

**ÖZ BİLGİ DESTEKLİ DERİN ÖĞRENME YAKLAŞIMLARI
İLE HSG GÜRÜLTÜ GİDERME**

**SELF-INFORMATION EMPOWERED DEEP LEARNING
APPROACHES FOR HSI DENOISING**

ORHAN TORUN

DOÇ. DR. SENİHA ESEN YÜKSEL ERDEM

Tez Danışmanı

PROF. DR. MEHMET ERKUT ERDEM

İkinci Tez Danışmanı

Hacettepe Üniversitesi

Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin

Elektrik ve Elektronik Mühendisliği Anabilim Dalı için Öngördüğü

DOKTORA TEZİ olarak hazırlanmıştır.

Mayıs 2024

ÖZET

ÖZ BİLGİ DESTEKLİ DERİN ÖĞRENME YAKLAŞIMLARI İLE HSG GÜRÜLTÜ GİDERME

Orhan TORUN

Doktora, Elektrik ve Elektronik Mühendisliği Bölümü

Danışman: Doç. Dr. Seniha Esen YÜKSEL ERDEM

2'nci Danışman: Prof. Dr. Mehmet Erkut ERDEM

Mayıs 2024, 152 sayfa

Hiperspektral görüntülerin (HSG'lerin) çevre izleme, hedef tespiti ve sınıflandırma gibi alanlardaki kullanımı hayati önem taşımaktadır. Ancak, gürültü etkisiyle meydana gelen bozulmalar HSG'lerin etkinliğini önemli ölçüde engellemektedir. Bu durum, HSG'lerden elde edilen verilerin doğruluğunu ve güvenilirliğini olumsuz etkilemektedir. Bu nedenle, anlamlı bilgiyi HSG'lerden doğru bir şekilde çıkarmak için gürültü giderme kritik öneme sahiptir. Geleneksel gürültü giderme yöntemleri, başlangıçta iki boyutlu (2B) görüntü tekniklerinden uyarlandığı için önemli olan uzamsal-spektral korelasyonları göz ardı etmektedir. Bu da spektral bozulmalara yol açmaktadır. HSG gürültü gidermedeki son gelişmeler, karmaşık optimizasyon süreçleri kullanarak uzamsal-spektral korelasyonlardan faydalanmaya odaklanmıştır. Ancak bu durum da hesaplama verimliliğini olumsuz etkilemektedir.

Son zamanlarda, derin öğrenmenin popülerliği ile birlikte, Evrişimsel Sinir Ağları (ESA) tabanlı yaklaşımlar, geleneksel yöntemlere göre önemli gelişmeler göstererek HSG gürültü giderme yöntemlerinde yeni bir dalga yaratmıştır. ESA'lar güçlü model varsayımlarından

faydalanarak HSG gürültü gidermede etkili öznelik çıkarmak için kullanılmaktadır. Bu veri odaklı modeller, gürültülü HSG'lerden temiz HSG'lere otomatik olarak bir eşleme öğrenmektedir. Ancak, ESA'lar farklı giriş içeriğinin kendine özgü özelliklerine adapte olma ve uzamsal-spektral alan içindeki uzun menzilli bağımlılıkları yakalama konusunda zorluklarla karşılaşmaktadır.

Bu tez, Derin Sinir Ağları (DSA) kullanarak HSG'lerden gürültü gidermeyi ve restorasyon işlemini gerçekleştirmeyi amaçlamaktadır. Yukarıdaki zorlukların üstesinden gelebilmek için, HSG gürültü giderme işlemine özel olarak uyarlanmış yeni öz-bilgi destekli dinamik mimariler önermekteyiz. Dinamik mimariler, derin öğrenme alanında hızla gelişen bir alan olarak, statik modellere göre önemli bir avantaj sunmaktadır. Statik muadillerinin aksine, dinamik ağlar yapılarını veya parametrelerini her yeni girdi için çıkarım aşamasında uyarlayabilmektedir. Bu uyarlanabilirlik, hesaplama verimliliğinden ödün vermeden elde edilen daha iyi doğruluk, daha güçlü temsil yeteneği ve genelleme yeteneği olmak üzere üç önemli fayda sağlamaktadır.

İlk olarak, uzamsal-spektral bilgiye dayalı adaptif öznelik dönüşümünü sağlayan Spektral Öz Modülasyonlu Kalıntı Blokları (Self-Modulating Residual Blocks-SSMRB) ile donatılmış Öz-Modülasyonlu ESA (Self-Modulating Convolutional Neural Networks; SM-CNN) ağımızı tanıtmaktayız. Özellikle, SSMRB'nin eklenmesi, gürültü giderme ağımızı, her giriş HSG'sinin uzamsal-spektral özelliklerine göre gürültü giderirken tahmin edilen özneliklerini uyarlayan dinamik bir ağa dönüştürmektedir. Gürültü gidermeyi, banttan banda uzamsal bilgiyi tarayarak ve uzamsal bilgi ile birlikte bitişik spektral bilgiyi kullanarak gerçekleştirmekteyiz. Bu mimari sayesinde, farklı uzamsal-spektral özelliklere sahip test verileri tek bir model ile gürültüden arındırılabilir. Sonuçların nitel ve nicel değerlendirmesi, önerilen modelin hem yapay hem de gerçek verilerde diğer tek model algoritmalarından daha verimli olduğunu göstermektedir. Ancak, bu modelimiz, global bilgileri etkili bir şekilde yakalayamamasından dolayı son zamanlarda önerilen Dönüştürücü tabanlı modellere göre daha düşük performans sergilemektedir.

Hem yerel detayları hem de uzamsal olarak uzak bölgeleri inceleyerek, uzun menzilli

bağımlılıkların ortaya çıkarılması görüntünün daha kapsamlı bir şekilde anlaşılmasına katkıda bulunmaktadır. Öz-dikkat mekanizmasına sahip olan Dönüştürücü'ler, uzun menzilli bağımlılıkları yakalama yetenekleri nedeniyle giderek daha yaygın kullanılmaktadır. Ancak, Dönüştürücü'leri lokal özellikleri öğrenmeleri için eğitmek genellikle önemli miktarda veri gerektirmektedir ve bu veri HSG'lerde kolayca bulunamayabilir. Ek olarak, HSG'lerdeki yüksek bant sayısı, özellikle öz-dikkat hesaplamaları için Dönüştürücü'lerde bellek kullanımını ve hesaplama karmaşıklığını artırabilmektedir. Bu sorunları ele almak için, ESA'ların güçlü yönü olan lokal öznitelik çıkarımını, Dönüştürücü yapısının uzun mesafeli bağımlılık modelleme becerisi ile birleştiren Hibrit ESA-Dönüştürücü modeli olan 3B evrişim ağı ile Kanal-bazlı ve Spektral Dönüştürücü (Channel-wise and Spectral Transformer with 3D convolution network; CST3D) sunmaktayız. CST3D, spektral ve kanal bazlı öz-dikkat mekanizmalarını, öğrenilebilir modülatörlerle entegre ederek, ilgili spektral bantları önceliklendirmeyi ve dikkat odağını güçlendirmeyi sağlamaktadır. Bu hibrit yaklaşım, ESA ve Dönüştürücü bireysel modellerin sınırlamalarını aşarak üstün gürültü giderme performansı ve farklı veri kümelerine genelleştirilebilme imkanı sunmaktadır. Deneysel sonuçlar, yaklaşımımızın HSG'lerden farklı türdeki gürültüyü etkili bir şekilde giderdiğini ve klasik, CNN tabanlı ve diğer hibrit modeller dahil olmak üzere günümüzün en son teknoloji modellerinden daha iyi performans gösterdiğini ortaya koymaktadır.

Diğer yandan, sinir ağlar genellikle gözetimli öğrenme yöntemiyle eğitilmekte ve daha sonra görülmemiş veriler üzerinde test edilmektedir. Gözetimli öğrenme büyük miktarda veri gerektirmektedir ve aynı zamanda temiz görüntülere de ihtiyaç duymaktadır. Ancak, HSG'ler için çok sayıda görüntü toplamak ve temiz görüntüler elde etmek zor ve masraflıdır. Sonuç olarak, bu gibi durumlarda sinir ağlarını gözetimli öğrenme yöntemleriyle eğitmek zorlu hale gelmektedir. Dinamik modeller veri adaptasyonunu artırmada etkili olsa da, HSG verisinin önemli spektral değişkenlik gösterdiği durumlarda performans düşüşleri yaşanabilmektedir. Bu çalışmada önerdiğimiz iki aşamalı öğrenme stratejisi hem ön öğrenmeyi hem de öz-gözetimli kalibrasyonu kullanmaktadır. İlk aşama, modeli gürültülü ve temiz veri çiftleri üzerinde eğitmek için gözetimli öğrenmeyi içermektedir. İkinci aşama, yalnızca gürültülü verileri kullanarak öz-gözetimli kalibrasyonla modeli belirli

gürültü çeşitlerine uyarlamaktadır. Bunun için, orta spektral bandı tahmin etmek amacıyla komşu bandın bilgilerini hedef olarak kullanılmaktayız. Ağın anlamlı ilişkileri öğrenmesini ve yalnızca girdiyi kopyalamayı engellemek için, hedef bandı giriş verilerinden stratejik olarak hariç tutarak kör bir nokta oluşturmaktayız. Bu nedenle, öz-gözetimli öğrenme tekniğimize Kör Bant Öz-gözetimli (Blind Band Self-Supervised; BBSS) öğrenme adı verilmektedir. Yaklaşımımızın, sinir ağı daha önce gözetimli öğrenmede belirli gürültü modelleriyle karşılaşmamış olsa bile, gürültülü HSG'ler için modelin doğruluğunu artırdığı gösterilmektedir.

Çalışmalarımız, HSG gürültü giderme için dinamik derin öğrenme mimarilerine doğru bir paradigim değişikliğini temsil etmektedir. Bu yaklaşım, gerçek dünya senaryolarında daha iyi doğruluk, hesaplama verimliliği ve genelleme yeteneklerinin vaadini taşımaktadır. Ek olarak, modelleri öz-kalibre etme yetenekleriyle donatarak, böylece temiz veri olmadan bile daha öncede görülmemiş ve potansiyel olarak gürültülü verilere uyum sağlama ve genelleme yeteneğini güçlendirmek amaçlanmaktadır.

Keywords: hiperspektral görüntü, öz bilgi, CNN, Dönüştürücü, gürültü giderme, görüntü restorasyonu

ABSTRACT

SELF-INFORMATION EMPOWERED DEEP LEARNING APPROACHES FOR HSI DENOISING

Orhan TORUN

**Doctor of Philosophy, Department of Electrical and Electronics
Engineering**

Supervisor: Assoc. Prof. Seniha Esen YÜKSEL ERDEM

2nd Supervisor: Prof. Mehmet Erkut ERDEM

May 2024, 152 pages

Hyperspectral images (HSIs) are of critical importance, especially in areas such as environmental monitoring, target detection, and classification. However, the degradation caused by noise effects significantly hinders the effectiveness of HSIs. This situation negatively affects the accuracy and reliability of the data obtained from HSIs. Hence, noise removal is essential to extract meaningful information from HSIs accurately. Traditional denoising methods, initially adapted from two dimensional (2D) imaging techniques, overlook crucial spatial-spectral correlations, resulting in spectral distortions. Recent advancements in HSI denoising have focused on exploiting spatial-spectral correlations through complex optimization processes, sacrificing computational efficiency.

Recently, with the popularity of deep learning, Convolutional Neural Network (CNN) based approaches have created a fresh wave of HSI denoising methods, demonstrating significant improvements over the traditional methods. CNNs leverage their strong inductive bias for effective feature extraction in HSI denoising. These data-driven models automatically learn

a mapping from noisy HSIs to clean HSIs. However, they encounter challenges in adapting to the specific characteristics of diverse input content and capturing long-range dependencies within the spatial-spectral domains.

This dissertation aims to use Deep Neural Networks (DNNs) to eliminate noise and perform restoration on HSIs. To address the above challenges, we propose novel self-information empowered dynamic architectures tailored for HSI denoising. Dynamic architectures, a burgeoning field within deep learning, offer a significant advantage over static models. Unlike their static counterparts, dynamic networks can adapt their structure or parameters during the inference stage for each new input. This adaptability enhances accuracy, representation power, and generality, all achieved without sacrificing computational efficiency.

Firstly, we introduce the Self-Modulating CNN (SM-CNN), equipped with Spectral Self-Modulating Residual Blocks (SSMRBs), enabling adaptive feature transformation based on spatio-spectral information. In particular, the introduction of SSMRB transforms our denoising network into a dynamic network that adapts its predicted features while denoising every input HSI with respect to its spatio-spectral characteristics. We perform noise removal by scanning band-to-band spatial information and using adjacent spectral information along with spatial information. Thanks to this architecture, test data with different spatial-spectral properties can be denoised with a single model. The qualitative and quantitative evaluation of the results show that the proposed algorithm is more efficient than other single-model algorithms on both synthetic and real data. However, our model exhibits lower performance compared to recently proposed transformer-based models due to its inability to capture global information effectively.

By investigating both local details and spatially distant areas, the unveiling of long-range dependencies contributes to a more comprehensive understanding of the image. Transformers, with their self-attention mechanism, are increasingly recognized for their ability to capture long-range dependencies. However, training Transformers to learn local features often requires substantial data, which may not be readily available for

HSIs. Additionally, the high band count in HSIs can lead to increased memory usage and computational complexity in Transformers, particularly for self-attention calculations. To address these challenges, we present a Hybrid CNN-Transformer model, CST3D (Channel-wise and Spectral Transformer with 3D convolution network), combining CNN's local feature extraction with Transformer's long-range dependency modeling. CST3D integrates spectral and channel-wise self-attention mechanisms, augmented with learnable modulators to prioritize relevant spectral bands and enhance attention focus. This hybrid approach overcomes limitations of individual models, offering superior denoising performance and generalization to diverse datasets. Experimental results show that our approach effectively removes different types of noise from HSIs, outperforming current state-of-the-art models, including classical, CNN-based, and other hybrid models.

On the other hand, neural networks are trained in a supervised manner and then tested on unseen data. Supervised training requires a large amount of data, and it also relies on clean images. However, collecting a large number of images and obtaining clean images for HSIs are difficult and costly. Consequently, training neural networks with supervised methods becomes challenging for such cases. While dynamic networks are effective in enhancing data adaptation, performance degradation occurs in cases where HSI data exhibits significant spectral variability. In this dissertation, our proposed two-stage learning strategy leverages both pre-training and self-supervised calibration. The first stage involves supervised learning to train the model on noisy and clean data pairs. The second stage incorporates self-supervised calibration using only noisy data to adapt the model to specific noise patterns. For the latter, to estimate the middle spectral band, we leverage the information from its neighboring band as a target. To ensure the network learns meaningful relationships rather than merely copying the input, we strategically create a blind spot by excluding the target band from the input data. Therefore, our self-supervised learning technique is named as Blind Band Self-Supervised (BBSS) Learning. Our approach has been shown to improve the accuracy of the model for noisy HSIs, even when the network did not previously encounter the specific noise patterns in supervised learning.

Our contributions signify a paradigm shift towards dynamic deep learning architectures

for HSI denoising. This approach holds the promise of enhanced accuracy, computational efficiency, and generalization capabilities in real-world scenarios. Additionally, it endows the models with self-calibration capabilities, reinforcing its ability to adapt and generalize to unseen and potentially noisy data, even in the absence of clean data.

Keywords: hyperspectral image, self-information, CNN, Transformer, denoising, image restoration

TEŞEKKÜR

Bu çalışmanın gerçekleştirilmesinde yardımlarını ve rehberliğini esirgemeyen, değerli fikirleriyle katkıda bulunan, akademik gelişimime önemli katkılarda bulunan tez danışmanım Doç. Dr. Seniha Esen YÜKSEL ERDEM'e en içten teşekkürlerimi ve saygılarımı sunarım. Çalışmanın her aşamasında sağladığı sürekli destek, bilimsel bakış açısı ve motivasyonu artırıcı yaklaşımları benim için son derece değerli olmuştur. Ayrıca, çalışma sürecimde sağladığı yönlendirmeler ve bilimsel katkılarla bana rehberlik eden ikinci tez danışmanım Prof. Dr. Erkut ERDEM ve bu süreçte birlikte çalışma fırsatı bulduğum kıymetli hocalarım Doç. Dr. Aykut ERDEM'e ve Dr. Nevrez İMAMOĞLU'na şükranlarımı sunarım. Onların bilgi ve deneyimleri, bu çalışmanın başarıyla tamamlanmasında büyük rol oynamıştır.

Bu çalışmanın gerçekleştirilmesinde sağladıkları rehberlik ve akademik desteklerinden dolayı tez izleme komitemde bulunan değerli hocalarım Prof. Dr. Cenk TOKER'e ve Doç. Dr. Erchan APTOULA'ya teşekkürlerimi sunarım. Yaptıkları değerli katkılar ve sağladıkları bilimsel görüşler, çalışmanın kalitesini artırmamıza büyük ölçüde katkıda bulunmuştur. Tez sürecinde gösterdikleri sabır, anlayış ve yönlendirmeleri için kendilerine derin şükranlarımı iletiyorum.

Jürideki değerli hocalarım başta olmak üzere, eğitim hayatım boyunca bilgi ve deneyimlerini esirgemeyen, akademik gelişimime önemli katkılarda bulunan tüm öğretmenlerime şükranlarımı ve saygılarımı sunarım.

Sevgili aileme, hayatımın her anında yanımda oldukları, manevi destekleriyle her zaman bana güç verdikleri için en içten teşekkürlerimi sunuyorum.

Çalışmamın yürütülmesinde sağladıkları destek için İLTAREN'e ve moral kaynağım olan kıymetli iş arkadaşlarıma içten teşekkürlerimi iletiyorum.

KUIS Yapay Zeka Araştırma Merkezi'ne sunduğu yapay zeka altyapısı için teşekkürlerimi sunarım.

Bu çalışma, TÜBİTAK tarafından 123E385 no'lu “Görünmeyeni Görmek: Hiperspektral Görüntülerin İyileştirilmesine ve Üretimine Uçtan Uca Yaklaşımlar” adlı proje kapsamında desteklenmiştir. Desteklerinden ötürü TÜBİTAK'a teşekkür ederim.

Ve işte, bu uzun yolculuğun önemli bir aşamasını daha geride bırakıyorum. Bu süreçte öğrendiklerim, yaşadıklarım ve hissettiklerim paha biçilemez bir hazine gibi kalbimde yer edindi. Her adımda beni motive eden şey, sönmeyen bir ateş gibi içimde yanan azimimdi. Bu azim, kararlılıkla ilerlememe güç verdi. Disiplinli bir şekilde çalışarak, hedeflerime adım adım yaklaştım. Mükemmelliği kovalamak ve kendi sınırlarımı zorlamak, benim için daima bir ilke oldu. Yaşadığım her deneyim, bana paha biçilmez dersler verdi. Kendime olan inancımı ve potansiyelimi her geçen gün daha da perçinledim. Bu nedenle, bu olağanüstü yolculukta bana rehberlik eden ve beni ben yapan her şeye minnettarım.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
ÇİZELGELER DİZİNİ.....	xiv
ŞEKİLLER DİZİNİ	xvi
KISALTMALAR	xxiii
1. GİRİŞ	1
1.1. Tezin Kapsamı	6
1.1.1. HSG için Gürültü Giderme Ağlarının Öğrenme Stratejileri	12
1.2. Katkılar.....	14
1.2.1. Yayınlar	17
1.2.2. Açık Kaynak Yazılım Katkıları.....	18
1.3. Tezin Organizasyonu	18
2. TEMEL BİLGİLER.....	20
2.1. Hiperspektral Gürültü Modeli.....	20
2.2. Hiperspektral Görüntülerin Düşük Kerte Özellikleri	21
2.3. Görüntü Dönüştürücü	22
2.3.1. Öz-Dikkat	23
2.3.2. Çoklu Öz-Dikkat	26
2.4. Yenilikçi Yaklaşımlar: Öz-Gözetimli Öğrenme	27
2.4.1. Derin Görüntü Önseli	27
2.4.2. Gürültüden Gürültüye.....	29
2.4.3. Gürültüden Boşluğa.....	31
3. İLGİLİ ÇALIŞMALAR	33
3.1. Klasik Yöntemler	33
3.2. Gözetimli Derin Sinir Ağları.....	35

3.2.1. CNN Tabanlı Modeller	35
3.2.2. Dönüştürücü Tabanlı ve Hibrit Modeller	37
3.3. Öz-Gözetimli Derin Sinir Ağları.....	39
4. ÖNERİLEN YÖNTEMLER.....	41
4.1. Öz-Modülasyonlu Evrimsel Sinir Ağı	42
4.1.1. Yöntem Açıklaması	44
4.1.2. Ağ Mimarisi	46
4.1.2.1. Öz-Modülasyonlu Kalıntı Bloğu.....	48
4.1.3. Yitim Fonksiyonu	50
4.2. Çift Dikkatli Hibrit CNN ve Dönüştürücü	50
4.2.1. Ağ Mimarisi	52
4.2.1.1. Gömme Katmanı.....	53
4.2.1.2. Dönüştürücü Katmanı.	53
4.2.1.3. Yukarı/Aşağı Örnekleme Katmanları.	60
4.2.1.4. Arıtma Katmanı.....	61
4.2.2. Yitim Fonksiyonu	62
4.3. Öz-Gözetimli Gürültü Giderme Ağlarının Kalibrasyonu	62
4.3.1. İki Aşamalı Öğrenme: Kör Bant Öz-Gözetimli Öğrenme	65
5. DENEYSEL SONUÇLAR	69
5.1. Veri Kümeleri	69
5.2. Değerlendirme Metrikleri	72
5.3. Yapay Gürültü Ayarları.....	73
5.4. Performans Değerlendirmesi: SM-CNN	74
5.4.1. Simüle Edilmiş Gürültü Deneyleri	75
5.4.2. Gerçek Veri Deneyleri	83
5.4.3. Bileşen İşlevsellik Analizi	85
5.5. Performans Değerlendirmesi: CST3D.....	89
5.5.1. Simüle Edilmiş Gürültü Deneyleri	90
5.5.2. Gerçek Veri Deneyi	98
5.5.3. Bileşen İşlevsellik Analizi	99

5.6. Performans Deęerlendirmesi: Grlt Giderici Aęların z-Gzetimli Kalibrasyonu	102
5.6.1. Simle Edilmiř Grlt Deneyleri	103
5.6.2. Gerek Veri Deneyi	106
6. SONULAR	109

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 5.1	Deneylerde Kullanılan Veri Kümelerinin genel özellikleri. 70
Çizelge 5.2	WDC Veri Kümesi Üzerinde Beş Karmaşık Gürültü Durumu ile Farklı Gürültü Giderme Yöntemlerinin Nicel Değerlendirmesi. 76
Çizelge 5.3	PU Veri Kümesi Üzerinde 10 Gürültülü Koşuda Farklı Gürültü Giderme Yöntemlerinin Nicel Değerlendirmesi. 79
Çizelge 5.4	IP Veri Kümesi Üzerinde Sınıflandırma Doğrulukları (SVM, %10 Eğitim Etiketleri) ve Yöntemlerin Çalışma Süreleri..... 84
Çizelge 5.5	HSIDwRD Veri Kümesi Üzerinde Farklı Gürültü Giderme Yöntemlerinin Nicel Değerlendirmesi. 85
Çizelge 5.6	Karışım Gürültü İçeren WDC Üzerinde Nicel Değerlendirme. 87
Çizelge 5.7	Atlama Bağlantılarının Ağ Performansı Üzerindeki Etkisi ($K = 24$). 88
Çizelge 5.8	Derin Sinir Ağının Eğitim Aşamaları. 90
Çizelge 5.9	ICVL Veri Kümesinde 4 Farklı Gauss Gürültü Seviyesi ile Farklı Gürültü Giderme Yöntemlerinin Nicel Değerlendirmesi. 91
Çizelge 5.10	ICVL Veri Kümesi Üzerindeki Beş Karmaşık Gürültü Senaryosunda Farklı Gürültü Giderme Yöntemlerinin Nicel Değerlendirmesi. 93
Çizelge 5.11	WDC Veri Kümesi Üzerindeki Beş Karmaşık Gürültü Senaryosunda Farklı Gürültü Giderme Yöntemlerinin Nicel Değerlendirmesi. 96
Çizelge 5.12	HSIDwRD Veri Kümesi Üzerinde Farklı Gürültü Giderme Yöntemlerinin Nicel Değerlendirmesi ve Yöntemlerin Çalışma Süreleri. 99
Çizelge 5.13	WDC ve ICVL Veri Kümelerinde Durum 5 Karışım Gürültü ile Bileşen Analiz Çalışmasının Nicel Değerlendirmesi. 101
Çizelge 5.14	CAVE Veri Kümesi Üzerindeki Nicel Sonuçlar. 104

Çizelge 5.15 WDC Veri Kümesinde Beş Karmaşık Gürültü Durumu ile Farklı Öğrenme Yaklaşımlarının Nicel Değerlendirmesi.	106
--	-----

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 1.1	Temiz spektral imzalara sahip hiperspektral veri küpü. 2
Şekil 1.2	Hiperspektral sensörler için elektromanyetik spektrum bölgeleri..... 3
Şekil 1.3	Sahte RGB görüntüler, iç ve dış mekanlardan alınan uzun ve kısa pozlama HSG örnekleri (RGB olarak 664nm, 532nm, 488nm HSI bantları kullanılarak sentezlenmiştir). Kısa pozlama gürültülü görüntüler üstte gösterilirken, temiz uzun pozlama görüntüler altta gösterilmektedir..... 5
Şekil 1.4	Uzaktan algılama verilerinde mevcut olan doğal gürültüyü sergileyen, Indian Pines ve Urban veri kümelerinden örnek bantları gösteren gri tonlamalı görüntüler. 6
Şekil 1.5	HSG gürültü giderme için eğitim modellerinin görsel karşılaştırması. (a) Tek bantı kullanarak karşılık gelen bantı tahmin etme (single-to-single; S2S), (b) Birden fazla bantı kullanarak birden fazla bantı tahmin etme (multi-to-single; M2M), (c) Birden fazla bantı kullanarak tek bantı tahmin etme (multi-to-single, M2S), (d) Önerdiğimiz kör bant öz-gözetimli (blind band self-supervised; BBSS) öğrenme. 13
Şekil 2.1	Bir HSG yamasından düşük kerte bir matris oluşturma sürecinin gösterimi. 21
Şekil 2.2	Dönüştürücü yapısı ve dikkat mekanizmasının temsili gösterimi (a) Dönüştürücü kodlayıcı bloğu, (b) Çoklu öz-dikkat (Multihead self-attention; MSA), (c) Öz-dikkat (Self-attention; SA)..... 24
Şekil 2.3	Üreteç ağı ile derin görüntü önseli yöntemi kullanarak görüntü restorasyonu. 28

