. Chen, C., Xiong, Z., Tian, X., Wu, F. (2018). Deep boosting for image denoising. *European Conference on Computer Vision (ECCV)*, 3–18.
103. Tai, Y., Yang, J., Liu, X. (2017). MemNet: a persistent memory network for image restoration. *IEEE Int. Conf. on Computer Vision (ICCV 2017)*, 4539– 4547.
104. Liu, P., Zhang, H., Zhang, K., Lin, L., Zuo, W. (2018). Multi-level wavelet-cnn for image restoration. *IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 773–782.
105. Zhao, Y. Q., Yang, J. (2015). Hyperspectral image denoising via sparse representation and low-rank constraint. *IEEE Transactions on Geoscience and Remote Sensing*, 53(1), 296-308.
106. Bui, A. T., Im, J. K., Apley, D. W., Runger, G. C. (2019). Projection-free kernel principal component analysis for denoising. *Elsevier Neurocomputing*, 357, 163-176.
107. Cha, S., Park, T., Kim, B., Baek, J., Moon, T. (2021). GAN2GAN: Generative Noise Learning for Blind Denoising with Single Noisy Images. *International Conference on Learning Representations (ICLR)*.
108. Luo, Z., Chen, S., Qian, Y. (2019). A Deep Optimization Approach for Image Deconvolution. *Computer Vision and Pattern Recognition*, arXiv:1904.07516.
109. Wang, T., Sun, M., Hu, K. (2018). Dilated deep residual network for image denoising. *International Conference on Tools with Artificial Intelligence*, 1272-1279.
110. Chen, Y., Pock, T. (2016). Trainable nonlinear reaction diffusion: A flexible framework for fast and effective image restoration. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1256-1272.
111. Lai, W. S., Huang J. B., Ahuja, N., Yang M. H. (2017). Deep Laplacian Pyramid Networks for Fast and Accurate Super-Resolution. *30th IEEE Conference on Computer Vision and Pattern Recognition*, 5835-5843.

112. Tian, C., Xu, Y., Zuo, W. (2020). Image denoising using deep cnn with batch renormalization. *Neural Networks*, 121, 461–473.
113. Anwar, S., Huynh, C. P., Porikli, F. (2017). Chaining identity mapping modules for image denoising. *arXiv*, arXiv:1712.02933.
114. Karlik, B., Olgac, A. V. (2011). Performance analysis of various activation functions in generalized MLP architectures of neural networks. *International Journal of Artificial Intelligence and Expert Systems*, 1(4), 111–122.
115. Shi, W., Caballero, J., Huszar, F., Totz, J., Aitken, A., Bishop, R., Rueckert, D., Wang, Z. (2016). Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network. *IEEE conference on computer vision and pattern recognition*, 1874–1883.
116. Tian, C., Xu, Y., Fei, L., Wang, J., Wen, J., Luo, N. (2019). Enhanced cnn for image denoising. *CAAI Transactions on Intelligence Technology*, 4(1), 17–23.
117. Tassano, M., Delon, J., Veit, T. (2019). Dvdnet: A fast network for deep video denoising. *IEEE International Conference on Image Processing (ICIP)*, 1805–1809.
118. Paramkusam, A., Reddy, V. S. K. (2014). Two-layer motion estimation algorithm for video coding. *Electronics Letters*, 50, 276–278.
119. Wang, C., Zhou, S. K., Cheng, Z. (2020). First image then video: A two-stage network for spatiotemporal video denoising, *arXiv*, arXiv:2001.00346.
120. Xue, T., Chen, B., Wu, J. (2019). Video Enhancement with Task-Oriented Flow. *Int J Comput Vis*, 127, 1106–1125
121. Claus, M., Van Gemert, J. (2019). Videnn: Deep blind video denoising. *IEEE/CVF conference on computer vision and pattern recognition workshops*.
122. Zhang, K., Li, Y., Liang, J., Cao, J., Zhang, Y., Tang, H., Van Gool, L. (2022). Practical blind denoising via swin-conv-unet and data synthesis. *arXiv preprint*, arXiv:2203.13278.
123. Patilab, S., Naik, G., Pai, R., Gad, R. (2018). Stacked Autoencoder for classification of glioma grade III and grade IV. *Elsevier Biomedical Signal Processing and Control*, 46, 67–75.
124. Yassenko, L., Klyatchenko, Y., Tarasenko-Klyatchenko, O. (2020). Image noise reduction by denoising autoencoder. *IEEE 11th International Conference on Dependable Systems, Services and Technologies*, 351–355.
125. Liu, G., Bao, H., Han, B. (2018). A Stacked Autoencoder-Based Deep Neural Network for Achieving Gearbox Fault Diagnosis, *Mathematical Problems in Engineering*.
126. Kingma, D., Welling, M. (2019). An Introduction to Variational Autoencoders. *Foundations and Trends in Machine Learning*, 12(2019), 307–392.