Şekil 2.4	Ağ Öğrenme Metodolojisi (a) Gözetimli öğrenme (Noise2Clean), (b) Öz-gözetimli öğrenme: Gürültüden gürültüye (Blind-spot network-Noise2Void).....	31
Şekil 4.1	FLOPs ve parametre sayısına karşı çizilen MPSNR ile model karmaşıklığı ve performans karşılaştırması. Balonların boyutu modelin görece parametre sayısını göstermektedir.	42
Şekil 4.2	HSG gürültü giderme için önerilen SM-CNN modelinin sistem genel bakışı. Eğitimde, ilk olarak temiz HSG'yi yapay gürültü ekleyerek gürültülü giriş verileri elde edilmektedir. Ardından, $K/2$ bantlarını çevirerek uç noktalarda spektral süreklilik sağlandıktan sonra uzamsal kırpma gerçekleştirilmektedir. Spektral boyutu sürekli tarayarak, uzamsal olarak kırılmış yamalardan komşu K spektral bant elde edilmektedir. Orta bant gürültüsünü gidermek için ağı eğitirken uzamsal olarak kırılmış komşu bantlar da girdi olarak kullanılmaktadır. Bu işlem tüm bantlar için aynı şekilde tekrarlanmaktadır. Gürültülü K komşu bant, Şekil 4.3'te gösterildiği gibi ağı düzenlemek için derin katmanlarda bir SSMRB'den geçmektedir. Ayrıca, orta bandı nihai çıktıya ekleyerek eğitimin kararlılığını ve verimliliğini sağlamak için kalıntı öğrenme stratejisi kullanılmaktadır. Testte ise, eğitimde olduğu gibi verileri uzamsal olarak kırıldıktan ve spektral olarak taranıp, sonra ağa girdi olarak verilmektedir. Burada ağ, derin katmanlardaki SSMRB aracılığıyla testle ilişkili spektral bantlarla modüle edilmekte, bu da modelin eğitim sırasında doğrudan görülmeyen karmaşık gürültü ayarları altında kendini uyarlamasını sağlamaktadır.	45
Şekil 4.3	Önerilen SM-CNN'nin yapısı. Derin katmanlarda kullanılan SSMRB Şekil 4.4'de verilmekte ve Bölüm 4.1.2.1.'de detaylandırılmaktadır.	47

Şekil 4.4	SM-CNN gürültü giderici ağımızda kullanılan spektral öz-modülasyonlu kalıntı bloğu (SSMRB). Bu blok, ağ gürültüye uyarlamak için spektral komşu bantları kullanarak derin katmanlardaki özellikleri modüle etmektedir.	49
Şekil 4.5	Önerilen hibrit ağımız olan CST3D'nin genel yapısı. CST3D iki paralel öz-dikkat mekanizması kullanılmakta: spektral öz dikkat (spectral self-attention; SSA) ve kanal bazlı öz-dikkat (channel-wise self-attention; CSA). SSA global spektral bilgilerden yararlanırken, CSA uzamsal ve spektral ayrıntılara odaklanmaktadır. Bu mekanizmaların çıktıları birleştirilip ve derinlemesine 3B evrişime (DWCONV3), ardından da basit bir geçitli doğrusal birime (SGate) iletilmektedir. CST3D'deki temel bileşenlerin yapısı Şekil 4.6'da detaylandırılmaktadır.	53
Şekil 4.6	CST3D'deki temel bileşenler. Hem spektral hem de özellik kanalları için öğrenilebilir modülatörler ekleyerek, modelimizin ilgili bantlara öncelik verme, dikkat odağını keskinleştirme ve eğitimi stabilize etme becerisini geliştirmekteyiz. (a) Kanal bazlı öz-dikkatin (CSA) yapısı, (b) Spektral öz-dikkatin (SSA) yapısı, (c) Basit geçitli doğrusal birim. Eleman bazında çarpma işlemi doğası gereği doğrusal olmadığından, aktivasyon fonksiyon kullanımını ortadan kaldırmaktayız.	55
Şekil 4.7	İlk katman için kanal modülatörü ile kanal bazlı öz-dikkat (CSA) haritası ve bazı öznitelik haritası kanallarının spektral spektrum boyunca ortalama değeri. (a) CSA skor matrisi, (b) Öznitelik kanalı 4, (c) Öznitelik kanalı 10, (d) Öznitelik kanalı 22.	57
Şekil 4.8	Şekil 4.7(a)'nın 10. sütununda gösterilen, 10. kanal ile diğer tüm kanallar arasındaki dikkat skoru.	57

Şekil 4.9	İlk katman için spektral modülatörlü spektral öz-dikkat (SSA) haritası ve bazı giriş görüntüsü spektral bantları (a) SSA skor matrisi, (b) 9. spektral bant (PSNR=20.785dB), (c) 11. spektral bant (PSNR=10.876dB), (d) 19. spektral bant (PSNR=17.199dB).....	59
Şekil 4.10	Şekil 4.9(a)'nın 9. sütununda gösterilen 9. spektral bant ile diğer tüm bantlar arasındaki dikkat skoru.	59
Şekil 4.11	Modülatörün etkisi: (a) yitim, (b) eğitim süreci boyunca doğrulama verilerinin PSNR değeri.	60
Şekil 4.12	İlk iki katmanın dikkat haritaları: (a) modülatörsüz, (b) modülatörlü. .	61
Şekil 4.13	Eğitim çiftleri renkli oklarla gösterilmektedir. Kırmızı ok: gürültüden temize eğitim çifti, Yeşil ok: gürültüden gürültüye eğitim çifti, Mavi ok: banttan banda eğitim çifti. Banttan banda eğitim çiftinde, görüntülerin dalga boyları farklıdır.	64
Şekil 4.14	Kırmızı çizgi: i . temiz bant ve i . kirli-1 bant arasındaki karşılıklı bilgi, Yeşil çizgi: i . kirli-1 bandı ile i . kirli-2 bandı arasındaki karşılıklı bilgi, Mavi çizgi: Kirli-1 verisinin $\{i., (i + 1).\}$ bantları arasındaki karşılıklı bilgi.	65
Şekil 4.15	İki aşamalı öğrenme şemasına genel bakış. Ağ mimarisi uygun herhangi bir mimari olabilmektedir. Örneğin, Bölüm 5.6.'da hem CST3D modelimizi hem de literatürden CNNFormer ve QRN3D'yi modellerini kullanmaktayız.	66
Şekil 5.1	Durum 5'teki karışım gürültülü WDC için sonuçlar. (a) Sahte renkli orijinal görüntü (bantlar: 57, 27, 17), (b) Kirli görüntü, (c) LRTF-DFR, (d) FastHyMix, (e) BM4D, (f) LRTV, (g) LRMR, (h) LRTDTV, (i) QRNN3D, (j) HSID-CNN, (k) MemNet, (l) HDNET, (m) MAN, (n) SM-CNN (Bizim).	77
Şekil 5.2	Durum 5 için önerilen ve rakip yöntemlerin gürültü giderme sonuçlarına karşılık gelen spektrum boyunca PSNR ve SSIM değerleri. 79	79

Şekil 5.3	Karışım gürültülü PU için sonuçlar. (a) Sahte renkli orijinal görüntü (bantlar: 60, 32, 10), (b) Kirli görüntü, (c) LRTF-DFR, (d) FastHyMix, (e) BM4D, (f) LRTV, (g) LRMR, (h) LRTDTV, (i) QRNN3D, (j) HSID-CNN, (k) MemNet, (l) HDNET, (m) MAN, (n) SM-CNN (Bizim).	81
Şekil 5.4	PU veri kümesinin her bir pikseline karşılık gelen SAM değerleri. (a) Kirli veri, (b) LRTF-DFR, (c) FastHyMix, (d) BM4D, (e) LRTV, (f) LRMR, (g) LRTDTV, (h) QRNN3D, (i) HSID-CNN, (j) MemNet, (k) HDNET, (l) MAN, (m) SM-CNN (Bizim).	82
Şekil 5.5	PU verisinde (55, 169) pikselinin spektral imza restorasyonunun kalitesi.....	82
Şekil 5.6	Doğal gürültülü IP veri kümesi sonuçları. (a) Band 2 kullanılarak gürültülü HSG'nin gri tonlamalı görüntüsü, (b) TDL, (c) BM4D, (d) LRTV, (e) LRMR, (f) LRTDTV, (g) LRTF-DFR, (h) FastHyMix, (i) QRNN3D (j) HSID-CNN, (k) MemNet, (l) HDNET, (m) MAN, (n) SM-CNN (Bizim).	84
Şekil 5.7	Gerçek gürültülü HSIDwRD veri kümesi sonuçları. (a) Uzun pozlama sahte renkli temiz görüntü (bantlar: 30, 15, 10), (b) Kısa pozlama kirli görüntü, (c) LRTF-DFR, (d) FastHyMix, (e) BM4D, (f) LRTV, (g) LRMR, (h) LRTDTV, (i) QRNN3D, (j) HSID-CNN, (k) MemNet, (l) HDNET, (m) MAN, (n) SM-CNN (Bizim).	86
Şekil 5.8	Farklı sayıda bitişik spektral bant ile gürültü giderme etkinliği.	88

- Şekil 5.9 ICVL için $\sigma = 30$ ile elde edilen sonuçlar. Sol üst köşedeki görüntüler, orijinal ve işlenmiş görüntüler arasındaki farklılıkları vurgulayan, 20 kat ölçeklenmiş ve ters çevrilmiş hata haritalarını göstermektedir (yani, $1 - 20 \times \{\text{temiz-işlenmiş}\}$). Hata haritaları, 3 bandın farkı alındığı için renkli görünmektedir. Daha beyaz alanlar daha düşük hata seviyelerini temsil etmektedir. (a) Sahte renkli temiz görüntü (bantlar: 29, 16, 8), (b) Kirli görüntü, (c) BM4D, (d) BCTF-HSI (e) LRMR, (f) LRTDTV, (g) LRTF-DFR, (h) FastHyDe, (i) HSID-CNN, (j) GRUNET, (k) QRNN3D, (l) SERT, (m) SST, (n) TRQ3DNet, (p) HSDT, (r) CST3D (Bizim)..... 92
- Şekil 5.10 Durum 5'teki karışım gürültülü ICVL için sonuçlar. Sol üst köşedeki görüntüler, orijinal ve işlenmiş görüntüler arasındaki farklılıkları vurgulayan, 10 kat ölçeklenmiş ve ters çevrilmiş hata haritalarını göstermektedir (yani, $1 - 10 \times \{\text{temiz-işlenmiş}\}$). Hata haritaları, 3 bandın farkı alındığı için renkli görünmektedir. Daha beyaz alanlar daha düşük hata seviyelerini temsil etmektedir. (a) Sahte renkli temiz görüntü (bantlar: 29, 16, 8), (b) Kirli görüntü, (c) BM4D, (d) BCTF-HSI (e) LRMR, (f) LRTDTV, (g) LRTF-DFR, (h) FastHyMix, (i) HSID-CNN, (j) GRUNET, (k) QRNN3D, (l) SERT, (m) SST, (n) TRQ3DNet, (p) HSDT, (r) CST3D (Bizim)..... 95
- Şekil 5.11 Durum 5'teki Karışım gürültülü WDC için sonuçlar. Sol üst köşedeki görüntüler, orijinal ve işlenmiş görüntüler arasındaki farklılıkları vurgulayan, 10 kat ölçeklenmiş ve ters çevrilmiş hata haritalarını göstermektedir (yani, $1 - 10 \times \{\text{temiz-işlenmiş}\}$). Hata haritaları, 3 bandın farkı alındığı için renkli görünmektedir. Daha beyaz alanlar daha düşük hata seviyelerini temsil etmektedir. (a) Sahte renkli temiz görüntü (bantlar: 153, 99, 39), (b) Kirli görüntü, (c) BM4D, (d) BCTF-HSI, (e) LRMR, (f) LRTDTV, (g) LRTF-DFR, (h) FastHyMix, (i) MemNet, (j) HSID-CNN, (k) QRNN3D, (l) SERT, (m) SST, (n) TRQ3DNet, (p) HSDT, (r) CST3D (Bizim). 97

Şekil 5.12	Durum 5 için önerilen ve rakip yöntemlerin gürültü giderme sonuçlarına karşılık gelen spektrum boyunca PSNR ve SSIM değerleri.	98
Şekil 5.13	Doğal gürültülü HSIDwRD veri kümesi sonuçları. Her görüntüde, sağ alt köşede renkli bir kutunun içinde yakınlaştırılmış bir bölge gösterilmektedir. (a) Band 32 kullanılarak uzun pozlama HSG'nin gri tonlamalı görüntüsü, (b) Kısa pozlama kirli görüntü, (c) BM4D, (d) LRMR, (e) LRTDTV, (f) LRTE-DFR, (g) FastHyMix, (h) HSID-CNN, (i) QRNN3D, (j) SERT, (k) SST, (l) TRQ3DNet, (m) HSDT, (n) CST3D (Bizim).	100
Şekil 5.14	HSIDwRD verisindeki (272, 272) pikselinin spektral imza restorasyon kalitesi.	100
Şekil 5.15	İki aşamalı öğrenme yaklaşımının etkinliğini gösteren görsel örnekler. (a) Sahte renkli CAVE verisi (bantlar: 30,15,10), (b) Her bandı GN ile kirlenmiş ve bantların üçte birinin rastgele seçilip %10 ile %70 arasında değişen yoğunlukta IN eklenmiş gürültülü görüntü, (c) GN ile eğitilmiş QRNN3D sonucu, (d) GN ile eğitilmiş TRQ3D sonucu, (e) GN ile eğitilmiş CNNFormer sonucu, (f) Gürültülü görüntüyle 34 epok BBSS öğrenme kullanılarak eğitilmiş CNNFormer sonucu.	105
Şekil 5.16	URBAN verinin altı farklı spektral bandından alınmış gri tonlamalı görüntüler. (a) Orijinal kirli bantlar, (b) BM4D, (c) BTC-HSI, (d) GLF, (e) GN ile eğitilmiş QRNN3D sonuçları, (f) Gürültülü görüntüyle 50 epok BBSS öğrenme kullanılarak eğitilmiş CNNFormer sonuçları, (g) GN ile eğitilmiş CST3D sonuçları, (h) Gürültülü görüntüyle 50 epok BBSS öğrenme kullanılarak eğitilmiş CNNFormer sonuçları.	107

KISALTMALAR

1B	: 1 Boyutlu
2B	: 2 Boyutlu
3B	: 3 Boyutlu
AB	: Atlama Bağlantıları
BBSS	: Blind Band Self-Supervised
CNN	: Convolutional Neural Network
CSA	: Channel-wise Self-Attention
CST3D	: Channel-wise and Spectral Transformer with 3D convolution network
DIP	: Deep Image Prior
DN	: Dead Pixel Noise
DNN	: Deep Neural Network
DSA	: Derin Sinir Ağı
ESA	: Evrişimsel Sinir Ağı
FFN	: Feed-Forward Neural Network
FLOPs	: Floating-point Operations
GN	: Gaussian Noise
HSG	: HiperSpektral Görüntü
HSI	: HyperSpectral Image
IN	: Impulse Noise
LN	: Layer Normalization
LWIR	: Long-Wave InfraRed
M2M	: Multi-to-Multi
M2S	: Multi-to-Single
MAE	: Mean Absolute Error
MPSNR	: Mean Peak Signal-to-Noise Ratio
MSA	: Multihead Self-Attention

MSE	:	Mean Squared Error
MSSIM	:	Mean Structural SIMilarity Index
MWIR	:	Mid-Wave InfraRed
NLP	:	Natural Language Processing
OA	:	Overall Accuracy
S2S	:	Single-to-Single
SA	:	Self-Attention
SAM	:	Spectral Angle Mapper
SGate	:	Simple Gate Unit
SM-CNN	:	Self-Modulation Convolutional Neural Network
SN	:	Stripe Noise
SSM	:	State Space Model
SSMM	:	Spectral Self-Modulation Modules
SSMRB	:	Spectral Self-Modulating Residual Block
SVM	:	Support Vector Machine
SWIR	:	Short-Wave InfraRed
ViT	:	Vision Transformer
VNIR	:	Visible and Near-InfraRed

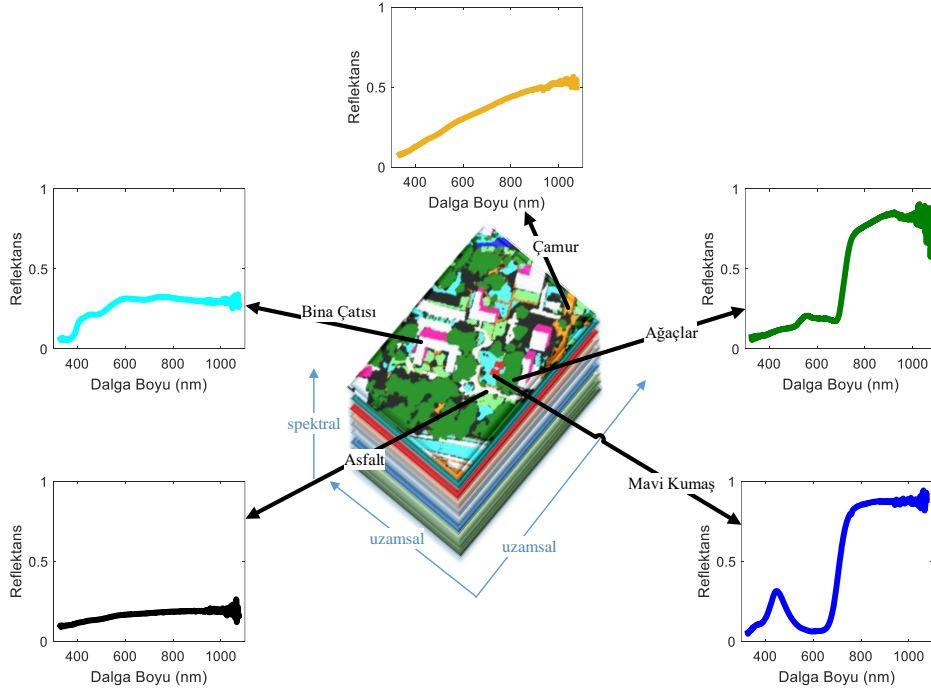
1. GİRİŞ

Hiperspektral kameralar, geniş bir uygulama yelpazesine sahip, çok avantajlı ve yüksek değerli bir teknolojidir. Hem görünür hem de görünmez spektral bantlarda görüntü oluşturabilmekte, yüzlerce banttan uzamsal ve spektral bilgi sağlayabilmekte ve bir nesneyi tek bir pikselden bile tespit edebilmekteler. Hiperspektral görüntüler (HSG'ler) olarak adlandırılan bu görüntüler, nesnelerin benzersiz spektral imzasını yakalayıp, yansıtma özelliklerinin ışık spektrumu boyunca nasıl değiştiğini ortaya çıkarmaktadır.

HSG'ler nesnelerin farklı dalga boylarında ne kadar ışık yansıttığını ölçen verilerdir [1]. Yüzlerce dalga boyuna bakıldığında, bir nesnenin ışığı yansıtma şekli onun spektral imzasını oluşturmaktadır. Bu imzalar, görüntüdeki her pikselin hangi malzemeden yapıldığını belirlemek ve görsel olarak benzer olan nesnelere uzamsal (görüntüdeki konumu) ve spektral bilgileri birlikte kullanarak ayırt etmek için kullanılabilir.

Hiperspektral kameralar, birçok dalga boyuyla ilişkili dar bantlardan bilgi toplamaktadır. Geleneksel RGB kameralardan farklı olarak, hiperspektral sensörler 100 veya daha fazla veri kanalı üretebilmektedir. Örneğin, Şekil 1.1 düşük yoğunluklu kentsel ve kıyı ortamları üzerinde bir hava platformuna monte edilmiş bir kamera kullanılarak elde edilen üç boyutlu bir hiperspektral veri küpünü göstermektedir [2]. Bu veri küpü, farklı nesnelere toplanan spektral verileri içermektedir. Ayrıca, şekil beş nesnenin spektral imzalarını da göstermektedir. Her bir dalga boyunun gösterilen nesnelere hakkında farklı bilgiler sağladığı gözlemlenebilmektedir. Bu bilgiler ışığında, görüntüdeki nesnenin hangi malzemeden yapıldığı (örneğin; ağaç, asfalt, kumaş vb.) hakkında yorum yapmak mümkün olmaktadır.

Spektral imzayı oluşturan değer, spektral reflektans olarak isimlendirilmektedir. Bu değer, nesnelere her dalga boyu için yansıttığı enerjinin nesnelere gelen enerjiye oranından elde edilmektedir. Hiperspektral sensörler, 0.4 μm 'den 14 μm 'ye kadar olan dalga boylarını içeren elektromanyetik spektrumun bir bölümünde, yaklaşık 0.01 μm genişliğindeki dar bantlarda çalışmaktadır. Hiperspektral sensörler, uygulama alanlarına göre dört dalga boyu

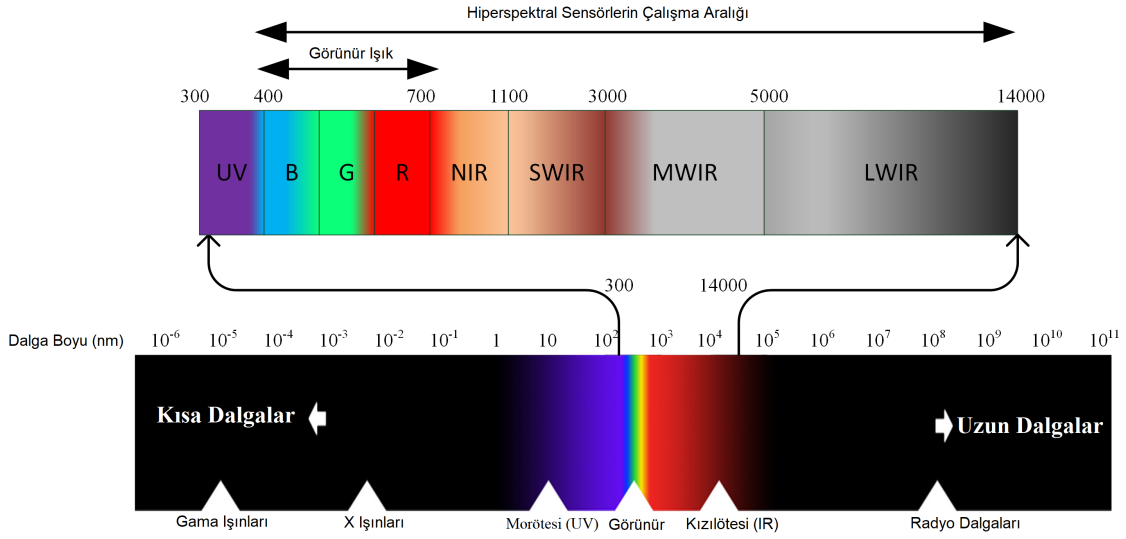


Şekil 1.1 Temiz spektral imzalara sahip hiperspektral veri küpü.

aralığında görüntü toplamak üzere tasarlanmıştır. Şekil 1.2'deki elektromanyetik spektrumda görülebileceği gibi, bu bölgeler şu şekilde listelenebilir:

- Görünür ve Yakın Kızılötesi (Visible and Near-infrared-VNIR, 0.4-1.1 μm),
- Kısa Dalga Kızılötesi (Short-wave infrared-SWIR, 1.1-3 μm),
- Orta Dalga Kızılötesi (Mid-wave infrared-MWIR, 3-5 μm),
- Uzun Dalga Kızılötesi (Long-wave infrared-LWIR, 5-14 μm),

HSG'ler, bir sahnenin uzamsal ve spektral açıdan zengin bilgilerini içermekte, bu da onları uzaktan algılama [3, 4], görüntü sınıflandırma [5, 6], ayrıştırma [7-9], bölütleme [10], tıbbi teşhis [11, 12] ve anomali tespiti [13] gibi birçok uygulama için kullanışlı hale getirmektedir. Ancak, gerçek dünya uygulamalarında, hiperspektral kameralar yaygın



Şekil 1.2 Hiperspektral sensörler için elektromanyetik spektrum bölgeleri.

kullanımını engelleyen bazı sınırlamalarla karşı karşıya kalmaktadır. Örneğin, düşük ışık koşullarında performansları önemli ölçüde azalmaktadır. Dış mekan verisi toplamak için genellikle açık hava ve güneş ışığı gerekmekte, bu da bazen günlerce beklemeyi veya daha uzun pozlama sürelerini gerektirmekte ve sonuç olarak veri toplama sürelerini uzatmaktadır. Örneğin, Şekil 1.3'te iç ve dış mekanlardan, hem kısa hem de uzun pozlama kullanılarak toplanan HSIDwRD veri kümesine [14] ait bazı örnekler sunulmaktadır. Kısa pozlama görüntülerine bakıldığında, gürültünün etkileri gözlemlenebilmektedir. Daha uzun pozlama süreleri ile çekilen görüntülerin daha temiz olduğu ve gürültü etkilerinin azaldığı görülmektedir. Bununla birlikte, uzun pozlama hareket içeren sahnelerde bulanıklık gibi ek sıkıntılara yol açabilmektedir. Görüntülerin net bir şekilde elde edilmesi için gürültü azaltma algoritmaları, bu zorlukların üstesinden gelmek için kritik önem taşımaktadır. Özellikle uzaktan algılamada, hiperspektral sensörler genellikle sensörler için zorlu çalışma ortamları sunan uçaklar, dronlar veya uydulara monte edilmektedir. Dolayısıyla, veri toplama sürecinde, atmosferik soğurma, sıcaklık, aydınlatma koşulları ve sensör arızaları gibi çeşitli faktörlerin neden olduğu gürültü ile HSG'ler kolayca kirlenebilmektedir. Yukarıda bahsedilen tüm etkiler, çevresel koşullar ve sensör arızaları gibi çeşitli gürültü türlerine neden olabilmektedir:

- i. Gauss gürültüsü (Gaussian noise-GN),
- ii. Çizgi gürültüsü (Stripe noise-SN),
- iii. Ölü piksel gürültüsü (Dead pixel noise-DN),
- iv. Dürtü gürültüsü (Impulse noise-IN),
- v. Yukarıda bahsedilen tüm gürültü türlerinin karışımı (Mixture noise),
- vi. Tanımlanamayan diğer gürültüler (Unknown noise),

GN tipik olarak görüntü elde etme ve iletimi sırasında hiperspektral sensörün termal gürültüsünden ve elektronik parazitlerden kaynaklanmaktadır. Çan şeklinde bir olasılık dağılım fonksiyonu ile karakterize edilmekte ve tüm piksel değerlerini eşit şekilde etkileyerek, görüntünün uzamsal veya spektral bilgisinde rastgele değişimlere neden olmaktadır. SN genellikle sensör dizisindeki tutarsızlıklardan, özellikle de uydularda kullanılan süpürge tipi (push-broom) sensörlerde görülen kalibrasyon hataları ile sensör kusurlarından kaynaklanmaktadır. Bu gürültü, görüntüde dikey veya yatay çizgiler olarak belirmekte, görüntünün bütünlüğünü bozmakta ve doğru yorumlamayı zorlaştırmaktadır. DN, hiperspektral sensördeki arızalı dedektör elemanlarından kaynaklanmaktadır. Bu pikseller ışığı tespit edememekte ve herhangi bir sinyal üretememekte, dolayısıyla görüntüde siyah veya beyaz noktalar olarak görünmekte ve birden fazla bantta oluşabilmektedir. Tuz-biber (salt-and-paper) gürültüsü olarak da bilinen IN gürültüsü, görüntüleme sürecindeki ani değişimler, anahtar hataları, veri iletiminde bit hataları veya hiperspektral kameranın elektronik devrelerindeki arızalar gibi nedenlerle ortaya çıkabilmektedir. Görüntüde tuz ve biberi andıran rastgele beyaz ve siyah pikseller olarak düzensiz bir yapıda görünmektedir. Ayrıca, HSG'deki her bant farklı türlerde ve seviyelerde gürültüye maruz kalabilmektedir [15]. Sonuç olarak, gürültü davranışı karmaşıktır ve görüntünün piksel değerlerinde rastgele değişimler, çizgi artefaktları, dağılmış ölü pikseller ve dürtü bozulmalarının bir kombinasyonunu sergilemektedir. Bu gürültü türlerini ve kaynaklarını anlamak, uzaktan algılama uygulamalarında etkili gürültü giderme ve görüntü iyileştirme tekniklerinin

geliştirilmesi için önem arz etmektedir. Böylece, görüntü kalitesi artırılmakta ve verinin doğru yorumlanması sağlanmaktadır.

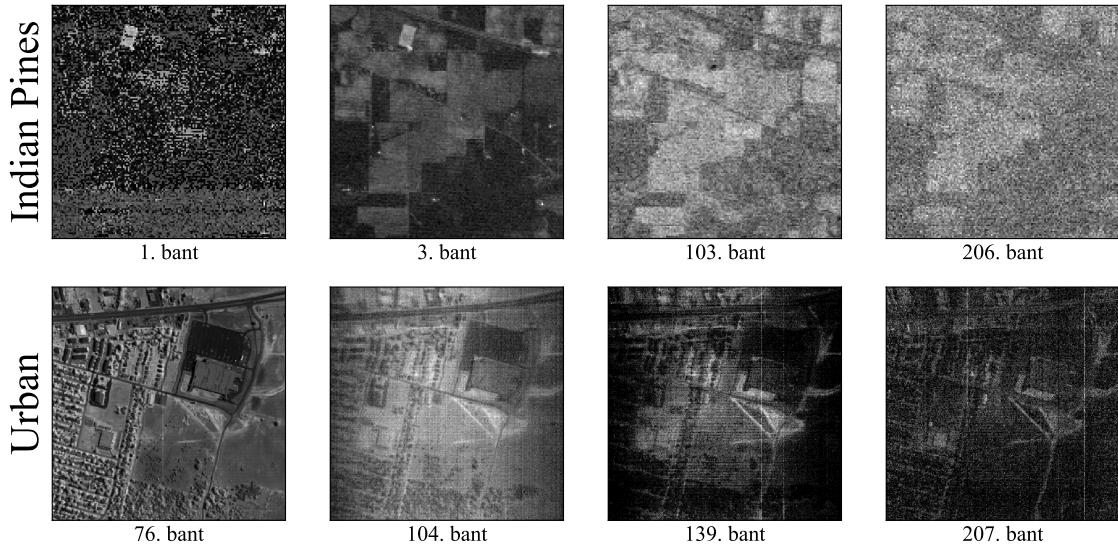
Ek olarak, hiperspektral görüntülerdeki gürültü uzamsal olarak ve farklı spektral bantlar arasında ilintili (correlated) olabilmektedir. Bu ilinti, hem içsel hem de dışsal çeşitli sebeplerden kaynaklanmaktadır. İçsel faktörler arasında sensör özellikleri, karanlık akım ve bozucu okuma gürültüsü (dark current and readout noise) [16] gibi sebepler ile sıcaklık dalgalanmalarının sensör performansını etkilemesi gibi çevresel etkiler bulunmaktadır. Dışsal faktörler, sinyal netliğini etkileyen atmosferik girişimler, emilim ve saçılma gibi unsurları içermektedir. Hatta veri toplama süreçleri, hareket artefaktları veya sensör kararsızlığı gibi etkenler de ilintili gürültüye katkıda bulunabilmektedir.



Şekil 1.3 Sahte RGB görüntüler, iç ve dış mekanlardan alınan uzun ve kısa pozlama HSG örnekleri (RGB olarak 664nm, 532nm, 488nm HSI bantları kullanılarak sentezlenmiştir). Kısa pozlama gürültülü görüntüler üstte gösterilirken, temiz uzun pozlama görüntüler altta gösterilmektedir.

Başka bir örnek olarak, Şekil 1.4, uzaktan algılamada yaygın olarak kullanılan iki veri kümesi olan Indian Pines ve Urban veri kümelerinin bantlarının gri tonlamalı temsillerini göstermektedir. Her bir bantı incelediğimizde, gürültünün hiperspektral görüntülerin bantlarını farklı şekilde etkilediğini görebilmekteyiz. Gürültü türü ve yoğunluğundaki değişiklikler her bantı farklı etkileyerek değerli bilgileri bozmaktadır. Sonuç olarak,

hiperspektral görüntülerdeki gürültü, görüntünün doğru yorumlanması (örneğin; uzaktan algılama için Şekil 1.4, kısa pozlama için Şekil 1.3) ve sınıflandırma ve hedef izleme gibi ardışık uygulamalar için önemli bir engel teşkil etmektedir. Bu nedenle, hiperspektral görüntülerde gürültü giderme, ardışık analizler için temel bir ön işleme adımı olarak kabul edilmektedir.



Şekil 1.4 Uzaktan algılama verilerinde mevcut olan doğal gürültüyü sergileyen, Indian Pines ve Urban veri kümelerinden örnek bantları gösteren gri tonlamalı görüntüler.

1.1. Tezin Kapsamı

Yukarıda bahsedildiği gibi, HSG'ler gürültü ile bozulduğunda, bu gürültü sınıflandırma, spektral ayrıştırma ve hedef tespiti gibi uygulamaların başarı oranlarını azaltmakta ve faydalı bilgilerin çıkarılmasını engellemektedir. Bu nedenle, gürültü giderme, HSG'lerden faydalı bilgilerin çıkarılması için önemli bir adım olarak görülmektedir. Gürültü giderme teknikleri, görüntülerdeki istenmeyen bileşenleri filtreleyerek HSG'lerden daha doğru ve güvenilir veriler elde etmemizi sağlamaktadır.

Son zamanlarda literatürde büyük ilgi gören HSG gürültü giderme konusu, çeşitli yöntemlerle ele alınmaktadır. En basit teknikler, HSG'lerin bantlarını ayrı ayrı ele alarak klasik 2B görüntüde gürültü giderme yöntemlerinin [17, 18] uyarlanmasına dayanmaktadır.

Ancak bu yöntemler yalnızca uzamsal bilgiyi dikkate aldıklarından ve bantlar arası bilgiyi göz ardı ettiklerinden sıklıkla spektral bozulmalara neden olmaktadır. Son dönemlerde, birçok HSG gürültü giderme modeli, HSG'lerin uzamsal-spektral ilintisine odaklanmaktadır [19–28]. Bu yöntemler, uzamsal-spektral bilgiyi etkin bir şekilde değerlendirerek daha yüksek doğruluk elde ederken, performansları bozulmuş HSG'nin önsel bilgilerinin (örneğin; gürültü varyansı, düşük kerte özelliği vb.) bilinmesine bağlı olmaktadır. Bu nedenle, bu tür yaklaşımların parametreleri her bir HSG için uygun şekilde ayarlanmalıdır. Ayrıca, bu yöntemler genellikle gürültü giderme sürecini karmaşık bir optimizasyon problemi olarak ele almakta ve bu problemin yinelemeli olarak çözülmesini gerektirmektedir. Bu yinelemeli yapılar, gürültü giderme sürecini zaman alıcı hale getirmektedir.

Son zamanlarda, derin sinir ağları (deep neural networks; DNNs) ile birlikte öğrenmeye dayalı stratejiler, geleneksel yöntemlere görece önemli ilerlemeler gösteren yeni bir HSG gürültü giderme teknikleri çağına öncülük etmektedir. DNN'ler, karmaşık mimarilerini kullanarak veriler içindeki karmaşık uzamsal ve spektral ilişkileri öğrenip temsil edebilmektedir. Bu veri odaklı modeller, gürültülü HSG'lerden temiz olanlara dönüşümü otonom olarak elde etmektedir. Derin öğrenme bağlamında, evrişimsel sinir ağları (convolutional neural networks; CNNs), verilerin uzamsal ve spektral özniteliklerini etkili bir şekilde yakalama yetenekleri nedeniyle HSG gürültü giderme için yaygın olarak kullanılmaktadır [29–34]. Özellikle, QRNN3D [32], 3B evrişim kullanarak yapısal uzamsal-spektral ilintiyi etkili bir şekilde entegre eden alternatif yönlü bir 3B yarı-tekrarlayan sinir ağıdır (3D quasi-recurrent neural network) ve yüksek restorasyon doğruluğu elde etmektedir.

CNN tabanlı gürültü giderme yöntemleri umut vaat etse de, iki önemli engelle karşı karşıya kalmaktadırlar:

- 1) CNN'ler genellikle HSG'nin uzamsal boyutundaki tüm kanal bazlı öznitelikleri eşit olarak ele almakta, bu da uzamsal-spektral alandaki kritik özniteliklerin kaybına yol açabilmektedir. Bu durum, belirli özniteliklerin benzersiz önemini göz ardı etmekte ve HSG'lerin etkili bir şekilde temsil edilmesini ve analiz edilmesini

engellemektedir. Yani, filtreler giriş sinyallerinin içeriğine göre otomatik olarak uyum sağlayamamaktadır. Aynı filtre grubu tüm görüntüyü dolaşarak her noktaya benzer şekilde işlem uygulamaktadır. Bu durum, görüntünün farklı bölgelerinin farklı özelliklere sahip olması halinde istenmeyen sonuçlara yol açabilmektedir.

- 2) CNN tabanlı yöntemler, küçük evrişim çekirdeklerini kullanarak HSG yamalarındaki uzun menzilli bağlamsal bilgileri etkili ve verimli bir şekilde yakalamakta zorlanmaktadır. Bu sınırlama, özellikle karmaşık desenlere sahip gürültülü görüntülerin analizinde engel teşkil edebilmektedir. Gürültü, yerel bilgileri gizleyebilmekte ve nesnelerdeki desenleri ayırt etmeyi zorlaştırabilmektedir. Görüntünün uzak kısımları arasındaki ilişkileri dikkate alan uzun menzilli öznitelikleri, yalnızca yerel öznitelik analizi ile görülemeyen anlamlı desenleri ve yapıları tanımlamak için önemli hale gelmektedir.

Ayrıca, reel gürültüden etkilenen HSG'lerin gürültüsünü gidermek, gerçek gürültü istatistiklerinin karmaşık (normal olmayan) dağılımı ve uzamsal ve spektral değişkenliği nedeniyle zorluk teşkil etmektedir. Bu tez çalışmasında, yukarıdaki sınırlamaları ele almak için, giriş verilerinin öz bilgilerini içeren dinamik ve iyi genelleştirilmiş gürültü giderme mimarilerini sunmayı amaçlamaktayız. Dinamik sinir ağları, derin öğrenmede gelişmekte olan bir alan olup [35, 36], test sırasında da yapılarını veya parametrelerini farklı girdilere uyarlayarak statik modellere göre belirgin bir avantaj sunmaktalar. Bu uyarlanabilirlik, hesaplama verimliliğini korurken doğruluğu, temsil gücünü ve genelleme yeteneğini artırmaktadır.

CNN'lerin karşılaştığı ilk zorluğu ele almak için, ilintili spektral ve uzaysal bilgiyi kullanan SM-CNN (Self-Modulating Convolutional Neural Network) olarak adlandırdığımız öz modülasyonlu bir evrişimsel sinir ağı sunmaktayız [37]. Modelin merkezinde, spektral öz modülasyonlu kalıntı bloğu (Spectral Self-Modulating Residual Block; SSMRB) adını verdiğimiz yeni bir blok yer almaktadır. Bu blok, ağın öznitelikleri, bitişik spektral bantlara göre uyarlamalı bir şekilde dönüştürmesine olanak tanımakta ve ağın karmaşık gürültüyü işleme yeteneğini artırmaktadır. Özellikle, SSMRB'nin eklenmesi, gürültü giderme ağıımızı,

her giriş HSG'sinin uzamsal-spektral bilgilerine göre gürültüyü bertaraf ederek tahmin edilen öznitelikleri uyarlayan dinamik bir ağa dönüştürmektedir.

İkinci olarak, CNN'ler için yukarıda bahsedilen her iki sınırlamayı da ele alan, daha iyi gürültü giderme performansı elde etmek amacıyla her iki yaklaşımın da güçlü yönlerinden yararlanan yeni bir hibrit CNN-Dönüştürücü (CNN-Transformer) modeli önermekteyiz. Gürültü, yerel bölgeleri bozan yüksek frekanslı değişimlere neden olarak gerçek görüntü içeriğini gizleyebilmektedir. Hem yerel detayları hem de uzamsal ve spektral uzak alanları inceleyerek, uzun menzilli bağımlılıkların ortaya çıkarılması, görüntünün daha kapsamlı bir şekilde anlaşılmasına katkıda bulunmaktadır. Öz-dikkat (self-attention) mekanizması ile Dönüştürücü'ler, uzun menzilli bağımlılıkları yakalama yetenekleri nedeniyle giderek daha fazla kullanılmaktadır. Ancak, Dönüştürücü ağları yerel öznitelikleri öğrenmek üzere eğitmek, HSG'ler için kolayca erişilemeyen büyük miktarda veriye ihtiyaç duymaktadır. Ayrıca, HSG'lerde bulunan çok sayıdaki bant sayısı, özellikle öz-dikkat hesaplamaları için Dönüştürücü'de fazla bellek kullanımına ve hesaplama karmaşıklığına yol açmaktadır. Bu zorlukları ele almak için, bu çalışmada her iki yaklaşımın güçlü yönlerini birleştiren yeni bir hibrit CNN-Dönüştürücü modeli olan 3B evrişim ağı ile Kanal-bazlı ve Spektral Dönüştürücü (Channel-wise and Spectral Transformer with 3D convolution network; CST3D) modelimizi sunmaktayız [38]. Modelimiz, iki öz-dikkat mekanizması içermektedir: farklı bantlar arasında global bilgiden yararlanan spektral öz-dikkat ve farklı 3B evrişim kanalları arasındaki bilgiyi entegre ederek uzamsal ve spektral detayları onaran kanal-bazlı öz-dikkat. Hem spektral hem de öznitelik kanalları için öğrenilebilir modülatörler ekleyerek, modelimizin ilgili bantlara öncelik verme, dikkat odağını keskinleştirme ve eğitimi dengeleme yeteneğini geliştirmekteyiz. Bu iyileştirmeler, gürültü giderme performansını artırmakta ve modelin yabancı verilere karşı genelleme yeteneğini yükseltmektedir. Ayrıca, basit kapılı doğrusal birimler (Simple Gated linear units; SGate) kullanarak eleman bazlı çarpma yoluyla doğrusalsızlığı sağlayan bloğumuzu sunmaktayız. Bu çarpmanın doğal doğrusalsızlığı, ek doğrusal olmayan aktivasyon fonksiyonlarını gereksiz kılmaktadır.

Ek olarak, HSG gürültü giderme işleminin kritik yönlerinden biri ağın eğitimidir. Ağa karmaşık dönüşümleri kavratılabilmek için, gözetimli öğrenme (supervised learning)

durumunda, gürültülü ve temiz verilerden oluşan geniş bir eğitim çifti kümesi gerekmektedir. Ancak, HSG'ler göz önüne alındığında, birçok eğitim çiftini toplamak kolay bir iş değildir. Literatürde yer alan bir çalışmada [14], yazarlar eğitim çiftleri için gerçek veriler toplamışlardır, ancak bu çiftlerin toplanması, özellikle uzaktan algılanan HSG'ler için ekstra çaba gerektiren ve pahalı bir süreçtir. Bu sebeple, HSG ağı eğitiminde yaygın bir yaklaşım, mevcut verilere yapay gürültü ekleyerek eğitim çiftleri oluşturmaktır [30–32, 34, 39, 40]. Bu tür yaklaşımların gürültülü test verilerinde iyi performans gösterebilmesi için, eğitim çiftleri oluşturulurken kullanılan yapay gürültünün test verilerindeki gürültüye benzer bir dağılıma sahip olması gerekmektedir. Başka bir yaklaşım ise, yalnızca gürültülü veriler kullanılarak ağın eğitildiği ve verilerdeki desenleri ve ilişkileri kendi başına tanımlayabildiği öz-gözetimli (self-supervised) öğrenmedir. Bu tez, dinamik DNN'ler kullanarak HSG'lerin restorasyonu için hem gözetimli hem de öz-gözetimli öğrenmenin potansiyeline odaklanmaktadır. Amaç, her iki öğrenme yaklaşımının güçlü yönlerinden yararlanarak yüksek kaliteli restorasyon elde etmektir. Bu iki öğrenme faydaları ve dezavantajları ele alınarak aşağıdaki gibi açıklanabilmektedir:

Gözetimli Öğrenme (Supervised Learning): Bu yaklaşım, DNN'yi eğitmek için gürültülü ve temiz HSG'lerden oluşan çiftler kullanmaktadır. Yitim fonksiyonu (loss function), bu veri odaklı modellerin gürültülü HSG'lerden temiz HSG'lere bir eşleme öğrenmesini otomatik olarak yönlendirmektedir. Ağın bu doğrusal olmayan eşlemeyi öğrenebilmesi için, çok sayıda gürültülü ve temiz veriden oluşan eğitim çiftlerine ihtiyaç duyulmaktadır. Avantajları ve dezavantajları şu şekilde sıralanabilir:

- Avantajlar:
 - Öz-gözetimli yöntemlere kıyasla potansiyel olarak daha yüksek doğruluk ve performans sunmaktadır.
 - Mevcut DNN mimarilerini gözetimli öğrenmeye uyarlamak daha kolaydır.
 - İyi kurulmuş eğitim prosedürleri ve değerlendirme metrikleri mevcuttur.
- Dezavantajlar:

- Büyük miktarda eğitim veri çifti ihtiyacı vardır, bu da temin edilmesi zor ve maliyetli olabilmektedir.
- Yapay olarak üretilmiş belirli gürültü türleri ve görüntü bozulmaları ile sınırlıdır.

Öz-gözetimli Öğrenme (Self-supervised Learning): Bu yaklaşım, temiz ve gürültülü veri çiftlerine ihtiyaç duymadan DNN'leri eğitmek için HSG'nin kendine özgü özelliklerini kullanan öğrenme tekniklerinden yararlanmaktadır. Bu öğrenme, temiz görüntülere ihtiyaç duymadan sadece gürültülü görüntüler kullanarak gürültü giderme modellerinin eğitimi için bir alternatif sunmaktadır. Olumlu ve olumsuz yönleri şu şekilde sıralanabilir:

- Avantajlar:

- Temiz veri ihtiyaçları yoktur, bu da onları daha esnek ve çeşitli senaryolara uygulanabilir hale getirmektedir.
- HSG'ye ait genel özellikleri ve kalıpları öğrenebilir, bu da potansiyel olarak görülmemiş veya modellenemeyen gürültü türlerine daha iyi genelleme yapmasını sağlamaktadır.

- Dezavantajlar:

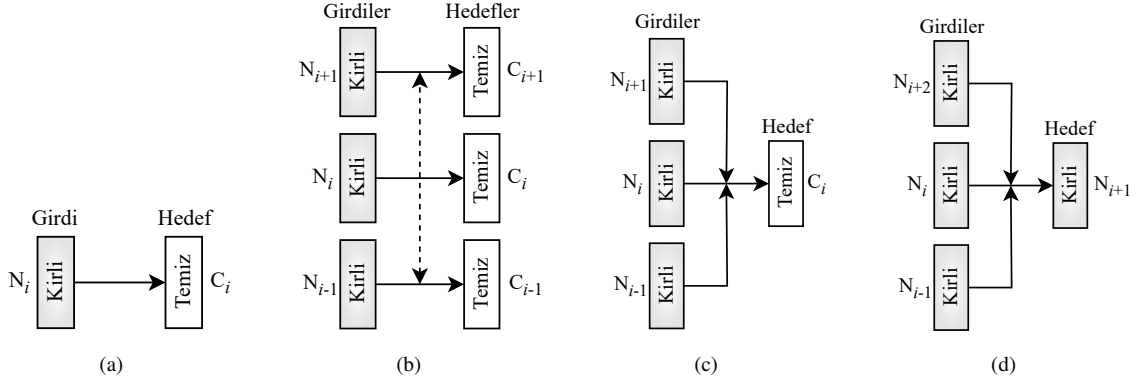
- Gözetimli öğrenmeye kıyasla ağırları bu şekilde eğitmek ve optimize etmek daha zor olabilmektedir.
- Bu öğrenme için yitim fonksiyonları ve gerekli diğer görevlerin dikkatli bir şekilde tasarlanması gerekmektedir.

Bunu müteakip, referans verilen literatürden elde edilen bilgilerden yararlanarak eğitim yöntemlerini analiz edilmekte ve önerilen dinamik modellerimizi eğitmek için kullanılan teknikleri detaylandırmaktayız. Bu tez kapsamında, mevcut bilgi birikimiyle entegre ederek öz-gözetimli yaklaşımımızın metodolojisini tanıtmaktayız.

1.1.1. HSG için Gürültü Giderme Ağlarının Öğrenme Stratejileri

Başarılı HSG gürültü giderme işleminin temeli, ağı etkili bir şekilde eğitmekten geçmektedir. Şekil 1.5(a),(b) ve (c) temsili şemalarda gösterildiği gibi, her biri kendi güçlü yönlerine ve ayrıntılarına sahip üç farklı eğitim yöntemi ortaya çıkmıştır. Yaygın bir yöntem, yukarıda bahsedildiği gibi, ağı temiz ve gürültülü çiftler kümesi kullanarak eğitmek olan gözetimli öğrenmedir. Bu öğrenme, ağın temiz görüntülerden öğrenmesini ve verilen bir girdi için doğru çıktıyı geliştirme anlayışını sağlamaktadır. İlk çalışmalarda, gri tonlama veya RGB görüntü gürültü giderme teknikleri, HSG görüntülerine giriş ve çıkış filtre boyutları değiştirilerek ve HSG'leri bant bant ele alacak şekilde uyarlanmıştır [29, 41]. Bu yaklaşım, tek banttan tek banda (single-to-single; S2S) öğrenme olarak adlandırılabilir. Ancak, bu 2B evrişim filtre tabanlı yaklaşımlar, HSG'lerde bol miktarda bulunan spektral bilgiyi tam olarak kullanamamaktadır. Sonraki çalışmalarda, hem spektral hem de uzamsal bilgiden yararlanmak için özel olarak tasarlanmış ağlar geliştirilmiştir [32, 33, 40, 42]. Bu modeller, derin ağları eğitmek için temiz ve gürültülü çiftlerden birden çok spektral bant kullanmakta ve bu metodoloji çok banttan çok banda (multi-to-multi; M2M) öğrenme olarak adlandırılabilir. Son zamanlarda, çok bant kullanarak orta bandı tahmin etmeyi amaçlayan yüksek performanslı bir gözetimli öğrenme yöntemi geliştirilmiştir (multi-to-single; M2S) [30, 39, 43]. Bu eğitim modeli, ağı bir bandın gürültüsünü gidermek için daha fazla bilgi yakalamasını ve tahmin performansını artırmasını sağlamaktadır. Bu tez çalışmasında, HSG'lerin gürültü giderilmesi için iki yeni ağ mimarisi sunmaktayız. İlk ağımız olan SM-CNN, M2S öğrenmeyi kullanarak dinamik öz-modülasyonlu bir gürültü giderici oluştururken, ikinci ağımız CST3D M2M öğrenmeyi hibrit bir CNN ve Dönüştürücü mimarisiyle birleştirerek hem yerel hem de küresel özellikleri dinamik olarak yakalamaktadır.

Daha önce değindiğimiz konuya geri dönersek, başka bir yaklaşım olan öz-gözetimli öğrenme ile ağ yalnızca gürültülü veriler üzerinde eğitilmekte ve eşleştirilmiş temiz-gürültülü örneklerle ihtiyaç duyulmamaktadır. Bu yöntem, ağı veri içindeki içsel desenleri ve ilişkileri keşfetmesine olanak tanımaktadır. Bu çalışmada, iki aşamalı bir



Şekil 1.5 HSG gürültü giderme için eğitim modellerinin görsel karşılaştırması. (a) Tek bantlı kullanarak karşılık gelen bantı tahmin etme (single-to-single; S2S), (b) Birden fazla bantı kullanarak birden fazla bantı tahmin etme (multi-to-single; M2M), (c) Birden fazla bantı kullanarak tek bantı tahmin etme (multi-to-single, M2S), (d) Önerdiğimiz kör bant öz-gözetimli (blind band self-supervised; BBSS) öğrenme.

öğrenme stratejisi önermekteyiz [44]. Öğrenme stratejimizin ilk aşaması, modeli gürültülü ve temiz veri çiftleri üzerinde eğitmek için Şekil 1.5'te gösterildiği gibi bir M2S veya M2M gözetimli öğrenme yaklaşımını kullanmayı içermektedir. Bu aşama, modelin verilerdeki modellenen yoğun gürültüyü (örneğin Gauss gürültüsü) öğrenmesi ve anlaması için gerekmektedir. Yukarıda bahsedildiği gibi, bu yaklaşım, eğitim çiftlerini oluşturmak için kullanılan yapay gürültünün test verilerindeki gürültü ile benzer bir dağılıma sahip olması durumunda etkili olmaktadır. Ancak, mevcut öğrenme tabanlı yöntemler genellikle Gauss gürültü modelleriyle sentezlenmiş eğitim çiftlerini kullanmakta, bu da test verilerindeki gürültü dağılımını doğru bir şekilde temsil etmeyebilmektedir. Sonuç olarak, bu durum görülmemiş gürültüler üzerinde optimal olmayan performansa yol açmaktadır.

Eğitimin ikinci aşamasında da, mevcut gözetimli öğrenme yöntemlerinin yukarıda belirtilen sınırlamasını, Noise2Noise [45, 46] ve Noise2Void [47] öğrenme stratejilerinden esinlenen yeni bir öz-gözetimli kalibrasyon yaklaşımı tanıtarak ele almaktayız. Bu yeni yaklaşım, temiz hedef veriye dayanmadan bilgi verici temsiller öğrenmek için verinin içsel yapısından yararlanmaktadır. Önerilen öz-gözetimli kalibrasyon, M2S öğrenmeye benzer şekilde ve temiz veriye ihtiyaç duymadan orta bantı tahmin etmek için birden fazla bantı kullanarak Şekil 1.5(d)'de gösterildiği gibi gerçekleştirilmektedir. Orta bantı tahmin etmek için komşu

bandı hedef olarak kullanılmaktadır. Ağın sadece kimlik eşlemesini (identity mapping) öğrenmesini önlemek için, hedef bandı girdi olarak hariç tutularak spektral bantlarda kör bir nokta oluşturmaktayız. Bu, modelimizin tahmin etmesi gereken banda doğrudan erişimi olmadığı anlamına gelmektedir. Bu nedenle, modelimize kör bant öz-gözetimli (Blind Band Self-Supervised; BBSS) öğrenme adını vermekteyiz. Birden fazla bandı kullanarak, modelimiz spektral verilerdeki karmaşık kalıpları ve ilişkileri yakalayabilmekte, böylece tahminin doğruluğunu artırabilmektedir. Ayrıca, yaklaşımımız esnek olup, farklı HSG verilerine kolayca uyarlanabilmektedir.

Özetleyecek olursak, ilk aşama, modeli yoğun gürültüyü öğrenmek için büyük bir veri kümesi üzerinde ön eğitimi içermektedir. Bu aşamayı, modeli belirli seyrek gürültüye uyarlamak için test verileri üzerinde öz-gözetimli kalibrasyon izlemektedir. Bu iki aşamalı yaklaşımı kullanarak, model ön eğitim aşamasında elde edilen bilgiden faydalanarak kalibrasyon aşamasında performans ve verimlilik artışı sağlamaktadır. Bu stratejinin, kullandığımız farklı modellerin doğruluğunu ve verimliliğini artırdığı bu çalışmada gösterilmektedir.

1.2. Katkılar

Bu tezin HSG gürültü giderme alanındaki ana katkıları şu şekilde özetlenebilir:

- HSI restorasyonu için mevcut gözetimli ve öz-gözetimli öğrenme yöntemleri incelenmektedir.
- HSG'lerin hem uzamsal hem de spektral bilgilerini işleyen, öznelik modülasyon katmanları aracılığıyla giriş komşu spektral bantlarını uyarlanabilir bir şekilde kullanan yeni bir dinamik öz-modülasyonlu evrimsel sinir ağı (SM-CNN) yapısı önerilmektedir. Öz-modülasyon, bir ağın performansını iyileştirmek veya farklı gürültü ve koşullara otonom olarak uyum sağlamak için kendi giriş verilerini nasıl modüle edeceğini öğrenmesine olanak tanıyan bir tekniktir. Bu model, ağın

girişteki bilginin bağlamına göre içsel temsillerini dinamik olarak ayarlayabilmesini sağlamakta, dolayısıyla daha verimli ve etkili öğrenmeye yol açmaktadır.