127. Im D., Im, J., Ahn, S., Memisevic, R., Bengio, Y. (2017). Denoising Criterion for Variational Auto-Encoding Framework. *Thirty-First AAAI Conference on Artificial Intelligence*, 2059-2065.
128. K. Rank, M. Lendl and R. Unbehauen, (1999). Estimation of image noise variance, *IEE Proc. Vis. Image Signal Process.*, 146(2), 80-84.
129. Cornera, B. R., Narayanana. R. M., Reichenbach, S. E., (2003). Noise estimation in remote sensing imagery using data masking. *Int. J. Remote Sens.*, 24(4), 689-702.
130. Shin, D. H., Park, R. H., Yang, S., Jung, J. H. (2005). Block-based noise estimation using adaptive Gaussian filtering. *IEEE Trans. Consumer Electron*, 51, 218-226.
131. Liu, X., Tanaka M., Okutomi, M. (2013). Single-Image Noise Level Estimation for Blind Denoising. *IEEE Transactions on Image Processing*, 22(12), 5226-5237.
132. Creswell, A., Bharath, A. A. (2018). Denoising Adversarial Autoencoders. *arXiv*, arXiv:1703.01220v4.
133. Chena, X., Songa, L., Yanga, X. (2016). Deep RNNs for Video Denoising. *Applications of Digital Image Processing, SPIE*, 9971.
134. Antczak, K. (2018). Deep Recurrent Neural Networks for ECG Signal Denoising, *arXiv*, 9(1), 135.
135. Rajeev, R., Samath, J., Karthikeyan, N. (2019). An Intelligent Recurrent Neural Network with Long Short-Term Memory (LSTM) BASED Batch Normalization for Medical Image Denoising. *Journal of Medical Systems, Springer Science*, 43(8), 234.
136. Cho, K. (2013). Boltzmann Machines for Image Denoising. *Artificial Neural Networks and Machine Learning – ICANN, Springer*, 611-618.
137. Keyvanrad, M., Pezeshki, M., Homayounpour, M. (2013). Deep Belief Networks for Image Denoising, *arXiv*, arXiv:1312.6158.
138. Guo, S., Yan, Z., Zhang, K., Zuo, W., Zhang, L. (2019). Toward convolutional blind denoising of real photographs. *IEEE Conference on Computer Vision and Pattern Recognition*, 1712–1722.
139. Tran, L. D., Nguyen, S. M., Arai, M. (2020). GAN-based noise model for denoising real images. *In Proceedings of the Asian Conference on Computer Vision*.
140. Jähne, B. (2002). Digital Image Processing. Engineering online library, *Springer*, 545-546.
141. Caputo, C. (2014). Digital Video Surveillance and Security. *Digital Video Surveillance and Security*, 25-47.
142. Proakis, J., Salehi, M. (2002). *Communication Systems Engineering* (İkinci Baskı), Prentice-Hall, Upper Saddle River, 217-267.