- SM-CNN modelimizin çekirdeğinde, spektral öz-modülasyonlu kalıntı bloğu (Spectral Self-Modulating Residual Block; SSMRB) adını verdiğimiz yeni bir bileşen bulunmaktadır. Bu bileşen, ağın bitişik spektral verilere dayanarak öznitelikleri ayarlamasına olanak tanımakta ve eğitim kümesine aşırı uyum sağlamasını engelleyerek karmaşık gerçek gürültüyü işleme yeteneğini arttırmaktadır.
 - Önerilen SSMRB katmanı, modelimizi her bir giriş HSG'nin uzamsal ve spektral bilgilerine göre tahmin edilen özniteliklerini gürültü giderme süreci boyunca uyarlayan dinamik bir gürültü giderme ağı haline getirmektedir. Bu yöntem, ağımızın öğrenilen ağırlıklarının tahmin etme (forward propagation) sırasında gerçek zamanlı olarak kendilerini uzamsal-spektral bilgileri dikkate alarak uyarlayabileceğini göstermektedir.
 - Bu modelimiz, herhangi bir ek parametre ayarına gerek kalmadan hem spektral bilgiyi hem de görüntülerin yerel detaylarını koruyarak, önemli ölçüde daha kesin ve net sonuçlar üretmektedir.
- Tez kapsamında HSG'lerden gürültüyü giderirken uzamsal ve spektral bilgiyi korumak için CNN ve Dönüştürücü modellerini birleştiren 3B evrişim ağı ile Kanal-bazlı ve Spektral Dönüştürücü (Channel-wise and Spectral Transformer with 3D convolution network; CST3D) adı verilen yeni bir hibrit model önerilmektedir. Bu önerilen model, girdiye bağımlı uyarlanabilir bir şekilde hem yerel özniteliklerin ilintileri hem de global özniteliklerin bağımlılıkları yakalayarak HSG gürültü giderme performansını arttırmaktadır.
 - Bildiğimiz kadarıyla, CST3D öğrenilebilir modülatörlerle donatılmış kanal ve spektral öz-dikkatleri eş zamanlı olarak kullanan ve ardından bu öznitelikleri derinlemesine 3B evrişim yoluyla entegre eden ilk modeldir.

- Spektral öz-dikkat ve kanal-bazlı öz-dikkat paralel olarak kullanılmaktadır. Bu kullanım, modelin farklı spektral kanalları arasındaki bilgiyi dahil ederken, birden fazla banttan global bilgiyi etkili bir şekilde modellemesine yardımcı olmaktadır. Öz-dikkat, bir ağın girdi verilerinin belirli bölümlerine odaklanarak gürültü kalıplarını veya ilgili öznitelikleri öğrenmesine olanak tanıyan bir mekanizmadır. Bu mekanizma, ağın anlamlı bilgileri çıkarmasını ve doğru tahminler yapmasını sağlamaktadır. Öz-dikkat, ağın giriş dizisinin farklı unsurlarına farklı önem düzeyleri atmasını, uzun menzilli bağımlılıkları yakalamasını ve genel performansını artırmasını mümkün kılmaktadır. Dikkat mekanizmalarının yüksek skorlar alarak gürültü seviyelerini azalttığı ve hem uzamsal hem de spektral alanlarda bilgi netliğini artırdığı analizlerle gösterilmektedir.
- Gürültü giderme performansını artırmak ve eğitim sürecini istikrarlı sürdürmek için kanal-bazlı ve spektral öğrenilebilir restorasyon modülatörleri önerilmektedir. Araştırmamız, modülatörlerin modelimize dahil edilmesinin temiz bant önceliklendirmesini kolaylaştırdığını, dikkat dağılımının netliğini artırdığını ve eğitim yetim değerlerini azalttığını göstermektedir. Bu bulgular, modelin performansını ve genelleme yeteneklerini iyileştirmeye yönelik kolektif işaretler sunmaktadır.
- Basit kapılı doğrusal birim (Simple Gated linear units; SGate) adı verilen basitleştirilmiş bir ileri besleme katmanı önerilmektedir. Bu birimin eleman bazında çarpmadan kaynaklanan doğal doğrusalsızlığı, doğrusal olmayan ek aktivasyon fonksiyonlarına olan ihtiyacı ortadan kaldırmaktadır.
- Ön eğitim ve öz-gözetimli kalibrasyonu içeren iki aşamalı bir öğrenme stratejisi önerilmektedir. Sürecin ilk aşaması, temiz hedeflerle büyük bir veri kümesi üzerinde modelin eğitilmesini içermektedir. Bu eğitim, modelin özellikle yoğun gürültü olmak üzere modellenilebilir yapay gürültüyle nasıl başa çıkacağını öğrenmesini sağlamaktadır. Ön eğitim aşamasının ardından, yalnızca gürültülü veriler kullanarak öz-gözetimli kalibrasyon uygulanmaktadır. Bu kalibrasyon adımı, modelin

verilerde mevcut olan modellenemeyen gürültü kalıplarına uyum sağlamasına olanak sunmaktadır.

- Öz-gözetimli kalibrasyonda, orta bantı tahmin etmek için komşu bant hedef olarak kullanılmaktadır. Ağın sadece kimlik eşlemesini (identity mapping) öğrenmesini önlemek için, hedef bant girdiden çıkartılarak spektral bantlarda kör bir nokta oluşturulmaktadır. Bu nedenle, modelimize kör bant öz-gözetimli (Blind Band Self-Supervised; BBSS) öğrenme adı verilmektedir.
- Birden fazla spektral bantı kullanarak, modelimizin spektral verilerdeki daha karmaşık kalıpları ve ilişkileri yakalaması ve tahmin performansının artması sağlanmaktadır.
- Önerilen yöntemlerimizi kapsamlı bir şekilde anlamak ve değerlendirmek için derinlemesine analizler ve bileşen işlevsellik deneyleri gerçekleştirilmektedir.
- Literatürde önerilen modeller ve kendi önerdiğimiz modeller birçok deneyle incelenmektedir.
- Her bir yaklaşımın güçlü ve zayıf yönleri analiz edilmekte, gelecekteki araştırma yönleri belirlenmektedir.

Bu tez, hem gözetimli hem de öz-gözetimli öğrenme yaklaşımlarının kapsamlı bir değerlendirmesini yapan DNN'ler kullanarak HSG restorasyonunun ilerlemesine katkıda bulunmayı amaçlamaktadır. Bulgular, gelecekteki HSG restorasyon yöntemlerinin geliştirilmesi için değerli bilgiler sağlayacak ve bu yöntemlerin doğru, verimli ve çeşitli senaryolara uyarlanabilir olmasını sağlayacaktır.

1.2.1. Yayınlar

Yukarıdaki katkıların bir kısmı aşağıdaki çalışmalarımızda yer almakta veya yayımlanmak üzere değerlendirilmektedir:

- Orhan Torun, Seniha Esen Yuksel, Erkut Erdem, Nevrez Imamoglu, and Aykut Erdem. Hyperspectral image denoising via self-modulating convolutional neural networks. *Signal Process.*, 214:109248, 2024.
- Orhan Torun, Seniha Esen Yuksel, Erkut Erdem, and Aykut Erdem. Self-supervised calibration of the denoising networks for HSI. In *IEEE IGARSS*, 2024.
- Orhan Torun, Seniha Esen Yuksel, Erkut Erdem, and Aykut Erdem. Dual-attention hybrid CNN-Transformer for HSI denoising. Değerlendirme aşamasında.

1.2.2. Açık Kaynak Yazılım Katkıları

Ayrıca aşağıdaki yazılımları kullanıma sunarak açık kaynak topluluğuna katkıda bulunmaktayız:

- SM-CNN modelimizin kodu <https://github.com/orhan-t/SM-CNN> adresinden ulaşılabilir haldedir.
- CST3D modelimizin kodu <https://github.com/orhan-t/CST3D> adresinde ulaşılabilir olacaktır.

1.3. Tezin Organizasyonu

Tezin organizasyonu aşağıda maddeler halinde sunulmaktadır:

- Bölüm 1, motivasyonumuzu, katkılarımızı ve tezin kapsamını sunmaktadır.
- Bölüm 2, tezin konusu ile ilgili geçmişe dair bilgileri ve temel kavramları ele alarak okuyucuya gerekli altyapıyı kazandırmaktadır.
- Bölüm 3, hem geleneksel yöntemlere hem de derin öğrenme yaklaşımlarına ait ilgili çalışmaları ayrıntılı olarak inceleyerek okuyucuya bu alanlardaki mevcut bilgi birikimini sunmaktadır.

- Bölüm 4, gürültüyü gidermede oldukça başarılı olan modellerimizi sunmaktadır. Bu modeller, giriş verilerinin kendine has özniteliklerini kullanarak ve öz-gözetimli öğrenme stratejilerinden faydalanarak, derin ağa daha önce karşılaşılmamış gürültüye karşı daha güçlü performans göstermesi için ince ayar yapmaktadır.
- Bölüm 5, önerilen yöntemlerin deneysel sonuçlarını göstererek literatürdeki gürültü giderme modelleriyle detaylı bir karşılaştırma sunmaktadır.
- Bölüm 6, bu tez çalışmasının özetini ve geleceğe yönelik olası araştırma alanlarını sunmaktadır.

2. TEMEL BİLGİLER

Bu bölüm, tezi anlamak için gerekli olan temel bilgileri sunmaktadır. İlk olarak, HSG gürültü modelini tanıtmıştır. Daha sonra, birçok geleneksel ve derin öğrenme yaklaşımına ilham veren bir özellik olan HSG'lerin düşük kerteli (low-rankness) yapısına değinilmiştir. Hibrit CNN ve Dönüştürücü modelimiz için bağlam sağlamak amacıyla, Dönüştürücü mimarisinin temel ilkeleri tanıtmıştır. Son olarak, önerdiğimiz öz-gözetimli eğitim modelinin ve mevcut literatürdeki yerinin anlaşılması açısından öz-gözetim öğrenmedeki önemli olan temel yenilikleri özetlenmiştir.

2.1. Hiperspektral Gürültü Modeli

HSG gürültü modeli oluşturmak için, \mathbf{X} ve \mathbf{Y} 'nin Denklem 1'de ve Denklem 2'de gözüktüğü gibi sırasıyla temiz ve gürültülü gözlemler olduğunu kabul edelim:

$$\mathbf{X} = [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_i, \dots, \mathbf{X}_B] \in \mathbb{R}^{M \times N \times B} \quad (1)$$

$$\mathbf{Y} = [\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_i, \dots, \mathbf{Y}_B] \in \mathbb{R}^{M \times N \times B} \quad (2)$$

Yukarıdaki denklemlerde yer alan \mathbf{X}_i ve \mathbf{Y}_i sırasıyla temiz ve gürültülü gözlemlerin i . bandını, $M \times N$ görüntünün uzamsal boyutlarını, B ise spektral bant sayısını göstermektedir. Bazı bantları etkileyen toplanır seyrek gürültü (yani, ölü piksel gürültüsü, şerit gürültüsü, darbe gürültüsü vb.), $\mathbf{S} \in \mathbb{R}^{M \times N \times B}$, ve tüm bantları etkileyen yoğun gürültü (yani, Gauss gürültüsü), $\mathbf{N} \in \mathbb{R}^{M \times N \times B}$, tarafından bozulan bir HSG aşağıdaki gibi doğrusal olarak modellenabilir:

$$\mathbf{Y} = \mathbf{X} + \mathbf{S} + \mathbf{N} \quad (3)$$


Temelde, HSG gürültü giderme süreci, \mathbf{Y} gürültülü gözleminde \mathbf{X} 'in bir kestirimi olan $\hat{\mathbf{X}} \in \mathbb{R}^{M \times N \times B}$ 'yi tahmin etme problemidir.

2.2. Hiperspektral Görüntülerin Düşük Kerte Özellikleri

HSG'nin yapısal düşük kerte (low-rank) özelliklerinden ilham alarak, gürültü giderme, süper çözünürlük, boyut azaltma ve malzeme tanımlama gibi uygulamalar için çeşitli yöntemler geliştirilmiştir. Bölüm-3.'te tartışıldığı üzere, bu yaklaşımlar HSG'lerin kalitesini artırmak ve analizini iyileştirmek için hem klasik hem de derin öğrenme çerçevelerinden yararlanmaktadır. Bu tez boyunca HSG'nin düşük kerte özelliklerini kullanan yöntemleri tartışacağımızdan, bu bölümde düşük kerte özelliğinin teorik temelini sunmaktayız.

Şekil 2.1 temiz bir HSG parçasının veri küpünü göstermektedir. Orijinal bir HSG küpü X ile temsil edilirse, boyutları $M \times N \times B$ olmaktadır. Burada, M görüntü yüksekliğini, N görüntü genişliğini ve B spektral bantların sayısını belirtmektedir. Şekilde gösterildiği gibi, uzamsal merkezi i, j konumunda olan $q \times q \times B$ boyutlarında bir $\mathbf{p}_{i,j}$ yaması seçildiğini varsayalım. Daha sonra, $\mathbf{p}_{i,j}$ yamasının k . bandının sütunları sözlüksel (lexicographical) sıraya göre düzenlenerek \mathbb{R}^{q^2} boyutunda bir vektör $\mathbf{p}_{i,j,k}$ olarak ifade edilebilmekte, bu vektörler ile $q^2 \times B$ boyutlarında $2B$ bir matris $\mathbf{P}_{i,j}$ şu şekilde elde edilmektedir:

$$\mathbf{P}_{i,j} = (\mathbf{p}_{i,j,1}, \mathbf{p}_{i,j,2}, \dots, \mathbf{p}_{i,j,B}) \quad (4)$$



Şekil 2.1 Bir HSG yamasından düşük kerte bir matris oluşturma sürecinin gösterimi.

HSG'lerde her bir spektral imza, lineer spektral karıştırma modeli olarak bilinen az sayıdaki saf spektral imzaların (endmembers) lineer bir kombinasyonu ile temsil edilebilmektedir. Dolayısıyla spektral imzalar arasında, diğer bir deyişle $\mathbf{P}_{i,j}$ matrisinin satırları arasında, yüksek ilinti mevcuttur. HSG yaması için saf spektral imzaların sayısında bir üst sınır

olan r varsayıldığında, $\mathbf{P}_{i,j}$ şu şekilde ifade edilebilmektedir: $\mathbf{P}_{i,j} = \mathbf{A}\mathbf{H}^T$. Burada, $\mathbf{H} \in \mathbb{R}_+^{B \times r}$ sütunları saf spektral imzaları temsil eden matristir ve $\mathbf{A} \in \mathbb{R}_+^{q^2 \times r}$ bolluk (abundance) matrisidir. Saf spektral imzaların sayısının üst sınır değeri olan r , nispeten küçük olduğundan, $\mathbf{P}_{i,j}$ 'nin kertesı sınırlıdır (yani, $\text{kerte}(\mathbf{P}_{i,j}) \leq r$) ve bu da $\mathbf{P}_{i,j}$ matrisinin düşük kerte özelliğini göstermektedir.

2.3. Görüntü Dönüştürücü

Görüntü Dönüştürücü (Vision Transformer; ViT), Dönüştürücü tabanlı doğal dil işleme (natural language processing; NLP) modellerinin başarısından yararlanan, bilgisayarla görmeye yönelik yenilikçi bir yaklaşımdır [48]. ViT'nin temel fikri, görsel veriyi bir dizi sembol (token) olarak temsil etmektir. Bu sembollerin her biri, girdi görüntüsünün bir yamasına karşılık gelmektedir. Bu yamalar, verimli ve etkili şekilde bir Dönüştürücü mimarisi tarafından işlenmektedir.

Geleneksel CNN'lerin sabit boyutlu alıcı alanlar üzerinde çalışması ve öznitelik çıkarımı için evrimsel işlemlerine dayanmasına karşın, ViT, yamalar arasındaki global bağımlılıkları ve uzamsal ilişkileri yakalamak için öz-dikkat mekanizmalarını kullanmaktadır [48]. Bu mekanizmalar, modelin çoklu ölçeklerde öznitelik öğrenip çıkarmasına ve giriş verilerindeki farklı uzamsal içeriklerine uyum sağlamasına olanak tanımaktadır.

Ayrıca, ViT modelleri, görüntü sınıflandırma [49], nesne tespiti [50] ve görüntü oluşturma [51] gibi çeşitli görsel uygulamalarda güçlü performans sergilemektedirler. Bu başarılar, Dönüştürücü mimarisinin görsel verilerde uzun menzilli bağımlılıkları ve ince ayrıntıları yakalama yeteneğine atfedilmekte, bu da yukarıda bahsedilen uygulamalar için kritik öneme sahip olmaktadır.

ViT'yi görsel verilere uygulanırken karşılaşılan temel zorluklardan biri, yama dizisini işlemek için gereken yüksek parametre sayısı ve hesaplama maliyetidir. Bu sorunu çözmek için, yerel öz-dikkat mekanizmalarını kullanma [52, 53], yama boyutunu küçültme [54] ve yüksek boyutlara sahip uzamsal alanda değil de kanal bazında öz-dikkat gerçekleştirme [55–57] gibi çeşitli yaklaşımlar önerilmiştir.

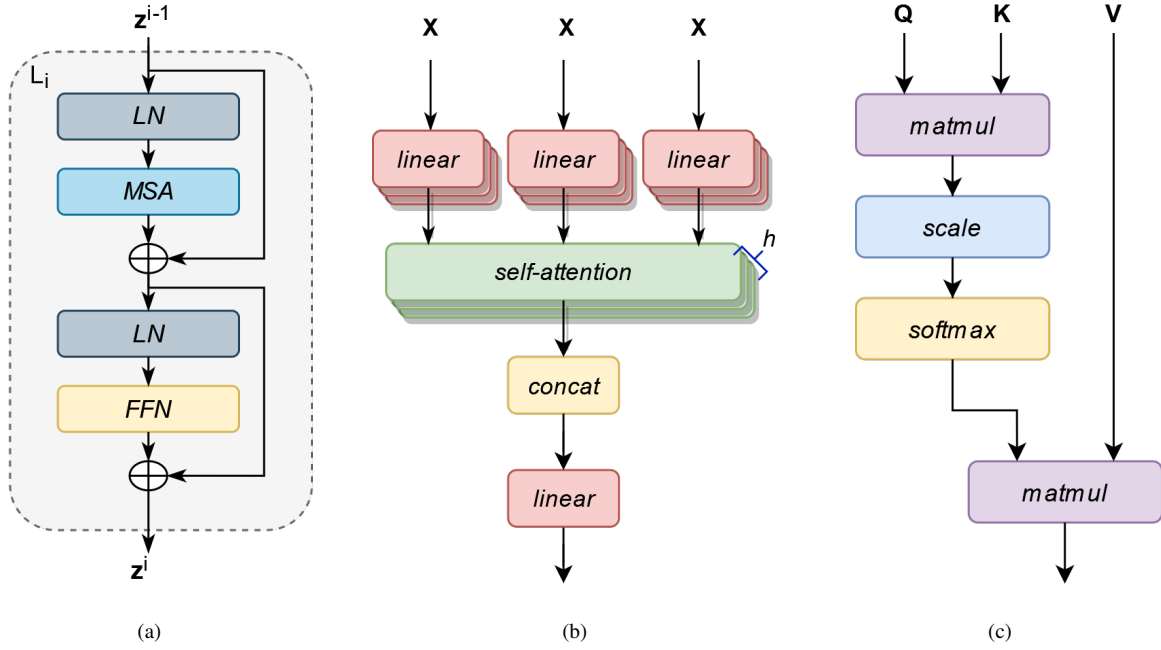
Özetle, ViT, Dönüştürücü tabanlı NLP modellerinin başarısından yararlanan ve bilgisayarla görme alanında umut vaat eden bir yaklaşımdır. Görsel verileri yama dizisi olarak temsil ederek ve öz-dikkat mekanizmalarını kullanarak, ViT modelleri giriş verilerindeki global bağımlılıkları ve uzamsal ilişkileri yakalayabilmektedir, bu da çeşitli görsel görevlerde güçlü performans sağlamaktadır. Ancak, ViT'yi büyük ölçekli görsel verilere uygulamanın hesaplama zorluklarını ele almak için daha fazla araştırma yapılmasına ihtiyaç duyulmaktadır.

Şekil 2.2(a)'da bir girdi özniteliğini (z^{i-1}) bir sonraki katman özniteliğine (z^i) dönüştüren tek bir Dönüştürücü kodlayıcısının yapısı (L_i) verilmektedir. Dönüştürücü ağı bu kodlayıcının arka arkaya eklenmesiyle oluşturulmaktadır. Şekilde gösterildiği gibi, Dönüştürücü kodlayıcı aşağıdaki yapılardan oluşmaktadır:

- *Katman Normalizasyonu (Layer Normalization; LN)*: Bu katman, gradyan kaybolmasını önlemek ve modelin öğrenme yeteneklerini iyileştirmek ve hızlandırmak için kullanılmaktadır.
- *Çoklu Öz-Dikkat (Multihead Self-Attention; MSA) Mekanizması*: Şekil 2.2(b)'de gösterildiği gibi, Dönüştürücü'nün en önemli bileşeni olan bu mekanizma, giriş dizisi elemanları arasındaki global bağımlılıkları yakalamak için kullanılmaktadır.
- *İleri Beslemeli Sinir Ağı (Feedforward Neural Network; FFN)*: Kodlanmış öznitelikleri, doğrusal olmayan dönüşüme tabi tutmak için kullanılmaktadır.
- *Katmanlar Arasındaki Atlama Bağlantıları (Skip Connections; SC)*: Bilgi akışını iyileştirmek ve gradyan kaybolmasını önlemek için katmanlar arasında atlama bağlantıları kullanılmaktadır.

2.3.1. Öz-Dikkat

Öz-dikkat (self-attention; SA) mekanizması, ViT mimarisinin temel bir bileşenidir. Bu mekanizma, modelin giriş görüntüsünün farklı bölümlerine aynı anda dikkat etmesini ve



Şekil 2.2 Dönüştürücü yapısı ve dikkat mekanizmasının temsili gösterimi (a) Dönüştürücü kodlayıcı bloğu, (b) Çoklu öz-dikkat (Multihead self-attention; MSA), (c) Öz-dikkat (Self-attention; SA).

giriş özellikleri arasındaki global bağımlılıkları öğrenmesini sağlamaktadır. Bu bağımlılıklar, giriş öznitelik haritasındaki farklı konumlar arasındaki dikkat ağırlıklarını hesaplayarak gerçekleştirilmektedir. ViT'deki öz-dikkat mekanizması, dil modeli için geliştirilmiş standart Dönüştürücü mimarisine [48] benzerlik göstermektedir. İlk olarak, giriş görüntüsü bir dizi yamaya bölünür ve her bir yama D boyutunda bir vektör olarak temsil edilmektedir. Bu yamalar, çoklu öz-dikkatin birden fazla katmanına beslenmekte ve her bir öz-dikkat katmanı D 'nin farklı bir alt uzayında yamalar arasındaki dikkat ağırlıklarını hesaplamaktadır.

Dikkat ağırlıkları, ölçekli nokta çarpım dikkat işlevi kullanılarak hesaplanmaktadır. Bu işlevde, gradyan patlamasının önüne geçmek amacıyla yamalar arasındaki nokta çarpımı alt uzay boyutunun kareköküyle ölçeklendirilmektedir. Dikkat ağırlıkları daha sonra yamaların ağırlıklı toplamını hesaplamak için kullanılmakta ve bu toplam ileri besleme ağının girdisi olarak kullanılmaktadır.

ViT'deki öz-dikkat mekanizmasının, girdi görüntüsündeki uzun menzilli bağımlılıkları etkili bir şekilde yakaladığı ve modelin yaptığı işlev için daha bilgilendirici öznitelikler

öğrenmesine izin verdiği gösterilmiştir [49].

Öz-dikkat (SA) mekanizmasının yapısı Şekil 2.2(c)'de gösterilmektedir. Şekilde yer alan “matmul” matris çarpımını, “scale” ölçeklendirmeyi ve “softmax” düzgeli üstel fonksiyonu temsil etmektedir. $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\} \in \mathbb{R}^{N \times d_{model}}$ şeklinde bir giriş dizisi verildiğinde, burada d_{model} vektörlerin boyutunu temsil eder, öz-dikkat mekanizması girdilerin ağırlıklı toplamını aşağıdaki gibi hesaplamaktadır:

$$SA(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax} \left(\frac{\mathbf{Q}\mathbf{K}^\top}{\sqrt{d_k}} \right) \mathbf{V} \quad (5)$$

Burada, $\mathbf{Q} = \mathbf{X}\mathbf{W}_Q$, $\mathbf{K} = \mathbf{X}\mathbf{W}_K$ ve $\mathbf{V} = \mathbf{X}\mathbf{W}_V$ sırasıyla sorgu (query), anahtar (key) ve değer (value) matrisidir. Öğrenilebilir ağırlık matrisleri olan \mathbf{W}_Q , \mathbf{W}_K , $\mathbf{W}_V \in \mathbb{R}^{d_{model} \times d_k}$, burada d_k gizli katmanın boyutudur, girdiyi sırasıyla sorgu, anahtar ve değer matrislerine doğrusal olarak çevirmektedir. Denklem 5'deki ifade, sorgu ve anahtar matrisleri arasındaki benzerlikleri (yani giriş dizileri arasındaki benzerlikleri) ölçekli nokta çarpımı ile basitçe hesaplamaktadır. Ardından, bu benzerlikleri bir olasılık dağılımı olarak elde etmek için bir düzgeli üstel fonksiyonu işlevi uygulanmaktadır. Bu işlem sayesinde benzerlikler 0 ila 1 arasındaki değerlerle ifade edilebilir hale gelmektedir. Bu benzerlik olasılık değerleri, değer matrisinin hangi bölümlerine dikkatin artacağını göstermektedir. Olasılık değerinin 1'e yakın kısımları, değer matrisinde ilgili yerlere daha fazla dikkat edileceği anlamına gelirken, 0'a yakın kısımları ise daha az dikkat edileceği kısımları göstermektedir.

Dönüştürücü'nün öz-dikkat mekanizması, bir bilgi işleme ve çekme sistemi modeli olarak düşünülebilir. İçerik tabanlı bir bilgi çekme sistemine benzer şekilde çalışır ve aktif olarak bilgi sorgulama süreciyle paralellik göstermektedir. Bir kütüphane bilgi çekme sistemi örnek olarak düşünüldüğünde, *sorgu*, aranmak istenen kaynağın niteleyici özelliklerine (örneğin: başlıklar, açıklamalar) karşılık gelmekte ve kütüphanedeki tüm kaynaklar için bir bilgi deposunda saklanan *anahtarlarla* eşleştirilmektedir. *Sorgu* ile *anahtarları* karşılaştırmaktan elde edilen dikkat skorları, aranmak istenen kaynağın alaka düzeyini ve önemini belirlemektedir. Daha sonra, bu anahtarlarla ilişkili *değerler*, dikkat puanlarına göre

toplanmakta veya ağırlıklandırılmakta ve sonuç olarak orijinal *sorguya* en iyi uyan kaynaklar (*değerler*) sıralanmaktadır. Görüntüler için yapılan da bu sisteme benzerlik göstermekte ve tüm pikseller arasındaki ilişkilere bakılarak girdi bağımlı ve öğrenilebilir sorgu, anahtar ve değer matrisleri oluşturulmaktadır. Böylece yapılan uygulamaya göre görüntüdeki tüm piksellerin ilişkilerine bakılarak önem sıralamaları belirlenmektedir.

2.3.2. Çoklu Öz-Dikkat

Çoklu öz-dikkat (MSA) bloğu, Şekil 2.2(b)'de gösterildiği gibi, paralel olarak birden fazla **Q**, **K**, and **V** matris seti içerir ve çoklu öz-dikkat değerlerini hesaplamak için her bir set Denklem 5'te verilen aynı SA sürecini kullanmaktadır. Daha sonra, paralel hesaplanan her SA sonucu birleştirilmektedir (şekilde gösterilen "concat" bloğu). Bu süreç aşağıdaki denklemde verildiği ifade edilmektedir:

$$\text{MSA}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(\text{SA}_1, \text{SA}_2, \dots, \text{SA}_h) \mathbf{W}_o \quad (6)$$

Burada, h katman sayısını temsil eder ve $\mathbf{W}_o \in \mathbb{R}^{d_{model} \times d_{model}}$ birleşik (concatenated) öz-dikkat (SA) sonuçlarını giriş boyutuna indirgeyen öğrenilebilir ağırlık matrisidir. Şekil 2.2(b)'de bu matris ve diğerleri doğrusal olarak temsil edilmektedir.

Özetle, öz-dikkat mekanizması, her pikselin tüm görüntüden bilgi almasını sağlayarak, evrimsel yerel filtrelerin sıklıkla gözden kaçırdığı önemli uzun menzilli bağlantıları ve global bağımlılıkları yakalamaktadır. Ayrıca, öz-dikkat görüntünün farklı bölgeleri arasındaki ilişkileri analiz ederek içeriğe duyarlı öznitelikler üretmektedir. Dahası, çoklu öz-dikkat mekanizması, bu temel üzerine inşa edilerek, her biri farklı öğrenilebilir parametrelere sahip birden fazla eş zamanlı işlemi paralel olarak yürütmektedir. Görüntünün farklı bölümlerine aynı anda odaklanması, verilerin daha zengin ve daha rafine bir şekilde anlaşılmasını sağlamakta ve ezberlemeyi (over-fitting) önleyerek eğitim sürecini stabilize etmektedir.

CNN'lere benzer şekilde, Dönüştürücü'ler de daha yaygın bir yaklaşım olan gözetimli öğrenme ile eğitilebilir. Ayrıca, bir sonraki bölümde açıklanan öz-gözetimli yöntemler ile de eğitim gerçekleştirilebilir.

2.4. Yenilikçi Yaklaşımlar: Öz-Gözetimli Öğrenme

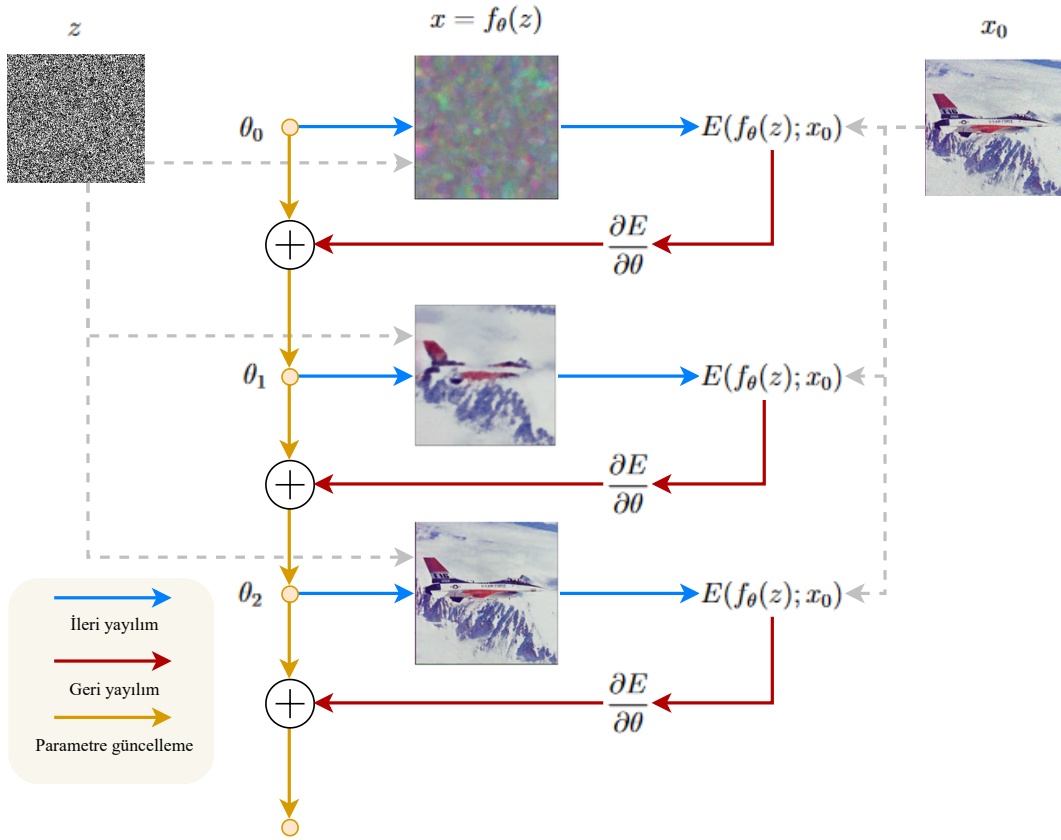
Bu bölümde, çoğu öz-gözetimli yöntemle ilham veren yenilikçi yapıların teorik temellerini özetlemekteyiz. Bunlar, RGB görüntüler için geliştirilen yöntemlerdir. Bölüm 3.3.'te, bu teorik bilgiler kullanılarak geliştirilen öz-gözetimli HSG gürültü giderme yöntemlerini tartışmaktayız. Ayrıca, buradaki temeller, Bölüm 4.3.'te tanıtılan öz-gözetimli öğrenme yöntemimizi anlamayı kolaylaştırmaktadır.

2.4.1. Derin Görüntü Önseli

Derin Görüntü Önseli (Deep Image Prior; DIP), görüntü işleme alanında önerilen bir yöntemdir ve birçok çalışmaya ilham kaynağı olmuştur. Bu çalışmaya göre öğrenmeden bağımsız, bir evrimsel görüntü üreteç ağ yapısı çok sayıda görüntü istatistiğini yakalamaktadır. Dolayısıyla, büyük bir veri kümesi kullanılarak yapılan gözetimli eğitim yerine, bozulmuş tek bir görüntünün derin bir üreteç ağı ile temiz karşılığını elde etmek mümkündür [58].

Denklem 7'de öğrenilebilir parametre seti θ ile bir derin üreteç sinir ağı f_θ verildiğinde, normal beklenti ağın parametrelerinin eğitim verilerinden öğrenilmesi ve ağın girdi görüntüler hakkında faydalı bilgi elde etmesidir. Ancak, herhangi bir eğitim gerçekleşmeden önce bile, bir ağın yapısında önemli miktarda bilgi bulunmaktadır. Doğal olarak, eğitim tamamlanmadan ağın görüntüyle ilgili yüksek düzeydeki kavramları öğrenmesi beklenemez. Ancak, doğal görüntülerin düşük düzeydeki yapısı hakkındaki bilgiler her adımda elde edilebilmektedir. Bu anlayış ile, bozulmuş bir gözlem \mathbf{x}_0 temel alınarak temiz karşılığı olan \mathbf{x} 'in çıkarılması için gereken şartlı görüntü dağılımını, $p(\mathbf{x}|\mathbf{x}_0)$, modellemek yeterli olmaktadır [58]. Derin bir üreteç ağının parametrelerini bozulmuş bir görüntü (\mathbf{x}_0)

kullanarak güncelleme adımları Şekil 2.3'te gösterilmektedir. Bu diyagramda, bozulmuş bir gözlemlenirken bile temiz verilerin elde edilebileceği gösterilmektedir. Gürültülü bir kod vektörü olan z 'yi bir görüntüye x eşleyen sinir ağı, rastgele bir parametre seti θ_0 ile başlatılmakta ve optimum parametre seti θ^* (yerel minimum) ve karşılık gelen çıktı x^* elde edilene kadar, Denklem 8'deki maliyet fonksiyonunu minimize etmek için yinelemeli olarak güncellenmektedir (geri yayılımda gradyan inişi ($\frac{\partial E}{\partial \theta}$) yoluyla). Burada sadece bozulmuş veriler kullanıldığı için temiz verilere ihtiyaç olmamaktadır.



Şekil 2.3 Üreteç ağı ile derin görüntü önseli yöntemi kullanarak görüntü restorasyonu.

$$\mathbf{x} = f_{\theta}(\mathbf{z}) \quad (7)$$

$$\theta^* = \operatorname{argmin}_{\theta} E(f_{\theta}(\mathbf{z}); \mathbf{x}_0); \quad \mathbf{x}^* = f_{\theta^*}(\mathbf{z}) \quad (8)$$

Denklem 8’de, gürültü giderme amacıyla tasarlanmış optimizasyon terimi şu şekilde tanımlanmaktadır: $E(\mathbf{x}; \mathbf{x}_0) = \|\mathbf{x} - \mathbf{x}_0\|^2$. Diğer uygulamalar için, DIP [58] çalışmasına ayrıntılı bakılması önerilmektedir. Sinir ağı eğitimi yeterince uzun bir süre çalıştırılırsa, yitim fonksiyonu yerel bir minimuma ulaşacak ve çözüm gürültülü görüntüye daha yakın olacaktır. Ancak, Şekil 2.3’te görüldüğü gibi, ağ önce temiz görüntüye yakın bir çıktı üretecek ve ardından görüntü için detay olarak kabul edilen gürültüyü üretecektir. Bu nedenle, eğitim doğru zamanda durdurularak temiz görüntüye yakın bir çıktı elde edilebilmektedir. Bu noktada, ağ bu yöntemle eğitilirken optimal durma noktasını belirlemek zorluk yaratmaktadır.

2.4.2. Gürültüden Gürültüye

DIP yöntemine benzer anlayışla, Gürültüden Gürültüye (Noise2Noise) yöntemi, bozulmuş görüntülerden temiz görüntülere geçişin, aynı sahnenin iki farklı bozulmuş versiyonunu kullanarak öğrenilebileceğini öne sürmektedir [45]. Görüntü iyileştirme uygulamalarında daha önce de bahsedildiği gibi genellikle gözetimli yöntemler kullanılmaktadır. Burada ağlar, gürültülü ve temiz görüntülerin eşleştirilmiş verileri üzerinde eğitilmektedir (yani, eğitim çiftleri $\{\mathbf{x}, \mathbf{s}\}$ olmak üzere \mathbf{x} gürültülü ve \mathbf{s} temiz görüntülerdir). Noise2Noise yöntemiyle ise, aynı sahnenin bağımsız olarak bozulmuş versiyon çiftleri kullanılarak eğitilmektedir, örneğin $\{\mathbf{x} = \mathbf{s} + \mathbf{n}, \mathbf{x}' = \mathbf{s} + \mathbf{n}'\}$. Dolayısıyla, bu yöntem, aynı içeriğe sahip iki görüntünün bağımsız gürültüler olan $\{\mathbf{n}, \mathbf{n}'\}$ ile bozulmuş olmasını gerektirmektedir. Ancak, gerçek dünya verilerinde bu her zaman mümkün olmamaktadır. Bu nedenle, bu yöntem ile derin ağ eğitimi için genellikle yapay olarak gürültü ekleyerek eğitim çiftleri $\{\mathbf{s} + \mathbf{n}, \mathbf{s} + \mathbf{n}'\}$ oluşturmaktadır.

Bu yöntemi daha ayrıntılı incelemek için öncelikle gözetimli eğitim yöntemlerini göz atalım. Gözetimli eğitim bağlamında, Denklem 9’da verilen maliyet fonksiyonu, bozulmuş ve temiz sinyaller ile oluşturulmuş eğitim çiftleri kullanılarak minimize edilmektedir.

$$\operatorname{argmin}_{\theta} \mathbb{E}_{(\mathbf{x}, \mathbf{s})} \{L(f_{\theta}(\mathbf{x}), \mathbf{s})\} \quad (9)$$

Burada f_θ , parametreleri θ olan bir ağı temsil etmekte; L yitim fonksiyonunu ve \mathbb{E} beklenen değeri temsil etmektedir. Denklem 9’u, giriş koşullu hedef dağılımı $p(\mathbf{x}, \mathbf{s}) = p(\mathbf{s}|\mathbf{x})p(\mathbf{x})$ kullanılarak basit bir manipülasyonla Denklem 10’a dönüştürmek mümkündür. Giriş sinyaline olan bağımlılık kaldırıldığında, bu yapı güvenilir giriş ölçümlerine dayanarak tahminler yürütmeye karşılık gelmektedir.

$$\operatorname{argmin}_\theta \mathbb{E}_{\mathbf{x}} \{ \mathbb{E}_{\mathbf{s}|\mathbf{x}} \{ L(f_\theta(\mathbf{x}), \mathbf{s}) \} \} \quad (10)$$

Basit bir örnek üzerinden maliyet fonksiyonunu minimize etmek için hangi bilgilere ihtiyaç duyulduğuna göz atacak olursak. Eğer $L_2 = (\mu - y)^2$ norm fonksiyonu kullanılırsa, güvenilir ölçümler (y) dikkate alındığında ve ölçümlerden ortalama sapmayı minimize edecek bir değer (μ) belirlemek için bir tahmin yapıldığında, Denklem 11’de verilen sonuç elde edilmektedir. Bu sonuca göre, tahmin sadece beklenen değere eşit olmaktadır.

$$\operatorname{argmin}_\mu \mathbb{E}_y \{ L_2(\mu, y) = (\mu - y)^2 \} \rightarrow \mu = \mathbb{E}_y \{ y \} \quad (11)$$

Sonuç olarak, aynı koşullu beklenen değerlere sahip farklı giriş koşullu hedef dağılımları $p(\mathbf{s}|\mathbf{x})$ kullanıldığında, Denklem 9’daki optimal ağ parametreleri olan θ değişmeyecektir. Bu, bir sinir ağı eğitimi için kullanılan temiz verilerin sıfır ortalamalı gürültü ile bozulabileceğini ve ağın öğrendiği bilgilerin değişmeyeceğini göstermektedir [45]. Bu nedenle, elde edilen yeni maliyet fonksiyonu Denklem 12’de verilmektedir. Ağın eğitimi gerçekleştirilmek amacıyla aynı görüntüye bağımsız gürültüler eklenerek eğitim çiftleri $\{\mathbf{x}_i, \mathbf{x}'_i\}$ oluşturulmaktadır.

$$\operatorname{argmin}_\theta \sum_i L(f_\theta(\mathbf{x}_i), \mathbf{x}'_i) \quad (12)$$


Dolayısıyla, tıpkı DIP yönteminde olduğu gibi, Noise2Noise ile ağı eğitmek için temiz veriye ihtiyaç olmamaktadır.

2.4.3. Gürültüden Boşluğa

Gürültülü ve temiz çiftler $\{x, s\}$ ile gözetimli öğrenme yaygın bir yaklaşımdır. Ancak, yukarıda bahsedildiği gibi Noise2Noise, aynı verinin bağımsız olarak bozulmuş versiyonlarını $\{x = s + n, x' = s + n'\}$ kullanarak eğitimi gerçekleştirerek yenilikçi bir adım atmaktadır. Bunun üzerine inşa edilen Gürültüden Boşluğa (Noise2Void), Noise2Noise yöntemindeki farklı gürültülere bağımlılığı ortadan kaldırma amacıyla tek bir bozulmuş görüntüden eğitimin yapılabilceğini göstererek sınırları daha da ileriye taşımaktadır [47].

Şekil 2.4'te, gözetimli öğrenme (Noise2Clean olarak adlandırılabilir) ve Noise2Void yöntemleriyle eğitimin nasıl gerçekleştirildiğini gösteren bir diyagram sunmaktayız. Bir piksel için gözetimli eğitimde (Şekil 2.4(a)), sinir ağının yama tabanlı perspektifini uygulayarak, eğitim verilerimizi $\{x_{RF(i)}, s_i\}$ çiftleri olarak görebiliriz, burada $x_{RF(i)}$ giriş görüntüsü olan x 'den çıkarılan i . piksel çevresindeki yamanın alıcı alanını (şekildeki mavi alan altındaki pikseller) temsil etmekte ve s_i aynı konumdaki temiz görüntü olan s 'den çıkarılan hedef piksel değerini ifade etmektedir. Bir piksel için bu yama tabanlı eğitim çiftleri kullanılarak yetim fonksiyonu aşağıdaki gibi ifade edilebilmektedir:

$$\operatorname{argmin}_{\theta} \sum_i L(f_{\theta}(x_{RF(i)}), s_i) \quad (13)$$



Şekil 2.4 Ağ Öğrenme Metodolojisi (a) Gözetimli öğrenme (Noise2Clean), (b) Öz-gözetimli öğrenme: Gürültüden gürültüye (Blind-spot network-Noise2Void).

Tek bir gürültülü görüntüden eğitim yapmanın uygulanabilirliğini anlamak için, uzamsal bir alıcı alana sahip bir ağ mimarisinin kullanımını düşünelim. Şekil 2.4(b)'de gösterildiği gibi, bu senaryoda, bu ağın alıcı alanı olan $\tilde{\mathbf{x}}_{RF(i)}$ merkezinde bir kör nokta (\mathbf{x}_i : girişin i . pikseli) olduğu varsayılmaktadır. Ardından, Noise2Noise yönteminin bulguları kullanarak, Noise2Void ile girdiye dahil edilmeyen \mathbf{x}_i pikseli hedef olarak kullanılarak yitim fonksiyonu aşağıdaki gibi ifade edilebilmektedir:

$$\operatorname{argmin}_{\theta} \sum_i L(f_{\theta}(\tilde{\mathbf{x}}_{RF(i)}, \mathbf{x}_i)) \quad (14)$$

Sonuç olarak, gürültünün istatistiksel olarak bağımsız ve sinyalin istatistiksel olarak bağımlı olduğunu düşünürsek, kör nokta ağı hem giriş hem de hedef verilerini aynı gürültülü eğitim görüntüsünden çıkarmasına olanak sağlamaktadır. Ancak, Noise2Void, görsel tutarlılığı düşük nesnelere (örneğin, görüntüde yalnızca birkaç piksel kaplayan küçük nesnelere) içeren görüntülerle uğraşırken görüntüde bulanıklaşmaya sebep olarak performans kaybı yaşamaktadır.

3. İLGİLİ ÇALIŞMALAR

Bu bölümde, öncelikle literatürdeki önemli klasik gürültü giderme yöntemleri özetlenmektedir. Ardından, derin öğrenme yaklaşımlarıyla geliştirilen hem gözetimli hem de öz-gözetimli öğrenme türlerine ayrı ayrı odaklanarak kapsamlı bir inceleme sunulmaktadır.

3.1. Klasik Yöntemler

Gürültü giderme amacına uygun olarak, çeşitli klasik HSG gürültü azaltma/giderme yaklaşımları önerilmiş olup, temel olarak iki ana kategoride sınıflandırılabilir: uzamsal filtreleme yöntemleri ve model tabanlı yaklaşımlar. Uzamsal filtreleme yöntemleri, gürültüyü bastırmak için doğrudan HSG'nin uzamsal alanında çalışmaktadır. Bu yöntemler, gürültüyü bertaraf ederken aynı zamanda görüntünün keskin kenarları ve ince detayları seçici olarak koruyan filtreler kullanmaktadır. Öte yandan, model tabanlı yöntemler, gürültü giderme sürecine rehberlik etmek için görüntü hakkındaki önsel bilgilere yoğun olarak önem vermektedir. Bu yöntemler, gürültüyü giderirken görüntü yapısını koruyabilmek için seyreklik, düzgünlük veya düşük kerte gibi çeşitli HSG önsel bilgilerinden yararlanmaktadır.

Literatürde birçok HSG gürültü giderme yöntemi mevcuttur. Bu yöntemler arasında uzamsal filtreleme modellerine dayananlar da dahildir. En basit teknikler, blok eşleştirme ve 3B filtreleme (block-matching and 3D filtering; BM3D) [17] ve ağırlıklı çekirdek normu minimizasyonu (weighted nuclear norm minimization; WNNM) [18] gibi 2B görüntüler için geliştirilmiş gürültü giderme yöntemlerini uyarlayarak HSG'leri bant-bant veya birkaç bant işleyecek şekilde ele almaktadır. Ancak, bu yöntemler yalnızca uzamsal bilgileri dikkate aldıklarından ve bantlar arasındaki bilgileri göz ardı ettikleri için genellikle spektral bozulmalara neden olmaktadır.

Son on yılda, model tabanlı yaklaşımlar, bir HSG'nin az sayıda saf spektral imza ile iyi bir şekilde temsil edilebileceği bilgisinden önemli ölçüde yararlanmıştır. Bu özellik, araştırmacıları gürültü giderme için HSG'lerin düşük kerte yapısından faydalanmaya teşvik

etmiştir. Bir çok çalışmaya ilham kaynağı olmuş ve düşük kerte temelli LRMR [21] yöntemi HSG restorasyonu için geliştirilmiştir. Ardından, LRMR yönteminin bir uzantısı olan NAILRMA [59] HSG'deki kompleks gürültü türlerini gidermede iyi çalışmaktadır. Bu yöntemlerde HSG'ler 2B bir matris olarak yeniden düzenlenmekte ve bu matrisin düşük kerte özelliği incelenmektedir. Görüntülerin düşük kerte özeliğinden fayda sağlayan diğer yöntemler, LRTV [22], LRTDTV [23] ve 3D-GTV [60] gibi, LRMR'ın performansını toplam varyasyon (TV) normu [61] ile birlikte geliştirmeye çalışmaktadır. Düşük kerte özelliğini etkili kullanmak için literatürde yakın zamanda da yeni modeller önerilmiştir [26, 27, 62–65]. Bu yöntemler, uzamsal-spektral bilgiyi etkili bir şekilde hesaba katarak daha yüksek doğruluk elde ederken, bu tür yöntemlerin performansı bozulmuş HSG'nin önsel bilgilerine (örneğin, gürültü varyansı, düşük kerte) dayanmaktadır ve özellikle TV tabanlı olanlar aşırı yumuşatmaya neden olarak görüntüdeki keskin hatlara zarar vermektedir. Bu nedenle, bu tür yaklaşımların hiper parametrelerinin her HSG için uygun şekilde ayarlanması gerekmektedir. Dahası, bu yöntemler genellikle gürültü azaltma sürecini yinelemeli olarak çözülmesi gereken karmaşık bir optimizasyon sorunu olarak ele almaktadır. Sonuç olarak, bu yinelemeli yapılar gürültü giderme sürecini zaman alıcı hale getirmektedir. Model tabanlı yöntemler hakkında daha kapsamlı ve derinlemesine bilgi, farklı model tabanlı yöntemlerin türleri, güçlü ve zayıf yönleri hakkında ayrıntılı bir genel bakış sunan inceleme çalışmasında [66] bulunabilir.

HSG gürültü giderme için başka bir yaklaşım ise seyrek temsiller kullanmaktır [67]. Yukarıda bahsedildiği gibi, hacimsel verilere BM3D filtresinin bir uzantısı olan BM4D filtreleme [68], bu yapıların öncü örneğidir. BM4D, 3B HSG yamalarını gruplandırmakta ve dönüşüm alanında filtrelemektedir. NGMeet yöntemi [69] ise HSG gürültü giderme için birleşik bir uzamsal yerel olmayan benzerlik ve spektral düşük kerte yaklaşımı sunmaktadır. FastHyDe [70] ve FastHyMix [71], sırasıyla GN ve karışım (mixture) gürültüsü gibi farklı gürültü türleri için verimli bir şekilde gürültü giderme yapabilmek adına, HSG'nin hem düşük kerte hem de öz-benzerlik özelliklerini etkin bir şekilde kullanmaktadır. Son zamanlarda SSSLRR [72], hem seyrek temsile hem de düşük kerte özelliklere dayalı bir gürültü giderme yöntemi önermektedir. Ancak, bu seyrek kodlamaya dayalı modeller Gauss

ve Poisson gürültüsü gibi istatistiksel olarak iyi davranışlı gürültülerde uygun olsalar da, gerçekçi senaryolarda sıklıkla karşılaşılan karışım gürültü ortamlarında zayıf performans göstermektedir.

3.2. Gözetimli Derin Sinir Ağları

Son zamanlarda, HSG gürültü gidermede sinir ağlarının kullanımı, verinin uzamsal ve spektral özelliklerini etkili bir şekilde yakalama yetenekleri nedeniyle giderek daha popüler hale gelmiştir. Ancak, HSG gürültü gidermenin kritik yönlerinden biri ağın eğitimidir. Yaygın bir yöntem, ağın temiz ve gürültülü çiftler kullanılarak eğitildiği gözetimli öğrenmedir. Daha önce de bahsedildiği gibi bu öğrenme, ağın temiz görüntülerden öğrenmesini ve verilen bir girdi için doğru çıktıyı anlama yeteneği geliştirmesini sağlamaktadır. Aşağıda, HSG'ye özel geliştirilmiş ve gözetimli bir şekilde eğitilmiş CNN tabanlı, Dönüştürücü tabanlı modeller ve bunların kombinasyonları tartışılmaktadır.

3.2.1. CNN Tabanlı Modeller

Son zamanlarda, derin öğrenmenin popülerliği ile birlikte, CNN tabanlı yaklaşımlar, geleneksel yöntemlere göre önemli gelişmeler göstererek HSG gürültü gidermede yeni bir çığır açmıştır. Bu veri odaklı modeller, otomatik olarak gürültülü HSG'lerden temiz HSG'lere bir eşleme öğrenmektedir. Ağın bu doğrusal olmayan eşlemeyi öğrenebilmesi için, büyük miktarda gürültülü ve temiz veriden oluşan eğitim çiftlerine ihtiyaç vardır. Bugüne kadar, HSG gürültü gidermeye yönelik birçok derin öğrenme yöntemi önerilmiştir. İlk dönemlerde, gri tonlamalı veya RGB görüntüler için geliştirilen yöntemler, giriş ve çıkış filtre boyutları ayarlanarak veya HSG'leri tek bir bant olarak ele alarak gürültü gidermede kullanılmıştır. DnCNN [41], hızlı yakınsama için kalıntı öğrenme (residual learning) ve grup normalizasyonu (batch normalization) kullanmayı önermiştir. HSI-DeNet [29] yöntemiyle, uzamsal ve spektral bilgiler için çok kanallı 2B evrişimsel filtrelerinden oluşan bir set temel alınarak HSG gürültü gidermede yöntemi tanıtılmıştır. Ayrıca, başlangıçta uzun süreli bağımlılık sorunlarını çözmek için derin kalıcı bellek ağı olarak RGB gürültü giderme

için önerilen MemNet [73], QRNN3D [32] çalışmasında HSG’de gürültü giderme için bir kıyaslama olarak başarılı sonuçlar elde etmiştir. Ancak, 2D filtrelere dayalı yaklaşımlar, HSG’lerdeki kapsamlı spektral bilgiden tam anlamıyla yararlanmamaktadır.

Son zamanlarda, HSG’nin hem spektral hem de uzamsal özelliklerinden yararlanmak için HSG’ye özgü ağlar da geliştirilmiştir [32, 33, 40, 74–76]. Özellikle, SSCAN [40], grup evrişimleri ile dikkat modüllerini birleştirerek görüntülerdeki uzamsal ve spektral bilgiyi etkili bir şekilde kullanmak için HSG’ye özgü bir gürültü giderme ağıdır. QRNN3D [32] ise 3B evrişimsel çekirdekli U-net [77] mimarisini kullanarak yapısal uzamsal-spektral ilintiyi etkili bir şekilde entegre eden alternatif yönlü bir 3B yarı-tekrarlayan sinir ağıdır (3D quasi-recurrent neural network). Bu yöntemle yarı-tekrarlayan havuzlama fonksiyonu tanıtılmış ve bu fonksiyon, spektral spektrum boyunca global ilintiyi başarılı yakalamaktadır. Bu tür yöntemler başarılı sonuçlar vermektedir, ancak farklı sensörlerden elde edilen görüntülerin değişken spektral bantlara sahip olması nedeniyle ağların yeniden yapılandırılması ve yeniden eğitilmesi gerekmektedir. Ne yazık ki, bu zaman alıcı bir süreçtir.