143. Ramesh, G., Logeshwaran, J., Gowri, J., Mathew, A. (2022). The management and reduction of digital noise in video image processing by using transmission based noise elimination scheme. *ICTACT Journal on Image and Video Processing*, 13(1).
144. Aljanabi, M. A., Hussain, Z. M., Shnain, N. A. A., Lu, S. F. (2019). Design of a hybrid measure for image similarity: a statistical, algebraic, and information-theoretic approach. *European Journal of Remote Sensing*, 2-15.
145. Winkler, S., Mohandas, P. (2008). The evolution of video quality measurement: From PSNR to hybrid metrics. *IEEE transactions on Broadcasting*, 54(3), 660-668.
146. Eskicioglu, A. M., Fisher, P. S. (1995). Image quality measures and their performance. *IEEE Transactions on communications*, 43(12), 2959-2965.
147. Martin, C. J., Sharp, P. F., Sutton, D. G. (1999). Measurement of image quality in diagnostic radiology. *Applied radiation and isotopes*, 50(1), 21-38.
148. Estévez, P. A., Tesmer, M., Perez, C. A., Zurada, J. M. (2009). Normalized mutual information feature selection. *IEEE Transactions on neural networks*, 20(2), 189-201.
149. Isola, P., Zhu, J. Y., Zhou, T., Efros, A. (2017). Image-to-image translation with conditional adversarial networks. *IEEE conference on computer vision and pattern recognition*, 1125-1134.
150. Demir, U., Unal, G. (2018). Patch-based image inpainting with generative adversarial networks. *arXiv preprint*, arXiv:1803.07422.
151. Ozkan, M. K., Sezan, M. I., Tekalp, A. M. (1993). Adaptive motion-compensated filtering of noisy image sequences. *IEEE transactions on circuits and systems for video technology*, 3(4), 277-290.
152. Choi, B. D., Han, J. W., Kim, C., Ko, J. (2007). Motion-Compensated Frame Interpolation Using Bilateral Motion Estimation and Adaptive Overlapped Block Motion Compensation. *IEEE Transactions on Circuits and Systems for Video Technology*, 17(4), 407-416.
153. Karnati, V., Uliyar, M., Dey, S. (2009). Fast Non-Local algorithm for image denoising. *IEEE International Conference on Image Processing (ICIP)*, 3873-3876.
154. Pont-Tuset, J., Perazzi, F., Caelles, S., Álvarez, P. A., Hornung A. S., Gool, L. V. (2017). The 2017 Davis challenge on video object segmentation, *CVPR*.
155. Martin, D., Fowlkes, C., Tal, D., Malik, J. (2001). A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics. *Eighth IEEE International Conference on Computer Vision*, 416-423.
156. Roth, S., Black, M. J. (2009). Fields of experts. *International Journal of Computer Vision*, 82(2), 205-229.

157. Ma, K., Duanmu, Z., Wu, Q., Wang, Z., Yong, H., Li, H., Zhang, L. (2017). Waterloo exploration database: New challenges for image quality assessment models. *IEEE Transactions on Image Processing*, 26(2), 1004–1016.
158. Agustsson, E., Timofte, R. (2017). NTIRE 2017 Challenge on Single Image Super-Resolution: Dataset and Study. *IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 1122-1131.
159. Lim, B., Son, S., Kim, H., Nah, S., Lee, K. M. (2017). Enhanced Deep Residual Networks for Single Image Super-Resolution. *IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 1132-1140.



ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : Yapıcı, Ahmet
 Uyruğu : T.C.
 Doğum tarihi ve yeri :
 Medeni hali :
 Telefon :
 Faks :
 e-mail :

Eğitim

Derece	Eğitim Birimi	
Doktora	Gazi Üniversitesi / Bilişim Sistemleri	
Yüksek lisans	ODTÜ / Yazılım Mühendisliği	
Lisans	Ege Üniversitesi / Bilgisayar Mühendisliği	2004
Lise	Antalya Anadolu Lisesi	2000

İş Deneyimi

Yıl	Yer	Görev
2014-Halen	Türksat A.Ş.	Direktör
2008-2014	TAI	Yazılım Mühendisi
2004-2008	Havelsan A.Ş.	Yazılım Mühendisi

Yabancı Dil

İngilizce, Almanca

Yayınlar

1. Yapıcı A., Akcayol, M. A. (2022). Derin Öğrenme ile Görüntülerde Gürültü Azaltma Üzerine Kapsamlı Bir İnceleme. *Int. J. Adv. Eng. Pure Sci.*, 34(1), 65-90.
2. Yapıcı A., Akcayol, M. A. (2021). A Review of Image Denoising With Deep Learning. *2nd International Informatics and Software Engineering Conference (IISEC)*, 1-6.
3. Kayayurt, B., Yayla, I, Yapıcı, A., Küçükoğuz, C. (2011). Ground control station

avionics software development in ANKA UAV. *IEEE/AIAA 30th Digital Avionics Systems Conference, Seattle, WA, USA*, 5B6-1-5B6-7.

Hobiler

Futbol, Yüzme





GAZİLİ OLMAK AYRICALIKTIR.