Yuan *et. al.* [30], hem uzaysal hem de spektral bilgiyi dikkate alarak, farklı HSG’ler için hiper parametreleri manuel olarak ayarlamaya gerek duymadan, kalıntı öğrenmeye dayalı CNN tabanlı bir HSG gürültü giderici ağı (HSID-CNN) önermişlerdir. Benzer şekilde, Zhang *et. al.* [39], karışım gürültüyü gidermek için uzamsal-spektral bilgiye ek olarak bitişik spektral farkı kullanan bir uzamsal-spektral gradyan ağı (spatial-spectral gradient network; SSGN) önermişlerdir. Maffei *et. al.* [31], HSI-SDeCNN adı verilen CNN tabanlı tek model bir gürültü giderme yöntemi geliştirmişlerdir. HSI-SDeCNN, gürültü varyansını giriş olarak aldığından, bu model bağımsız özdeşçe dağılmış GN için etkilidir. Bu yöntemler, tek bir modeli eğiterek oldukça başarılı sonuçları vermektedir. Ancak, test verilerindeki başarıları, eğitim verilerine test verilerindeki gürültüye benzer yapay gürültü eklemeye bağlıdır. Bu yöntemlere kıyasla, bizim SM-CNN modelimiz, önerilen SSMRB mekanizması aracılığıyla ağın özneliklerini sağlanan spektral verilere göre modüle ederek test sırasında kendini uyarlayabilmektedir. Bu durum, deneylerimizde de kanıtlandığı gibi, önerilen SM-CNN’in

eđitim ve test verisi dađılımları arasındaki açıklık farkını kısmen azaltmasına yardımcı olmaktadır.

3.2.2. Dönüřtürücü Tabanlı ve Hibrit Modeller

Son zamanlarda, derin öğrenmenin yükselen bir alanı olan dinamik sinir ađları [35, 36, 78], çıkarım sırasında yapılarını veya parametrelerini belirli girdiye uyacak şekilde dinamik olarak ayarlayarak statik modellere göre belirgin bir avantaj sunmaktadır. Dinamik bir yapı olarak Dönüřtürücüler [48], mimarisini ve parametrelerini belirli girdiye uyacak şekilde özelleřtirme esnekliđi sunarak verideki karmařık iliřkileri ve desenleri kavrama kapasitesini güçlendirir. Son zamanlarda, ViT [49] ve geliřtirilmiř versiyonları [52, 57], çeřitli görüntü iřleme görevleri için omurga mimarileri olarak popülerlik kazanmıřtır. CNN'lerden farklı olarak, ViT'lerdeki öz-dikkat mekanizması, uzamsal özellikler arasındaki uzun menzilli bađımlılıkları yakalamaya olanak tanımaktadır. Bu nedenle, Dönüřtürücü'ler HSG sınıflandırma [79, 80] ve restorasyon [81, 82] için başarılı bir şekilde kullanılmıřtır. Ancak, ViT'nin öz-dikkat modülü, görüntülerdeki yakın piksellerin genellikle uzak piksellere göre daha güçlü iliřkiler sergilediđini öne süren uzamsal intizamı göz ardı etme eğilimindedir. Bu nedenle, bu yerel iliřkileri dolaylı olarak öğrenmek için ViT'ler genellikle büyük miktarda eğitim verisine ihtiyaç duymaktadır. Bu durum, sınırlı veriye sahip HSG gürültü giderme iřlemleri için sıkıntı yaratabilir. Ayrıca, HSG'lerin çok sayıda spektral banda sahip olması öz-dikkat hesaplamaları için yüksek hesaplama maliyeti ve bellek gereksinimleri ortaya çıkararak Dönüřtürücü tabanlı gürültü giderme yöntemleri için zorluklar oluřturmaktadır.

Yukarıdaki kısıtlamaları ele almak için, son zamanlarda HSG gürültü gidermede CNN'lerin ve Dönüřtürücü'lerin birlikte harmanlanarak kullanıldıđı yapılar önerilmektedir [33, 42, 82–88]. Örneđin, SST [85], en basit şekilde, giriş HSG'den çıkarılan CNN öznitelikleri üzerinde yerel olmayan uzamsal öz-dikkat ve global spektral öz-dikkat uygulayarak bunu başarmaktadır. TRQ3DNet [84] ise mevcut QRNN3D [32] HSG gürültü giderme modelinin gücünü, Dönüřtürücü tabanlı bir RGB gürültü giderme modeli olan Uformer [53] ile birleřtirerek umut verici sonuçlar elde etmiřtir. Ancak, bu model karmařıklıđı azaltmayı

amaçlayan pencere tabanlı dikkat mekanizması nedeniyle görüntülerin uzamsal boyutlarının pencere boyutunun katları olmasını gerektirmektedir. SERT [36], uzamsal alandaki yerel olmayan benzerlikleri etkili bir şekilde yakalamak için yatay ve dikey yönlerde çalışan bir dikdörtgen öz-dikkat mekanizması kullanmaktadır. Ayrıca, uzamsal-spektral küplerin düşük kerte özelliklerini kullanarak gürültü baskılama ve örtüşmeyen uzamsal dikdörtgenler arasındaki etkileşimleri artıran bir spektral iyileştirme modülü içermektedir. Dönüştürücülerin uzun menzilli bağımlılıkları modelleme yeteneği, üstün gürültü giderme performanslarına katkıda bulunmaktadır, ancak bu, daha fazla parametre sayısı ile birlikte gelmektedir. UNFOLD [87], bu sorunu kodlayıcıda vanilya Dönüştürücü ve kod çözücüde farklı çekirdek boyutlarına sahip 3B CNN'ler kullanarak ele almakta ve U-Net mimarisini kullanarak HSG'nin hem yerel hem de global özelliklerini yakalamaktadır. Ancak, HSG'lerdeki spektral bant sayısı, bu Dönüştürücü modelinde öz-dikkat hesaplamalarını arttırmaktadır. Son olarak, HSDT [86], evrimsel ve Dönüştürücü bloklarını birleştirerek hibrit bir kodlayıcı-kod çözücü mimarisi sunmaktadır. Bu model, daha etkili özellikler çıkarmak için girdileri hem uzamsal hem de spektral boyutlar boyunca işleyip ve ardından spektral bantlar boyunca öznitelikleri daha da rafine eden spektral imzaları kodlayan öğrenilebilir sorgularla bir öz-dikkat bloğu ile devam etmektedir. Ek olarak, bilgilendirici öznitelikleri zenginleştirmek için öz-modülasyon işlemi kullanmaktadır.

Bu tezde, CNN'leri ve Dönüştürücü'leri benzersiz bir şekilde birleştiren ve en yakın model olan HSDT'yi [86] performans olarak aşan yeni bir HSG gürültü giderme yaklaşımını sunmaktayız. Modelimiz, her biri öğrenilebilir spektral ve kanal bazlı modülatörlerle güçlendirilmiş Dönüştürücü blokları içinde ayrı spektral ve kanal bazlı dikkat mekanizmalarının uygulanmasıyla kendini diğerlerinden ayırmaktadır. Bu modülatörler, yaklaşımımızın hassas bant önceliklendirmesine ve daha net dikkat dağılımına izin vererek spektral ve uzaysal özelliklerin çıkarılmasını önemli ölçüde iyileştirmekte ve modelin yapısında önemli bir yere sahiptir. Hem spektral hem de uzamsal bilgilere odaklanan bu ikili öz-dikkat mekanizmalarımızla birlikte, yalnızca gürültü giderme performansını yükseltmekle kalmaz, aynı zamanda eğitim sürecini de stabilize ederek model genelleme yeteneğini artırmaktadır. Bölüm 4.2., modelimizin özelliklerini ve HSG gürültü gidermeye

özgün katkılarını derinlemesine incelemektedir.

3.3. Öz-Gözetimli Derin Sinir Ağları

Bir diğer yaklaşım ise öz-gözetimli öğrenme (self-supervised learning) kullanmaktır. Burada ağ yalnızca gürültülü veriler kullanılarak eğitilmekte ve verilerdeki desenleri ve ilişkileri kendi başına tanımlayabilmektedir. Nguyen *et. al.* [89], CNN eğitimi için yitim fonksiyonu olarak Stein yansız risk tahminini (Stein's unbiased risk estimation; SURE) kullanmayı önermektedir. SURE, ortalama kare hatası (mean-squared-error; MSE) için yansız bir tahmindir ve sadece gürültülü HSG kullanılarak hesaplanabilmektedir. Bu yaklaşım, temiz verilere ihtiyaç duymadan CNN'nin öz-gözetimli eğitimini sağlamaktadır. Ancak, SURE Gauss gürültüsü için tasarlandığından [90] karışım gürültüler üzerindeki performansı sınırlı kalmaktadır. Yakın zamanda önerilen bazı çalışmalarda [74, 75], HSG gürültü giderme için DIP stratejisine [58] dayalı farklı üreteç ağlar önerilmiş ve eğitilmiştir. Sonrasında, LRDS2 [91], düşük kerte ve derin uzamsal-spektral önselleri birleştirerek umut vadeden sonuçlar vermektedir. Ancak, bu çalışmaların başarısı aynı zamanda farklı HSG'ler için endmember sayısı gibi önsel bilgi sahibi olmaya da bağlıdır. Benzer şekilde, SLRP-DSP [92] spektral ve derin uzamsal önselleri entegre ederek potansiyel göstermekte, ancak yenilemeli optimizasyonu hesaplama açısından zorlayıcı olmaktadır.

Noise2Noise [45] temel alınarak, Qian *et. al.* [46] HSG'lerin bitişik bantlarından gürültülü veri örnekleri kullanıp eğitim çiftleri oluşturarak spektral bilgiyi entegre etmiştir. Tek bir banda odaklanırken, eğitim sırasında daha zengin frekans kombinasyonlarının kapsamlı bir şekilde keşfedilmesiyle önemli performans iyileştirmeleri gerçekleştirmektedir. Yine, Noise2Noise [45] öğrenme şemasını HSG gürültü giderme için yeniden uyarlayarak süper piksel bölütlemesinden ve süper pikseller içindeki eşleştirilmiş gürültülü piksellerden yararlanarak yeni başka bir model önerilmiştir [93]. Diğer bir yöntem ise HSG'nin alt uzay temsil katsayıları (öz-görüntüler olarak da adlandırılır) kullanılarak, ağ eğitimi sırasında temiz verilere dayanmadan gürültülü öz-görüntülerden eğitim çiftleri oluşturma yaklaşımıdır [94]. Tüm bu çalışmalar ışığında, görüntü işleme için öz-gözetimli öğrenmenin

vaatlerine rağmen, mevcut HSG gürültü giderme yöntemleri, HSG'ler içindeki bol spektral ilintileri yeterince kullanamamaktadır. Bu nedenle de ilgili yöntemlerin etkinliklerini sınırlı kalmaktadır. Ayrıca, bu çalışmaların başarısı yine görüntüden görüntüye değişkenlik gösteren önsel bilgilerin sahip olunmasına bağlıdır.

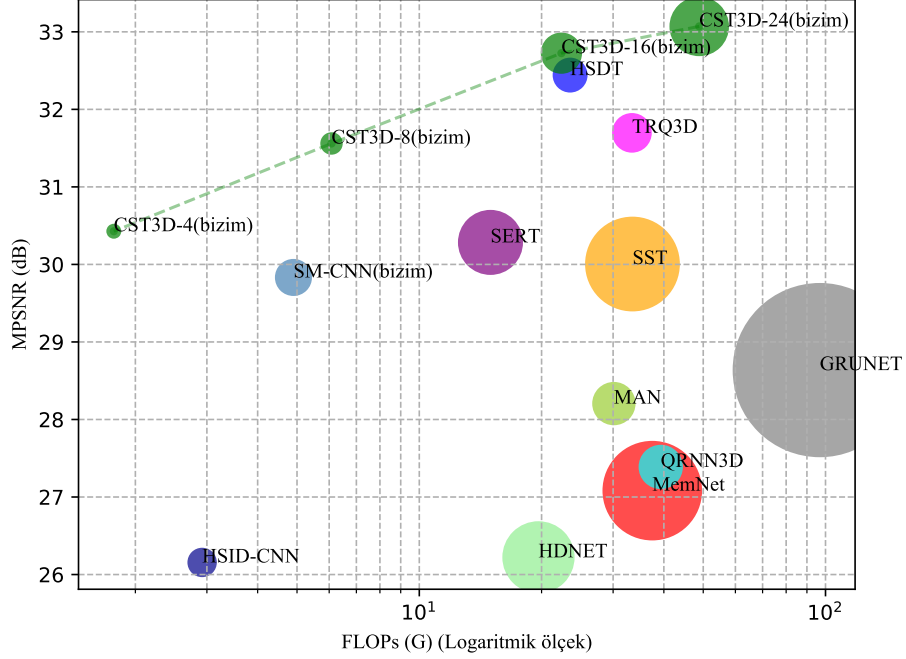
Bu çalışma, modelimizi daha önce görülmemiş gürültü örüntülerine sahip HSG verileri için eğitmek üzere iki aşamalı bir öğrenme stratejisi önermektedir. İlk aşama, modeli gürültülü ve temiz veri çiftleri üzerinde eğitmek için gözetimli öğrenmeyi içermektedir. İkinci aşama, modelleri belirli gürültü modellerine uyarlamak için yalnızca gürültülü verileri kullanarak öz-gözetimli kalibrasyonu içermektedir. Yaklaşımımızın, ağ daha önce gözetimli öğrenmede belirli gürültü modelleriyle karşılaşmamış olsa bile, gürültülü HSG'ler için modelin doğruluğunu ve verimliliğini artırdığı gösterilmiştir. Metodolojimizde, HSG hakkında önsel bilgi sahibi olmak gerekmemektedir.

4. ÖNERİLEN YÖNTEMLER

Bu bölümde, bu tez boyunca geliştirdiğimiz dinamik gürültü gidericileri ayrıntılı olarak açıklamaktayız. İlk modelimiz, öznitelikleri bitişik spektral verilere dayalı olarak uyarlanabilir bir şekilde dönüştüren ve karmaşık gürültüleri yönetme yeteneğini artıran SM-CNN ağı olacaktır. Ardından, her iki yaklaşımın güçlü yönlerini birleştiren, gelişmiş gürültü giderme performansı sunan, çift dikkat mekanizmalı hibrit CNN ve Dönüştürücü modelimizin ayrıntılı bir açıklamasını sunacağız. Son olarak, bu tez kapsamında geliştirdiğimiz öz-gözetimli eğitim modelimizin motivasyonunu ve yapısını tartışacağız.

Modellerimizin ayrıntılarına girmeden önce, literatürdeki diğer derin modellerle karşılaştırma yapılarak genel bir anlayış sağlamak amaçlanmaktadır. Şekil 4.1, derin modellerin karmaşıklık ve performansını önerdiğimiz ağlar (SM-CNN ve CST3D'nin dört versiyonu) ile karşılaştırmaktadır. WDC veri setindeki gürültü giderme işleminin Ortalama Tepe Sinyal-Gürültü Oranı (Peak Signal-to-Noise Ratio; MPSNR) değeri, kayan nokta işlemleri (Floating-point Operations; FLOPs) ve parametre sayısına karşı çizilmiştir. FLOPs, bir derin öğrenme modelinin bir görüntü üzerinden tek bir ileri geçişi gerçekleştirmek için ihtiyaç duyduğu toplam aritmetik işlemlerin (toplamalar ve çarpmalar) sayısını ifade etmektedir. Şekildeki her balonun büyüklüğü, karşılık gelen modeldeki öğrenilebilir parametre sayısını temsil etmektedir. Şekilde görüldüğü gibi, dinamik bir CNN tabanlı ağ olan SM-CNN, daha az öğrenilebilir parametre ve daha düşük FLOPs ile övgüye değer bir performans elde etmektedir. Ancak, hibrit modellerle (TRQ3D, SST, SERT ve CST3D gibi) karşılaştırıldığında, performansı daha düşük kalmaktadır. Çünkü bu yöntemler, global spektral ve uzamsal bilgiyi etkili bir şekilde entegre etmektedir. SM-CNN, CNN tabanlı yöntemleri (QRNN3D, HSID-CNN, HDNET vb.) ise geride bırakmaktadır. Şekil, her biri farklı kanal sayısına (4, 8, 16 ve varsayılan olarak 24) sahip dört CST3D model varyasyonunu göstermektedir. Şekilden de görülebileceği gibi, parametre sayısı ve FLOPs, kanal sayısına bağlı olarak önemli ölçüde değişmektedir. CST3D-16 ve CST3D-24 model versiyonlarımız, tüm mevcut modelleri gürültü giderme konusunda geride bırakmaktadır. CST3D-24 daha fazla hesaplama gerektirirken (yani FLOPs), CST3D-16 daha az parametre

ve hesaplama ile üstün MPSNR elde etmektedir. Dikkat çekici bir şekilde, sadece dört kanalla bile modelimiz, karşılaştırdığımız çoğu yönteme kıyasla iyi sonuçlar elde etmektedir. Bu başarı, modelimizin hem global hem de yerel spektral-uzamsal bilgileri etkili bir şekilde kullanabilme yeteneğinden kaynaklanmaktadır.



Şekil 4.1 FLOPs ve parametre sayısına karşı çizilen MPSNR ile model karmaşıklığı ve performans karşılaştırması. Balonların boyutu modelin görece parametre sayısını göstermektedir.

4.1. Öz-Modülasyonlu Evrimsel Sinir Ağı

Önerdiğimiz dinamik derin sinir ağı çerçevesi, HSG'lerin hem uzamsal hem de spektral bilgilerini, giriş komşu spektral bantlardan uyarlanabilir bir şekilde yararlanarak, öznelik modülasyon katmanları aracılığıyla işlemektedir. Yaklaşımımızın merkezinde, derin katmanlarda kullanılan yenilikçi Spektral Öz-Modülasyonlu Kalıntı Bloğu (Spectral Self-Modulating Residual Block; SSMRB) yer almaktadır. SSMRB, öznelik haritalarını akıllıca düzenleyerek eğitim kümesine aşırı uyum sağlamayı önlemekte ve gürültü giderme performansını artırmaktadır. Bu mekanizma iki ana fayda sağlamaktadır: (i) gürültü gidericiyi uzamsal-spektral bilgileri ile düzenleyerek ağın öğrenme yeteneğini güçlendirmek

ve (ii) çeşitli gürültü desenlerine etkili bir şekilde uyum sağlayan iyi genelleştirilmiş gürültü giderme yetenekleri oluşturmak.

Yeni SSMRB modülünü genişleterek, HSG’de gürültü gidermek için Öz-modülasyonlu CNN (SM-CNN) modelini de tanıtmaktayız. Deneysel sonuçlarımız, mevcut çalışmalara kıyasla önerdiğimiz gürültü giderme yönteminin etkili genelleme yeteneklerini göstermektedir. Talihli bir şekilde, yapay gürültü verileriyle eğitildiğinde bile ağımız gerçek gürültülü HSG’lerin gürültüsünü gidermede üstün performans sergilemektedir. Bu sonuç, SSMRB ile güçlendirilen yaklaşımımızın gerçek gürültülü HSG’leri yüksek doğrulukla ele alma konusundaki etkinliğini ve vaadini vurgulamaktadır. Ana katkılarımız aşağıdaki gibi özetlenebilir:

- Modelimizin ana unsuru, spektral öz-modülasyonlu kalıntı bloğu (SSMRB) olarak adlandırdığımız, ağırlık bitişik spektral verilere dayalı olarak öznelikleri ayarlamasını sağlayan ve eğitim setine aşırı uyumu önleyen, böylece karmaşık gerçek gürültüyle başa çıkma kapasitesini artıran yeni bir bileşendir.
- SSMRB katmanı, önerilen modeli, her bir giriş HSG’nin uzamsal-spektral bilgilerine göre tahmin edilen öznelikleri uyarlayan dinamik bir gürültü giderme ağı haline getirmektedir. Bu, ağımızın ağırlıklarının ileri yayılım sırasında uzamsal-spektral verileri dikkate alarak kendilerini gerçek zamanlı olarak uyarlayabileceğini göstermektedir.
- Öz-modülasyon mimarisi kullanarak, farklı sayıda spektral banda sahip çeşitli HSG’lerden gürültüyü verimli bir şekilde gideren yeni bir gürültü giderme ağı olan SM-CNN modelini tasarladık. Bu ağ, ek bir parametre ayarlamasına gerek duymadan hem spektral bilgiyi hem de HSG’nin yerel detaylarını koruyarak çok daha kesin ve net sonuçlar üretmektedir.
- Deneysel analizlerimiz, yaklaşımımızın tek bir SM-CNN modeli aracılığıyla farklı spektrumlarda GN, SN, DN, IN, karışım ve gerçek dünya gürültüsü dahil olmak üzere çeşitli gürültü durumlarında en son HSG gürültü giderme yöntemlerinin bir çoğundan hem niteliksel hem de niceliksel olarak daha iyi performans gösterdiğini ortaya koymaktadır.

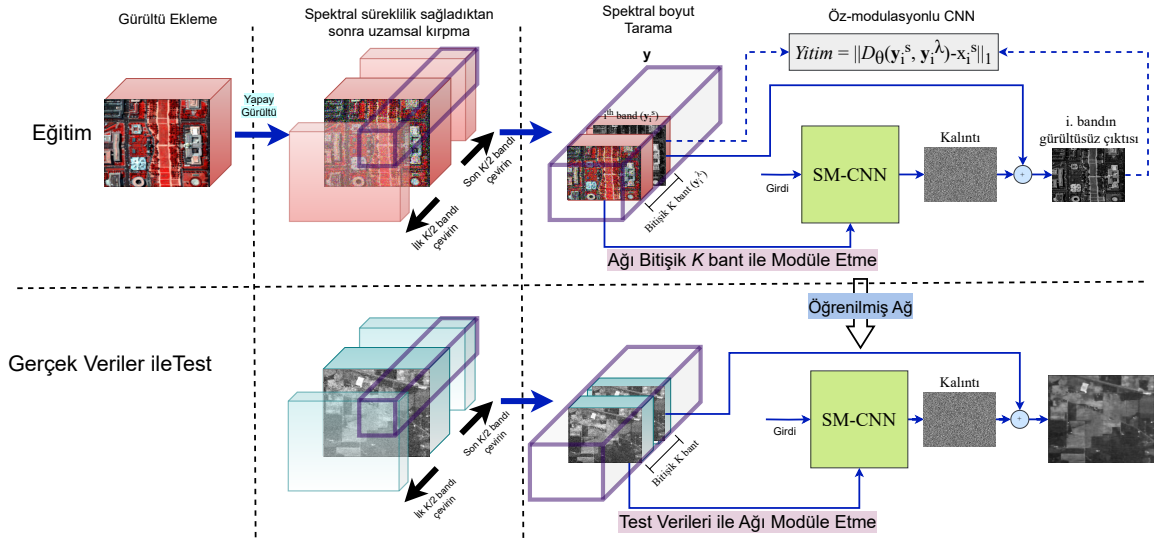
Ayrıca, önerdiğimiz yöntem gerçek dünyadaki gürültülü HSG üzerinde sınıflandırma performansının iyileştirilmesine olanak sağlamaktadır.

4.1.1. Yöntem Açıklaması

Bu bölümde, önerilen tek model SM-CNN ağıımızı detaylı olarak açıklamaktayız. HSG gürültü giderme için önerilen yöntemin sistem genel görünümü Şekil 4.2’de verilmiştir. HSG’ler farklı sayıda spektral banda ve uzamsal çeşitliliğe sahip sensörler tarafından elde edildiğinden, bir ağın genellikle farklı veriler için yeniden eğitilmesi gerekmektedir. Bu nedenle, tek bir model oluşturmak için benimsenen strateji, spektral boyutu taramak ve her seferinde uzamsal olarak kırılmış bir bandın gürültüsünü gidermektir. SM-CNN yöntemiyle, HSG’nin hem uzamsal hem de spektral bilgisini kullanmak için derin bir ağ yapısı önerilmektedir. Önerilen model bir bandın gürültü giderme işlemini gerçekleştirdiğinde, $h \times w$ piksel boyutunda yamanın içindeki uzamsal bilgiyi ve bu bandı da içeren K bitişik bandın spektral ilintisini kullanmaktadır. Önemli bir nokta, bu K komşu bantları ağıımızı düzenlemek için de kullanmamızdır, bu nedenle öz-modülasyonlu olarak adlandırmaktayız. Bu şekilde, farklı gürültü türleri (GN, karışım gürültü vb.) için ağın gürültü azaltma kapasitesini ve uyum kabiliyetini önemli ölçüde arttırmaktayız. Önerilen eğitim çerçevesi daha ayrıntılı olarak açıklanabilir:

- 1) SM-CNN gürültülü veriler ile temiz veriler arasında doğrusal olmayan bir eşlemeyi kavradığından, Şekil 4.2’de gösterildiği gibi orijinal HSG verilerine farklı yapay gürültüler ekleyerek eğitim çiftleri oluşturmaktayız.
- 2) Gürültü giderme işlemini banttan banda uzamsal bilgiyi tarayarak ve yukarıda belirtildiği gibi uzamsal bilgiyle birlikte K bitişik spektral bilgiyi kullanarak gerçekleştirmekteyiz. Bu nedenle uç noktalarda $K/2$ bantlarını ters çevirerek spektral sürekliliği sağlamaktayız.
- 3) Ardından, $M \times N \times (B + K)$ boyutundaki spektral olarak büyütülmüş gürültülü verileri uzamsal olarak kırarak $h \times w \times (B + K)$ boyutunda y yamalarını elde etmekteyiz.

- 4) Son olarak, spektral boyutu sürekli tarayarak uzamsal olarak kırılmış yamalardan bitişik K spektral bantlar elde etmekteyiz. y_i^s orta bantı ve y_i^λ komşu bantlarını, burada $i \in [1, B]$, ağa girdi olarak vererek y_i^s orta bantın gürültüsünü gidermeyi sağlamaktayız. Ağ, bu orta bant y_i^s ve ona karşılık gelen temiz hedef x_i^s ile eğitilmektedir. Aynı zamanda, bu komşu bantlar ağın spektral öz-modülasyonu için kullanılmaktadır.
- 5) Uzamsal olarak kırılmış her yama y için y_i^s girişi, buna karşılık gelen y_i^λ spektral bantları ve temiz hedef x_i^s seçilmekte ve bu işlem tüm bantlar için tekrarlanmaktadır.



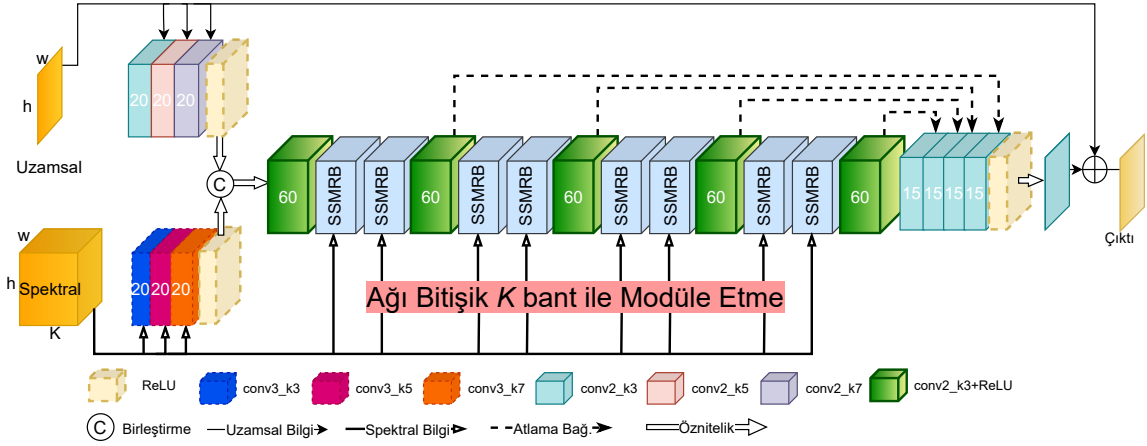
Şekil 4.2 HSG gürültü giderme için önerilen SM-CNN modelinin sistem genel bakışı. Eğitimde, ilk olarak temiz HSG'yi yapay gürültü ekleyerek gürültülü giriş verileri elde edilmektedir. Ardından, $K/2$ bantlarını çevirerek uç noktalarda spektral süreklilik sağlandıktan sonra uzamsal kırma gerçekleştirilmektedir. Spektral boyutu sürekli tarayarak, uzamsal olarak kırılmış yamalardan komşu K spektral bant elde edilmektedir. Orta bant gürültüsünü gidermek için ağ eğitirken uzamsal olarak kırılmış komşu bantlar da girdi olarak kullanılmaktadır. Bu işlem tüm bantlar için aynı şekilde tekrarlanmaktadır. Gürültülü K komşu bant, Şekil 4.3'te gösterildiği gibi ağ düzenlemek için derin katmanlarda bir SSMRB'den geçmektedir. Ayrıca, orta bantı nihai çıktıya ekleyerek eğitimin kararlılığını ve verimliliğini sağlamak için kalıntı öğrenme stratejisi kullanılmaktadır. Testte ise, eğitimde olduğu gibi verileri uzamsal olarak kırıldıktan ve spektral olarak taramıp, sonra ağa girdi olarak verilmektedir. Burada ağ, derin katmanlardaki SSMRB aracılığıyla testle ilişkili spektral bantlarla modüle edilmekte, bu da modelin eğitim sırasında doğrudan görülmeyen karmaşık gürültü ayarları altında kendini uyarlamasını sağlamaktadır.

Eđitim tamamlandıktan sonra test iřlemi Őekil 4.2’de gsterildiđi gibi gerekleřtirilmektedir. ncelikle tıpkı eđitimde olduđu gibi test verisinin $K/2$ bantları ters evrilerek u noktalarda spektral sreklilik sađlanmaktadır. Bytlmř test verisi daha sonra eđitimde olduđu gibi aynı Őekilde kırılmaktadır. Őekil 4.2’de gsterildiđi gibi, ađ test verisinin komřu bantları tarafından modle edilerek, ađın ok daha iyi grlt giderme performansı vermesi sađlanmaktadır.

4.1.2. Ađ Mimarisi

SM-CNN modelinin genel mimarisi Őekil 4.3’te gsterilmektedir. Őekildeki evriřim katmanlarına yazılan sayılar, kanal sayılarını belirtmektedir. Ađımızın iki giriř verisi bulunmaktadır: $h \times w$ boyutundaki uzamsal giriř verisi, grlts giderilecek mevcut grltl bandı temsil ederken, $h \times w \times K$ boyutundaki spektral giriř verisi bitiřik bantların uzamsal-spektral bilgisini temsil etmektedir. Yukarıda belirttiđimiz gibi, nerilen ađın đrenme stratejisine dayanarak, farklı HSG verileri bant sayısından bađımsız olarak tek bir modelle grlts giderilebilir. nk burada yama tabanlı banttan banda grlt giderme iřlemi gerekleřtirilmektedir. Buradaki en nemli noktalardan biri, derin katmanlarda SSMRB aracılıđıyla sađlanan ilintili spektral verileri kullanarak ađı modle etmektir. Bu durum iki fayda sađlamaktadır. İlk olarak, ađı uzamsal-spektral bilgiler ile dzenlemekte ve bylece ađın đrenme yeteneđini arttırmaktadır. İkincisi, ađın znetelik modlasyon sreciyle daha iyi genelleme yapmasını sađlamakta, bu da modelin yeni grlt trlerine kendini uyarlamasına olanak tanımaktadır. Bu kazanımlar, derin katmanlardaki zneteliklerin spektral bilgiye gre normalleřtirilmesiyle elde edilmektedir. Derin katmanlarda, zneteliklerin normalizasyon parametreleri piksel bazında grlt seviyesinden elde edilmektedir. Daha sonra, normalleřtirilmiř znetelikler bitiřik spektral verilere gre leklendirilmekte ve kaydırılmakta, bylece ierik bađımlı hale getirilmektedir.

Ađımızın temel yapısı, verilen hiperspektral grntnn uzamsal ve spektral bilgilerini kodlamak iin hem 2B hem de 3B CNN katmanlarıyla iřlendiđi HSID-CNN [30] modelinden ilham almıřtır. Ancak, mimarideki SSMRB blođunun tanıtılması, zellikle



Şekil 4.3 Önerilen SM-CNN'nin yapısı. Derin katmanlarda kullanılan SSMRB Şekil 4.4'de verilmekte ve Bölüm 4.1.2.1.'de detaylandırılmaktadır.

görülmemiş gürültü dağılımlarını ele alma konusunda modelimizin davranışında önemli bir fark yaratmaktadır. SSMRB bloğu, ağın eğitim sırasında görülenlerden tamamen farklı özelliklere sahip verilerle kendini uyarlamasını sağlamaktadır. Bu uyum yeteneği, gürültü dağılımlarının büyük ölçüde değişebileceği gerçek dünya senaryolarında çok önemlidir.

Daha spesifik olarak, Şekil 4.3'te gösterildiği gibi, tek bir 2B uzamsal bant girişi, farklı çekirdek boyutlarına sahip 2B CNN (conv2_k3, conv2_k5, conv2_k7, burada k çekirdek boyutunu ifade etmekte) katmanlarıyla işlenmektedir. Paralelde, 3B uzamsal-spektral veri küpü girişi, farklı çekirdek boyutlarına sahip 3B CNN (conv3_k3, conv3_k5, conv3_k7) katmanlarıyla işlenmektedir. İlk katmanlarda gerçekleştirilen bu 2B ve 3B CNN, tek bir bandın özelliklerini daha iyi kullanmak ve bitişik ilintili spektral bantları yüksek oranda kullanmak amacıyla düşünülmüştür. 2B CNN ve 3B CNN çıktılarına ReLU uygulandıktan sonra, bu çıktılar birleştirilip ve CNN (conv2_3k+ReLU) ile önerilen SSMRB katmanlarından oluşan ardışık derin katmanlara iletilmektedir. Model performansı ve hesaplama verimliliği arasında doğru dengeyi sağlamak için, ardışık SSMRB'lerin sayısı deneysel seçimle belirlenmiştir. Bölüm 4.1.2.1.'de ayrıntılı olarak açıklanacağı üzere, SSMRB modülü ağı gürültü giderme sürecinin her adımında verilen spektral sinyalden haberdar eder ve deneylerimizde gösterdiğimiz gibi ana spektral-uzamsal gürültü giderme ağının performansını büyük ölçüde artırmaktadır. Eğitim stabilitesini sağlamak [41] için ardışık derin katmanlardan çıkış katmanına atlama bağlantıları (skip connections)

kullanılmaktadır. Bu dört atlama bağlantısı, 15 kanallı 2B evrişimlerden (conv2_k3) geçirilip ve ardından tüm çıktılar birleştirilmektedir. Son olarak, önerilen gürültü gidericinin son katmanı gürültülü uzamsal kanaldan temiz verinin tahminini elde etmek için bir tek kanallı 2B evrişimden oluşmaktadır.

4.1.2.1. Öz-Modülasyonlu Kalıntı Bloğu. Ağımızı SSMRB ile spektral sinyalin kendisini kullanarak modüle etmekteyiz ve bu nedenle ağımıza öz-modülasyonlu CNN olarak adlandırmaktayız. SSMRB'nin yapısı Şekil 4.4'te gösterilmektedir. Bu blok, iki spektral öz-modülasyon modülü (spectral self-modulation module; SSMM) ve ardışık olarak bağlanmış iki 2B CNN'den oluşmaktadır. SSMM, girişteki öznitelik haritasını $\mathbf{f}_{\text{pre}} \in \mathbb{R}^{h \times w \times C}$, burada $h \times w$ öznitelik haritasının uzamsal boyutunu ve C kanal sayısını belirtmektedir, bitişik spektral bilgiyi alarak dönüştürmektedir. öznitelik haritalarının afin dönüşümünü üretmek için, SSMM önce öznitelik haritasını kanal bazında normalleştirmekte ve ardından bitişik spektral bantları kullanarak her piksel için ölçek (γ) ve kaydırma (β) oluşturmakta, bu şekilde dönüştürülmüş özellikleri elde etmektedir:

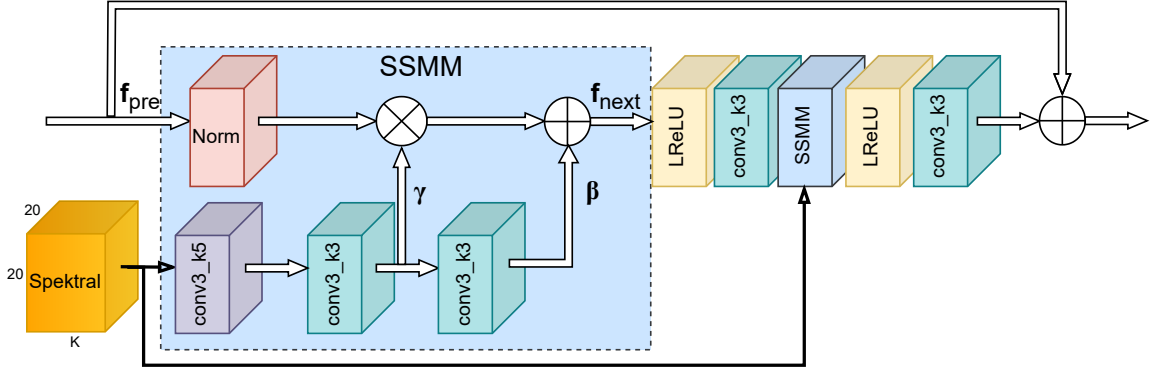
$$\mathbf{f}_{\text{next}}^c = \gamma_c(\mathbf{y}^\lambda) \frac{\mathbf{f}_{\text{pre}}^c - \mu_c}{\sigma_c} + \beta_c(\mathbf{y}^\lambda) \quad (15)$$

Burada, $\gamma_c(\mathbf{y}^\lambda)$ ve $\beta_c(\mathbf{y}^\lambda)$, her $c \in [1, C]$ için giriş spektral bantlarından (\mathbf{y}^λ) piksel bazında elde edilen öğrenilmiş öz-modülasyon parametreleridir ve $C = 60$ olarak alınmıştır. μ_c ve σ_c , sırasıyla kanal c için öznitelik haritası $\mathbf{f}_{\text{pre}}^c$ 'in ortalama ve standart sapmasını ifade etmekte ve aşağıdaki gibi hesaplanmaktadır:

$$\mu_c = \frac{1}{hw} \sum_l^h \sum_k^w \mathbf{f}_{\text{pre}}^c(l, k) \quad (16)$$

$$\sigma_c = \sqrt{\frac{1}{hw} \sum_l^h \sum_k^w (\mathbf{f}_{\text{pre}}^c(l, k) - \mu_c)^2 + \delta} \quad (17)$$

Yukarıdaki denklemde yer alan δ , Denklem 15'in sıfıra bölünmesini önlemek için bir stabilite parametresi olarak kullanılmaktadır. SM-CNN modelimiz için $\delta = 10^{-5}$ olarak ayarlanmıştır.



Şekil 4.4 SM-CNN gürültü giderici ağımda kullanılan spektral öz-modülasyonlu kalıntı bloğu (SSMRB). Bu blok, ağı gürültüye uyarlamak için spektral komşu bantları kullanarak derin katmanlardaki özellikleri modüle etmektedir.

Teorik açıdan bakıldığında, önerilen SSMRB bloğu ile Dönüştürücü sinir ağlarının temel yapı taşı olan dikkat blokları arasında bazı paralellikler çizilebilir. Ancak, ikisi arasındaki farkları netleştirmek önemlidir. Dikkat mekanizmasının ve SSMRB bloğundaki öznitelik modülasyon şemasının işleyişindeki fark sezgilerde yatmaktadır. Özellikle, dikkat mekanizmaları belirli uzamsal konumların veya öznitelik kanallarının en yararlı bilgileri içerdiğini varsayarak ve bu konumları veya kanalları daha fazla işlem için seçmektedir. Öte yandan, SSMRB bloğu, bitişik spektral verilerin özelliklerine bağlı olarak çıkarılan öznitelik haritalarında uzamsal olarak değişken bir afin dönüşüm gerçekleştirmektedir. Komşu spektral bantlar arasındaki ilintileri ve ilişkileri dikkate alarak öznitelikleri modüle etmektedir. Bu anlamda, SSMRB bloğu normalizasyon faktörlerinin ortalama ve varyansı temsil eden ve çıkarım sırasında bitişik spektral veriler temelinde tahmin edilen özel bir tür normalizasyon katmanı olarak görülebilir. Bu uyum yeteneği, ağı giriş verilerinin belirli spektral özelliklerine kendini ayarlamasına izin verir ve farklı gürültü dağılımlarına karşı daha dayanıklı hale getirmektedir.

4.1.3. Yitim Fonksiyonu

Önerilen modelimizi eğitirken, eğitim prosedürünün stabilitesini ve verimliliğini sağlamak için kalıntı öğrenme stratejisini kullanmaktayız [30, 41]. Bir eğitim seti $\{(\mathbf{y}_i^s, \mathbf{y}_i^\lambda), \mathbf{x}_i^s\}_{i=1}^N$ verildiğini varsayalım, burada N eğitim yamalarının sayısını, \mathbf{x}_i^s gürültülü düşük kaliteli yama olan \mathbf{y}_i^s 'nin tek bantlı temiz halini, ve \mathbf{y}_i^λ ise \mathbf{y}_i^s 'nin gürültülü K bitişik spektral bandını ifade etmektedir. Parametre seti θ olan SM-CNN gürültü giderici (D_θ) için yitim fonksiyonu aşağıdaki gibi verilmektedir:

$$\mathcal{L}(\theta) = \frac{1}{2N} \sum_{i=1}^N \|D_\theta(\mathbf{y}_i^s, \mathbf{y}_i^\lambda) - \mathbf{x}_i^s\|_1 \quad (18)$$

Yukarıdaki yitim, L1 normu olarak da bilinen Ortalama Mutlak Hatadır (Mean Absolute Error; MAE). MAE, tahmin edilen ve hedef görüntüler arasındaki farkların mutlak değerini almakta ve ağı aykırı değerlere karşı doğal olarak sağlam hale getirmektedir. SM-CNN modeliz bu yitim fonksiyonunu kullanarak karışım gürültüler üzerinde eğitilmiş ve modelin sonuçları Bölüm 5.4.'te sunulmaktadır.

4.2. Çift Dikkatli Hibrit CNN ve Dönüştürücü

Bu bölümde, ikinci modelimiz olan hibrit CNN-Dönüştürücü modelini tanıtmaktayız. Bu model, hem Dönüştürücü'lerin hem de CNN'lerin güçlü yönlerinden faydalanarak, her iki yaklaşımın da eksikliklerini gidermeyi ve daha yüksek bir gürültü giderme performansı elde etmeyi hedeflemektedir.

Bölüm 3.2.2.'de bahsedildiği gibi, Dönüştürücü'lerin global öz-dikkat mekanizması, görüntülerdeki yakın piksellerin uzak olanlara göre genellikle daha güçlü ilişkileri olduğunu gösteren uzamsal düzenleri görmezden gelme eğilimindedir. Sonuç olarak, Dönüştürücü'ler genellikle bu yerel ilişkileri dolaylı olarak öğrenmek için büyük miktarda eğitim verisine ihtiyaç duymakta, bu da sınırlı veriyle HSG gürültü giderme görevlerinde zorluk yaratmaktadır. Ayrıca, HSG'lerin yüksek spektral boyutluluğu, öz-dikkat işlemlerinin

hesaplama maliyeti ve bellek gereksinimlerinin daha yüksek bant sayılarıyla artmasına neden olduğundan, Dönüştürücü tabanlı gürültü giderme yaklaşımları için dezavantaj oluşturmaktadır.

Yukarıdaki kısıtlamaları ele almak için, bu çalışma yüksek gürültü giderme performansı için her iki yaklaşımın güçlü yönlerinden yararlanan yeni bir hibrit CNN-Dönüştürücü mimarisi önermektedir. Modelimiz, iki dikkat mekanizmasını içermektedir: farklı bantlar arasındaki global spektral ilişkileri yakalayan spektral öz-dikkat ve çeşitli öznitelik kanalları boyunca bilgileri entegre ederek uzamsal ve spektral detayları yakalayan kanal bazlı öz-dikkat. Ayrıca, her katmanda derinlemesine 3B evrişim kullanarak komşu bölgelerden gelen ilintili uzamsal ve spektral bilgileri etkili bir şekilde yakalamayı amaçlamaktayız. Restorasyon performansını daha da artırmak için, öz-dikkat modüllerimiz derin öznitelikleri değiştiren kanal bazlı ve spektral öğrenilebilir restorasyon modülatörlerini içermektedir. Bu basit tasarım, yalnızca restorasyon kalitesini önemli ölçüde artırmakla kalmaz, aynı zamanda eğitim sürecinin istikrarına da katkıda bulunmaktadır. Dahası, eleman bazında çarpma yoluyla doğrusalsızlığı tanıtmak için basit geçitli doğrusal birimler (simple gate linear units) kullanılmaktadır. Bu çarpmanın doğasında var olan doğrusalsızlık özelliği, ilave doğrusalsızlığı sağlayan aktivasyon fonksiyonlarını gereksiz kılmaktadır.

Bölüm 5.5.'te, kamuya açık uzaktan algılama HSG veri kümeleri üzerinde deneyler yaparak, yaklaşımımızın mevcut en iyi gürültü giderme yöntemlerine kıyasla üstün performans gösterdiğini tartışmaktayız. Yaklaşımımız, hem nicel ölçütler hem de görsel kalite açısından mevcut teknikleri geride bırakmaktadır. Ayrıca, ağıımızı çeşitli Gauss ve karışım gürültü türleri kullanarak eğitip farklı gürültü senaryolarını ele alabilen tek bir model oluşturmaktayız.

Ana katkılarımız aşağıdaki gibi özetlenebilir:

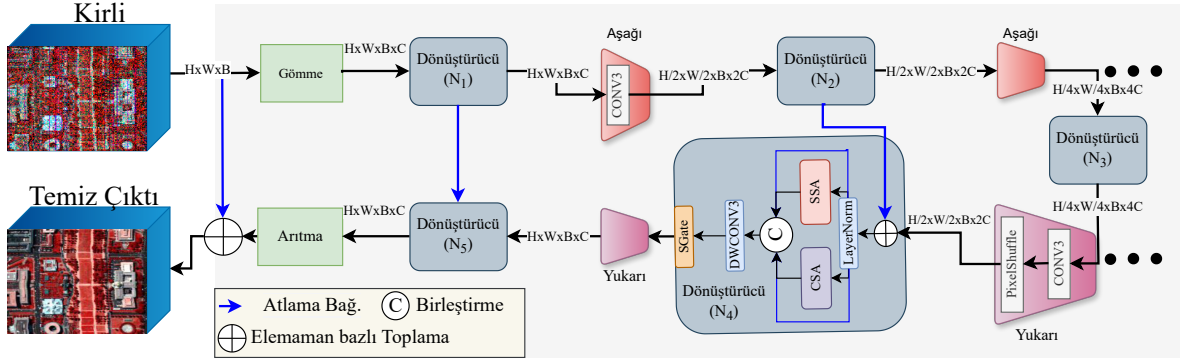
- Bildiğimiz kadarıyla modelimiz, öğrenilebilir modülatörlerle donatılmış kanal bazlı ve spektral dikkatleri eş zamanlı olarak kullanan ve ardından bu özellikleri derinlemesine 3B evrişim yoluyla entegre eden ilk modeldir.

- Spektral öz-dikkati ve kanal bazlı öz-dikkati paralel olarak kullanmaktayız, bu da modelin farklı spektral kanallardaki bilgileri birleştirirken birden fazla banttan gelen global bilgileri etkili bir şekilde modellemesine yardımcı olmaktadır. Yüksek skor alan dikkat mekanizmalarının gürültü seviyelerini azaltarak hem uzamsal hem de spektral alanlarda bilgi netliğini artırdığını göstermekteyiz.
- Gürültü giderme performansını artırmak ve eğitim sürecini stabilize etmek için, kanal bazlı ve spektral öğrenilebilir restorasyon modülatörlerini tanıtmaktayız. Araştırmamız, modülatörlerin modelimize dahil edilmesinin hassas bant önceliklendirmesini kolaylaştırdığını, dikkat dağılımının netliğini artırdığını ve eğitim kaybının azalmasına katkıda bulunduğunu göstermektedir. Bu bulgular, birlikte değerlendirildiğinde, model performansı ve genelleştirme yeteneklerinde iyileşmeye işaret etmektedir.
- Basit geçitli doğrusal birim olarak adlandırılan basitleştirilmiş bir ileri besleme katmanı önermekteyiz. Bu birimin eleman-bazlı çarpımından kaynaklanan doğal doğrusalsızlık özelliği, aktivasyon fonksiyonuna olan ihtiyacı ortadan kaldırmaktadır.
- Modelimiz, uzamsal ve spektral bilgileri korurken HSG'lerden gürültüyü gidermek için CNN ve Dönüştürücü modellerini birleştirmektedir. Önerilen bu entegrasyon şeması, hem yerel özellik ilintilerini hem de global öznelik bağımlılıklarını yakalayarak HSG gürültü giderme performansını arttırmaktadır.
- Modelimiz, hesaplama karmaşıklığını optimize etmek için uzamsal bilgiler yerine daha küçük boyutlu spektrumlar ve kanallar üzerinden öz dikkatleri oluşturmaktadır.

4.2.1. Ağ Mimarisi

Önerdiğimiz ağ mimarisi olan CST3D'yi (3B evrişim ağı ile Kanal-bazlı ve Spektral Dönüştürücü) Şekil 4.5'te genel hatlarıyla sunmaktayız. Şekilde gösterildiği gibi, CNN'ler ve Dönüştürücü'leri birleştiren hibrit bir yapı kullanmaktadır. Bu yapı, HSG verilerinin hem yerel hem de global yönlerinin kapsamlı bir analizine olanak tanımakta ve bu da gürültü giderme performansını arttırmaktadır. Özetle, ağımız dört ana bileşenden oluşmaktadır:

Gömme Katmanı, Dönüştürücü Katmanı, Yukarı/Aşağı Örnekleme Katmanları ve Arıtma Katmanı. Aşağıda, bu ana bileşenlerin ayrıntılarını vermekteyiz.



Şekil 4.5 Önerilen hibrit ağımız olan CST3D'nin genel yapısı. CST3D iki paralel öz-dikkat mekanizması kullanılmakta: spektral öz dikkat (spectral self-attention; SSA) ve kanal bazlı öz-dikkat (channel-wise self-attention; CSA). SSA global spektral bilgilerden yararlanırken, CSA uzamsal ve spektral ayrıntılara odaklanmaktadır. Bu mekanizmaların çıktıları birleştirilip ve derinlemesine 3B evrişime (DWCONV3), ardından da basit bir geçitli doğrusal birime (SGate) iletilmektedir. CST3D'deki temel bileşenlerin yapısı Şekil 4.6'da detaylandırılmaktadır.

4.2.1.1. Gömme Katmanı. Gömme katmanı (Embedding Layer), HSG'lerden 3B evrişimler kullanarak öznitelikler çıkararak yaklaşımımızda kritik bir rol oynamaktadır. Bu işlem, sonraki Dönüştürücü modülünün temel uzamsal-spektral bilgileri etkili bir şekilde yakalamasını sağlamaktadır. Bu katman ayrıca uzamsal ve spektral bilgileri daha düşük boyutlu kanal boyutuna entegre ederek Dönüştürücü'lerin karmaşıklığını etkili bir şekilde azaltmaktadır.

4.2.1.2. Dönüştürücü Katmanı. Modelimizde, Şekil 4.5'te gösterildiği gibi, atlama bağlantılarına sahip bir U-Net mimarisi benimsenmektedir. Bu tasarım, bilginin doğrudan girişten çıkışa geçmesini sağlayarak modeldeki katman ve parametre sayısını azaltarak eğitmeyi daha kolay hale getirmektedir [77]. Kodlayıcı ve kod çözücünün her seviyesinde birden fazla Dönüştürücü bloğu kullanılmaktadır. Dönüştürücü bloklarının sayısı, model performansını optimize ederken hesaplama verimliliğini sağlamak amacıyla deneysel olarak belirlenmiştir ve seviyeler arasında farklılık gösterebilmektedir.

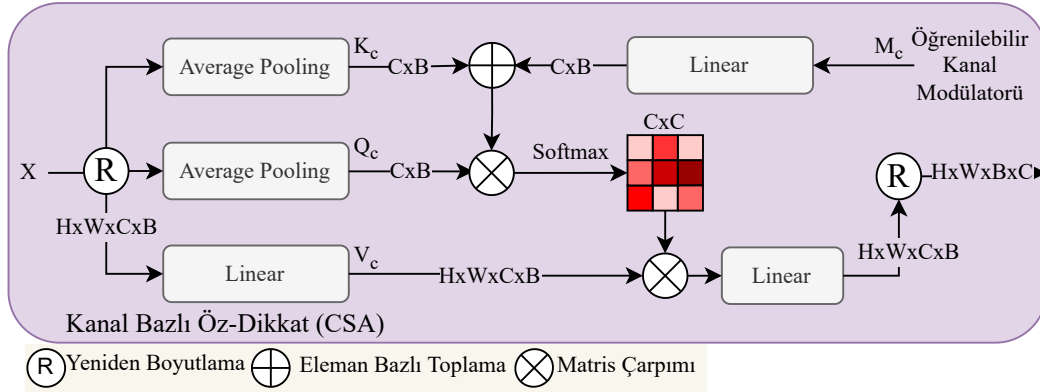
Her bir Dönüştürücü bloğu, gradyan kaybolması sorununu önlemek ve modelin verilerin karmaşık özniteliklerini yakalama yeteneğini geliştirmek için kullanılan bir katman normalizasyonu (Layer Normalization; LN) bloğuyla başlamaktadır. Ayrıca, bu blok eğitim kararlılığını da beraberinde getirmektedir. LN'nin ardından, Şekil 4.5'da gösterildiği gibi önerilen CST3D modelinin kalbini oluşturan spektral ve kanal bazlı öz-dikkatler paralel olarak yer almaktadır. Dönüştürücü'lerde ana hesaplama yükü bu öz-dikkat katmanlarından kaynaklanmaktadır. Öz dikkat mekanizması Denklem 5'te verildiği gibi girdilerin ağırlıklı toplamını hesaplamaktadır.

Vanilya öz-dikkat mekanizmasında [48, 49], anahtar-sorgu nokta çarpım etkileşiminin (Denklem 5) işlem ve bellek karmaşıklığı, girdinin uzamsal çözünürlüğü ile orantılı olarak katlanarak artmaktadır. Bu sorunu ele almak için, kanal bazlı öz-dikkat (channel-wise self-attention; CSA), büyük ölçekli görüntü işleme görevleri için umut verici bir çözüm olarak ortaya çıkmıştır [56, 57]. CSA, öz-dikkati uzamsal boyut yerine kanallar arasında uygulamaktadır. CSA, derinlemesine evrişimler gibi hesaplama açısından verimli teknikler kullanarak, kanallar arasındaki önemli ilişkileri verimli bir şekilde yakalamakta ve böylece hesaplama gereksinimlerini önemli ölçüde azaltmaktadır. Bu yaklaşım, genellikle büyük boyutlara sahip olan HSG verileri için özellikle avantaj sağlamaktadır.

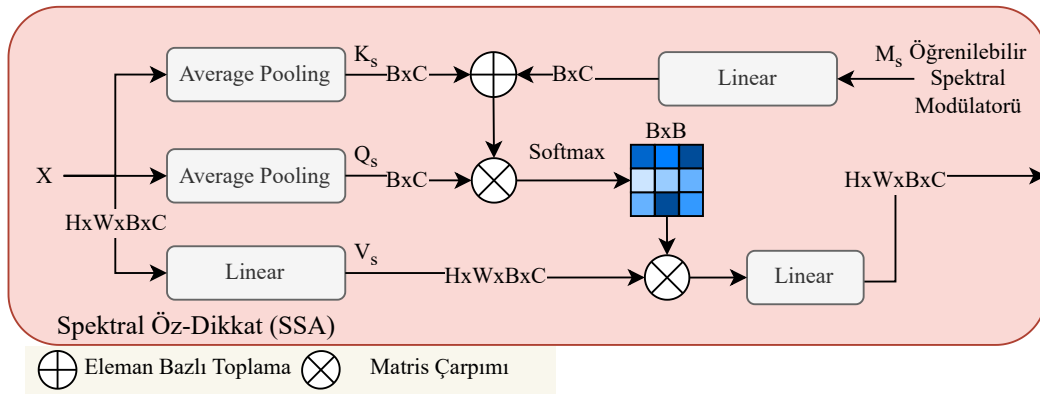
Kanal Bazlı Öz-Dikkat (Channel-wise Self-Attention, CSA). Modelimizde, CSA'nın avantajlarından yararlanarak, uzamsal ve spektral bilgiler arasındaki global etkileşimleri Denklem 19'da tanımlandığı şekilde yakalamaktayız. Kanallarımız hem uzamsal hem de spektral bilgileri içerdiği için, bu yaklaşım HSG verilerinin içindeki karmaşık etkileşimleri daha derin bir şekilde anlamamızı ve potansiyel olarak modelimizin doğruluğunu artırmamızı sağlamaktadır.

$$\text{CSA}(\mathbf{Q}_c, \mathbf{K}_c, \mathbf{V}_c) = \text{softmax} \left(\frac{\mathbf{Q}_c^\top (\mathbf{K}_c + \mathbf{M}_c \mathbf{W}_{\mathbf{M}_c})}{\sqrt{d_k}} \right) \mathbf{V}_c^\top \quad (19)$$


Basitlik açısından, girdi \mathbf{X} üzerinde uzamsal öznitelik boyutları boyunca doğrudan ortalama havuzlama (average pooling) gerçekleştirerek $\mathbf{K}_c, \mathbf{Q}_c \in \mathbb{R}^{B \times C}$ matrisleri elde



(a)



(b)



(c)

Şekil 4.6 CST3D'deki temel bileşenler. Hem spektral hem de özellik kanalları için öğrenilebilir modüller ekleyerek, modelimizin ilgili bantlara öncelik verme, dikkat odağını keskinleştirme ve eğitimi stabilize etme becerisini geliştirmekteyiz. (a) Kanal bazlı öz-dikkatin (CSA) yapısı, (b) Spektral öz-dikkatin (SSA) yapısı, (c) Basit geçitli doğrusal birim. Eleman bazında çarpma işlemi doğası gereği doğrusal olmadığından, aktivasyon fonksiyon kullanımını ortadan kaldırmaktayız.

edilmektedir. Burada B spektral bantların sayısını, C ise öznelik kanallarının sayısını temsil etmektedir. Ayrıca, derin öznelikleri ayarlamak için kanal bazlı öğrenilebilir bir restorasyon modülü ($\mathbf{M}_c \in \mathbb{R}^{C \times C}$) sunmaktayız. Bu basit tasarım, restorasyon kalitesini

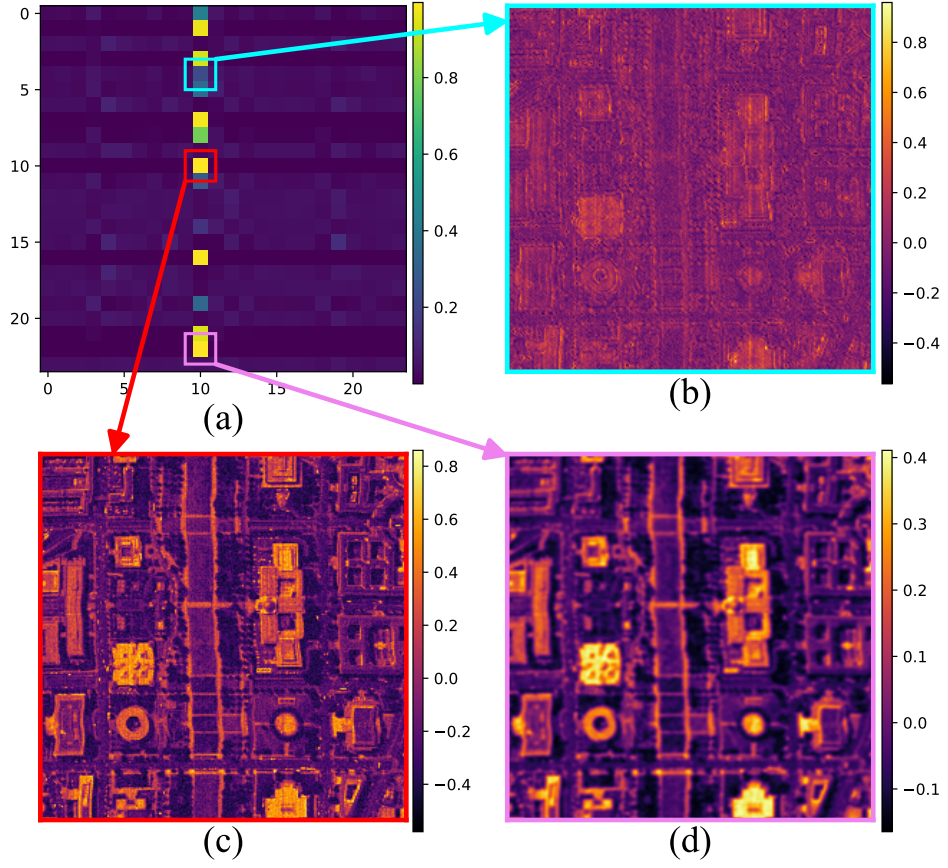
önemli ölçüde arttırmaktadır. Ardından, dikkat matrisini şu şekilde hesaplanmaktadır: $\mathbf{A}_c = \text{softmax} \left(\frac{\mathbf{Q}_c^\top (\mathbf{K}_c + \mathbf{M}_c \mathbf{W}_{M_c})}{\sqrt{d_k}} \right) \in \mathbb{R}^{C \times C}$. Burada \mathbf{W}_{M_c} , kanal bazlı modülatörü anahtar değeriyle aynı boyuta doğrusal olarak eşleyen öğrenilebilir bir ağırlık matrisidir.

Şekil 4.7, eğitilmiş modelimizin ilk katmanındaki CSA mekanizmasını göstermekte ve özniteliklere dayalı olarak belirli kanallara nasıl öncelik verdiğini etkili bir şekilde ortaya koymaktadır. Bu görselleştirme, öğrenilebilir bir modülatör ile geliştirilmiş CSA'mızın işlevselliğini anlamak için çok önemlidir. Özellikle, CSA, Şekil 4.7(a)'da gösterildiği gibi, karışık gürültüden etkilenen veriler içinde 10. kanala önemli ölçüde odaklanmaktadır. Şekil 4.7(b) ile (d) sırasıyla 4, 10 ve 22 numaralı kanallar için spektral alan boyunca ortalama öznitelikleri göstermektedir. Kanal 10'un diğerleriyle ilişkisini daha iyi anlamak için Şekil 4.8, Şekil 4.7(a)'nın 10. sütunundaki verilerin ayrıntılı bir görünümünü sunmaktadır. Bu analizlerde, yüksek dikkat skoru alan 10. kanal hem yoğunluk hem de uzamsal netlik açısından daha düşük gürültü seviyeleri sergilemektedir. Buna karşılık, gürültüye daha fazla maruz kalan 4. kanal, kanal 10 ile daha az etkileşim göstererek gürültü gidermede daha az öneme sahip olduğunu göstermektedir. Bu arada, kanal 22 bulanık görünmesine rağmen, düşük gürültü seviyesinden ötürü kanal 10 ile daha yüksek bir dikkat ilintisi sunmaktadır. Buradan model gürültü gidermek için temiz kanallara daha fazla önem vererek kendisini adapte ettiği çıkarımında bulunmak mümkündür. Bu gözlemler, modelin genel performansını artırmada kritik bir unsur olan hem spektral hem de uzamsal bilgileri öğrenme ve entegre etmede CSA mekanizmamızın etkinliğini göstermektedir.

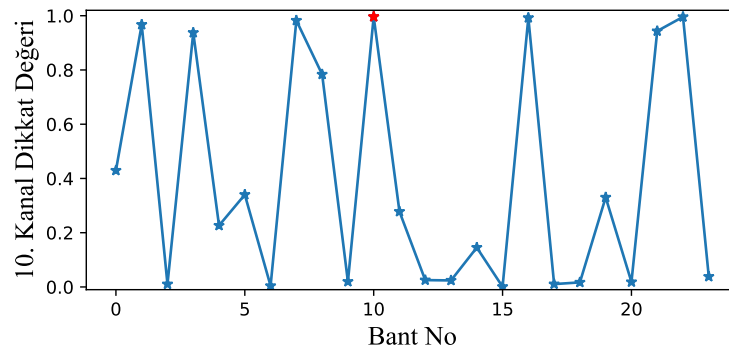
Spektral Öz-Dikkat (Spectral Self-Attention; SSA). Paralelde, aşağıdaki şekilde formüle edilebilen spektral öz-dikkat hesaplaması gerçekleştirilmektedir:

$$\text{SSA}(\mathbf{Q}_s, \mathbf{K}_s, \mathbf{V}_s) = \text{softmax} \left(\frac{\mathbf{Q}_s (\mathbf{K}_s + \mathbf{M}_s \mathbf{W}_{M_s})^\top}{\sqrt{d_k}} \right) \mathbf{V}_s \quad (20)$$

Dikkat matrisi ($\mathbf{A}_s = \text{softmax} \left(\frac{\mathbf{Q}_s (\mathbf{K}_s + \mathbf{M}_s \mathbf{W}_{M_s})^\top}{\sqrt{d_k}} \right)$) spektral bilgi ve spektral öğrenilebilir restorasyon modülatörüne (\mathbf{M}_s) dayalı olarak oluşturulmakta, ve boyutları $\mathbb{R}^{B \times B}$ olarak gösterilmekte; burada B spektral bantların sayısını ifade etmektedir. Sırasıyla \mathbf{K}_s ve \mathbf{Q}_s



Şekil 4.7 İlk katman için kanal modülatörü ile kanal bazlı öz-dikkat (CSA) haritası ve bazı öznitelik haritası kanallarının spektral spektrum boyunca ortalama değeri. (a) CSA skor matrisi, (b) Öznitelik kanalı 4, (c) Öznitelik kanalı 10, (d) Öznitelik kanalı 22.



Şekil 4.8 Şekil 4.7(a)'nın 10. sütununda gösterilen, 10. kanal ile diğer tüm kanallar arasındaki dikkat skoru.

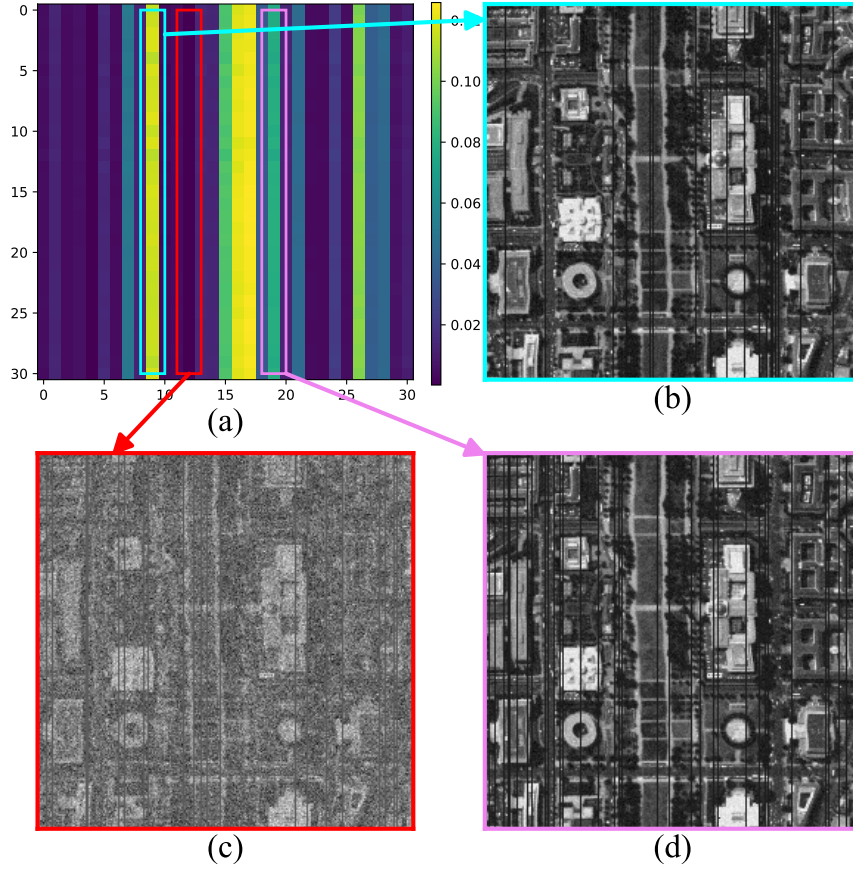
olarak gösterilen anahtar ve sorgu matrislerini oluşturmak için uzamsal öznitelik boyutları boyunca X girdisine doğrudan ortalama havuzlama (average pooling) uygulamaktadır.

Burada, W_{M_s} spektral modulatörü anahtar değerle aynı boyuta doğrusal olarak eşleyen öğrenilebilir bir ağırlık matrisidir.

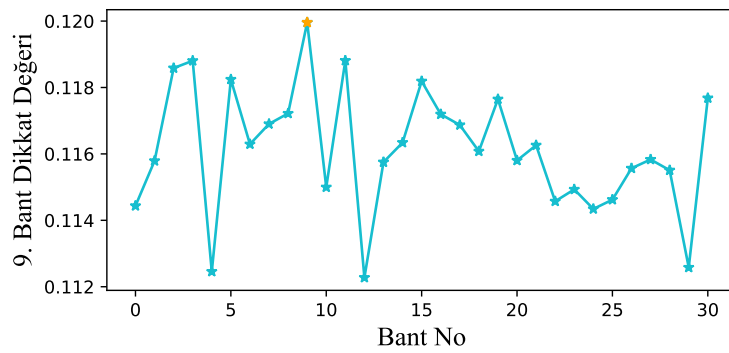
Şekil 4.9 eğitilmiş modelimizin ilk katmanındaki SSA mekanizmasını göstermektedir. Şekil 4.9(a)'da gösterilen dikkat haritası modelimizin ilk katmanına ait olduğundan, giriş sinyalinin spektral bantları arasındaki ilişkiler hakkında doğrudan bir fikir vermektedir. Bu katman dikkati, modelin başlangıçta spektral bilgileri nasıl yorumladığını ve önceliklendirdiğini ortaya koyması ve farklı bantların temel düzeyde etkileşimini göstermesi açısından çok önemlidir. Her bant, sinyal içindeki belirli örüntülere ve gürültüye verdiği tepkiyi yansıtan benzersiz bir dikkat dağılımı sunmaktadır. Spektral bant 9'un diğerleriyle nasıl etkileşime girdiğine bir örnek vermek için Şekil 4.10, Şekil 4.9(a)'nın 9. sütunundaki verilerin ayrıntılı bir görünümünü sunmaktadır. SSA, yüksek PSNR değeri sergileyen 9. banda daha fazla önem atfetmektedir. Buna karşılık, daha düşük PSNR değerine sahip 11. bant daha az dikkat skoru alırken, 9. ve 11. bantlar arasında bir PSNR değerine sahip 19. bant orta düzeyde bir skor aldığı görülmektedir. Bu gözlemler, SSA'nın dikkat dağılımını bantların PSNR değerleriyle ilişkilendirme ve böylece spektral analiz sırasında daha yüksek kaliteli bilgilere öncelik verme yeteneğinin altını çizmektedir. Bu yetenek, modelin gelişmiş spektral veri işleme ve analizi için çok önemli olan kritik spektral bilgileri ayırt etme ve vurgulama konusundaki verimliliğini göstermektedir.

Basit Geçit Birimi (Simple Gate Unit; SGate). Son olarak, kanal bazlı ve spektral dikkatleri atlama bağlantısıyla birleştirip ve derinlemesine 3B evrişim uygulamaktayız. Ardından, Şekil 4.6(c)'de gösterildiği gibi basit geçit doğrusal birim kullanılmaktadır. Eleman bazlı çarpmanın doğal doğrusalsızlığı nedeniyle, ek aktivasyon fonksiyonların kullanımına gerek kalmamaktadır. Böylece modelimizin yapısını sadeleştirmede katkıda bulunmaktayız.

Modulatörlerin (M_c ve M_s) modelimizdeki etkisini değerlendirmek için, hem bu modulatörleri içeren hem de içermeyen eğitim çalışmaları gerçekleştirdik. Şekil 4.11 her iki konfigürasyon için doğrulama verileri üzerindeki eğitim yitim değerleri ve PSNR değerlerini göstermektedir. Bu sonuçlar, modulatörlerin hariç tutulmasının eğitim sürecinde istikrarsızlığa yol açtığını, özellikle de 10. epoktaki dalgalanmalarda belirgin olduğu




Şekil 4.9 İlk katman için spektral modülatörlü spektral öz-dikkat (SSA) haritası ve bazı giriş görüntüsü spektral bantları (a) SSA skor matrisi, (b) 9. spektral bant (PSNR=20.785dB), (c) 11. spektral bant (PSNR=10.876dB), (d) 19. spektral bant (PSNR=17.199dB).



Şekil 4.10 Şekil 4.9(a)'nın 9. sütununda gösterilen 9. spektral bant ile diğer tüm bantlar arasındaki dikkat skoru.


açıkça gözükmemektedir. Bu da modülatörlerin eğitimin dengelenmesine katkıda bulunduğunu göstermektedir. Ayrıca, modülatörlerin varlığı eğitim süresi boyunca sistemin öğrenme

kapasitesini arttırdığı görülmektedir. Ek olarak, Şekil 4.12’de gösterildiği gibi, modülatörlü ve modülatörsüz eğitilmiş modellerin ilk iki katmanındaki SSA ve CSA mekanizmalarını karşılaştırmaktayız. İlk katmandan elde edilen SSA sonuçları, modülatörlerin modelin başlangıçtan itibaren belirli bantlara etkili bir şekilde öncelik vermesini sağladığını göstermektedir. Buna karşılık, modülatörlerin yokluğunda, bu önceliklendirme seviyesi yalnızca ikinci katmanda elde edilmektedir. Sonuç olarak, modülatörler modelimizin daha hızlı öğrenmesine katkıda buldukları çıkarımında bulunmak yanlış olmaz.




Şekil 4.11 Modülatörün etkisi: (a) yitim, (b) eğitim süreci boyunca doğrulama verilerinin PSNR değeri.

4.2.1.3. Yukarı/Aşağı Örnekleme Katmanları. Kodlayıcı, yüksek çözünürlüklü girdinin uzamsal boyutunu azaltırken kanal kapasitesini hiyerarşik bir şekilde artırmada kritik bir rol oynamaktadır. Öte yandan, kod çözücü düşük çözünürlüklü derin öznitelikleri girdi olarak almakta ve aşamalı olarak yüksek çözünürlüklü temsilleri yeniden oluşturmaktadır. Kodlayıcıda aşağı örnekleme elde etmek için yalnızca 3B evrişim kullanılmaktadır, bu da uzamsal boyutu etkili bir şekilde azaltırken öznitelik boyutunu iki katına çıkarmaktadır. Buna karşılık, kod çözücü özniteliklerin yukarı örneklenmesi için 3B evrişim ve ardından piksel karıştırma (pixel-shuffle) işlemi kombinasyonunu kullanmaktadır. Piksel karıştırma katmanı, geleneksel teknikler olan bilineer veya en yakın komşu enterpolasyonundan daha hızlı bir şekilde görüntülerin yukarı örneklenmesi için son derece verimli bir yöntem sunmaktadır. Özellikle, piksel karıştırma katmanı ek bir hesaplama gerektirmez, böylece işlem verimliliğini daha da artırmaktadır. Burada yapılan tüm işlemlerin amacı ağıın daha düşük seviye bilgileri yakalayarak yüksek seviye olarak tarif



(a)



(b)

Şekil 4.12 İlk iki katmanın dikkat haritaları: (a) modülatörsüz, (b) modülatörlü.

edebileceğimiz gürültüden kurtulmak hedeflenmektedir. Bunun için önce kodlayıcı blokları düşük seviye bilgileri oluşturarak gürültü etkisini azaltırken, kod çözücü blokları düşük seviye bilgilerden yüksek seviyeli temiz bilgiler oluşturmaktadır.

4.2.1.4. Arıtma Katmanı. Arıtma katmanı (Refinement Layer), Dönüştürücü katmanı tarafından çıkarılan öznitelikleri ek 3B evrişim işlemleriyle işlemektedir. Bu nedenle, bu

katmanın rolü Dönüştürücü katmanı tarafından öğrenilen temsillerin iyileştirildiği ve orijinal veri boyutuyla uyumluluğun sağlandığı bir iyileştirme adımı olarak yorumlanabilir.

4.2.2. Yitim Fonksiyonu

Diğer modelimizde olduğu gibi, CST3D'yi etkili ve verimli bir şekilde eğitilmesini sağlamak için kalıntı öğrenme stratejisini kullanmaktayız. Bu yaklaşım daha önce öğrenilen bilgilerden faydalanarak modelin kararsız hale gelmesini önlemektedir [30, 41]. Bir eğitim seti $\{\mathbf{y}_i, \mathbf{x}_i\}_{i=1}^N$ kullandığımızı varsayarsak, burada N eğitim yamalarının sayısını, \mathbf{x}_i temiz bir yamayı ve \mathbf{y}_i gürültülü düşük kaliteli bir yamayı ifade etmektedir. Dolayısıyla, eğitim sırasında kullandığımız Charbonnier yitim fonksiyonunu aşağıdaki gibi tanımlanmaktadır:

$$\mathcal{L}(\theta) = \sqrt{\frac{1}{2N} \sum_{i=1}^N \|D_{\theta}(\mathbf{y}_i) - \mathbf{x}_i\|_2^2} + \epsilon \quad (21)$$

Yukarıdaki denklemde, D_{θ} ağıımızı temsil etmekte, θ ağın öğrenilebilir parametre seti (CNN ve Dönüştürücü katmanların parametreleri) ve $\epsilon = 10^{-3}$ bir sabittir.

Charbonnier yitim fonksiyonu, MAE ve ortalama kare hatası (Mean Squared Error; MSE) yöntemlerinin avantajlarını birleştirmektedir. Bu avantaj, MSE'ye kıyasla aykırı değerlere karşı daha az hassas olmasını ve MAE'den daha yumuşak olmasını sağlamakta, bu da eğitim sırasında daha iyi yakınsama elde edilmesine yardımcı olmaktadır. Modelimizi bu yitim fonksiyonunu kullanarak Tablo 5.8'de verilen stratejiyi izleyerek eğitip, sonuçları Bölüm 5.5.'te sunmaktayız.

4.3. Öz-Gözetimli Gürültü Giderme Ağlarının Kalibrasyonu

Genel olarak, sinir ağları gözetimli bir şekilde eğitilmekte ve daha sonra görünmeyen veriler üzerinde test edilmektedir. Gözetimli eğitim büyük miktarda veri gerektirmekte ve ayrıca temiz görüntülere dayanmaktadır. Ancak, HSG'ler için çok sayıda görüntü toplamak ve temiz görüntüler elde etmek zor ve maliyetlidir. Sonuç olarak, sinir ağlarının gözetimli

yöntemlerle eğitilmesi bu tür durumlar için zorlayıcı hale gelmektedir. Dinamik ağılar veri adaptasyonunu geliştirmede etkili olsa da, HSG verilerinin önemli spektral değişkenlik gösterdiği durumlarda performans düşüşü meydana gelmektedir. Bu bölümde, hem ön eğitimden hem de öz-gözetimli kalibrasyondan yararlanan iki aşamalı öğrenme stratejimizi tanıtmaktayız.

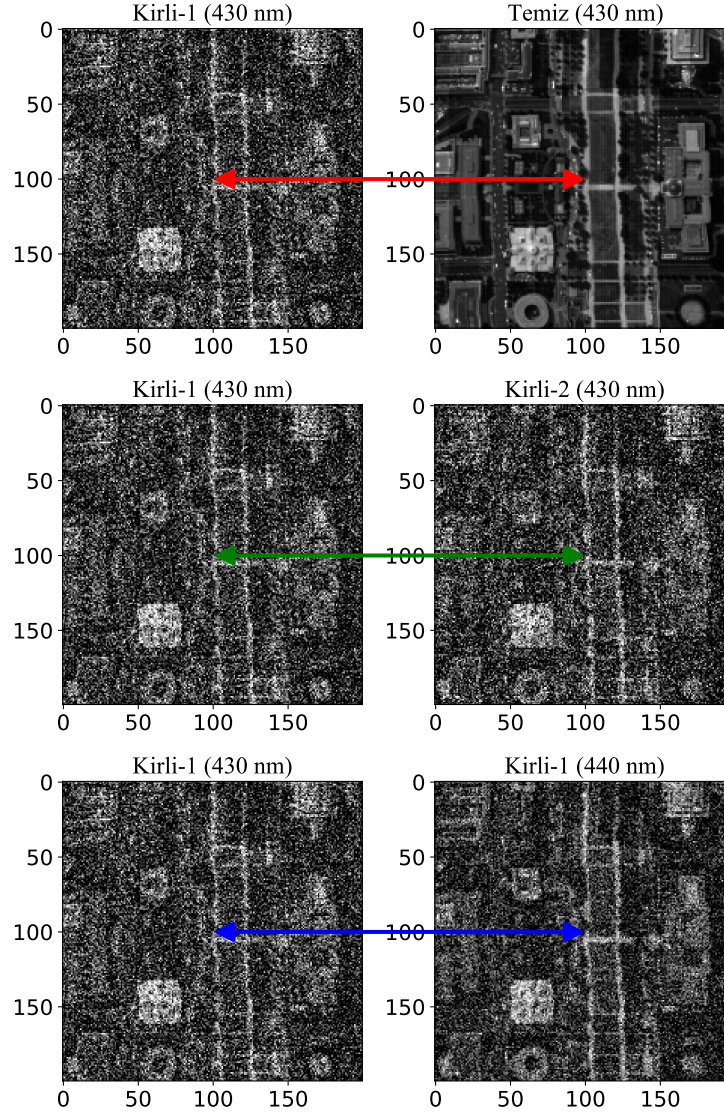
Bu çalışmada, ayrıntılı spektral bilgileri yakalayan HSG'deki komşu bantların birbirlerinin içeriğini tahmin edip edemeyeceğini araştırdık. Bunu, belirli bant çiftleri (Şekil 4.13'te mavi okla gösterilen eğitim çifti) arasındaki "karşılıklı bilgi (mutual information)" adlı bir ölçüyü hesaplayarak gerçekleştirmekteyiz. Bu metrik her bir bandın komşularıyla ne kadar bilgi paylaştığını bize göstermektedir.

Şekil 4.13'de bir HSG'den alınan $430nm$ bandına sahip temiz görüntü, temiz görüntünün her bandına bağımsız olarak üretilen farklı gürültüler eklenerek oluşturulan kirli-1 ve kirli-2 verilerinden alınan $430nm$ bandı ve kirli-1'den alınan $440nm$ bandı gösterilmektedir. Gözetimli öğrenme, şekilde verilen kirli-1 verilerini tahmin etmek için temiz veriler (Şekil 4.13'de kırmızı ok ile gösterilen eğitim çifti) kullanılarak gerçekleştirilmektedir. Noise2Noise yönteminde, kirli-1'i tahmin etmek için kirli-1'den bağımsız olarak bozulmuş başka bir gürültülü görüntü, yani kirli-2 verisi (Şekil 4.13'de yeşil okla gösterilen eğitim çifti) kullanılarak eğitim gerçekleştirilmektedir.

Öncelikle, A ve B gibi iki rastgele değişken verildiğinde, bunların karşılıklı bilgisi, $I(A, B)$, Denklem 22'de verildiği gibi hesaplanmaktadır. Denklemde, $p(a)$ ve $p(b)$ sırasıyla A ve B sinyallerinin marjinal olasılık yoğunluk fonksiyonlarını ve $p(a, b)$ bileşik olasılık yoğunluk fonksiyonunu temsil etmektedir.

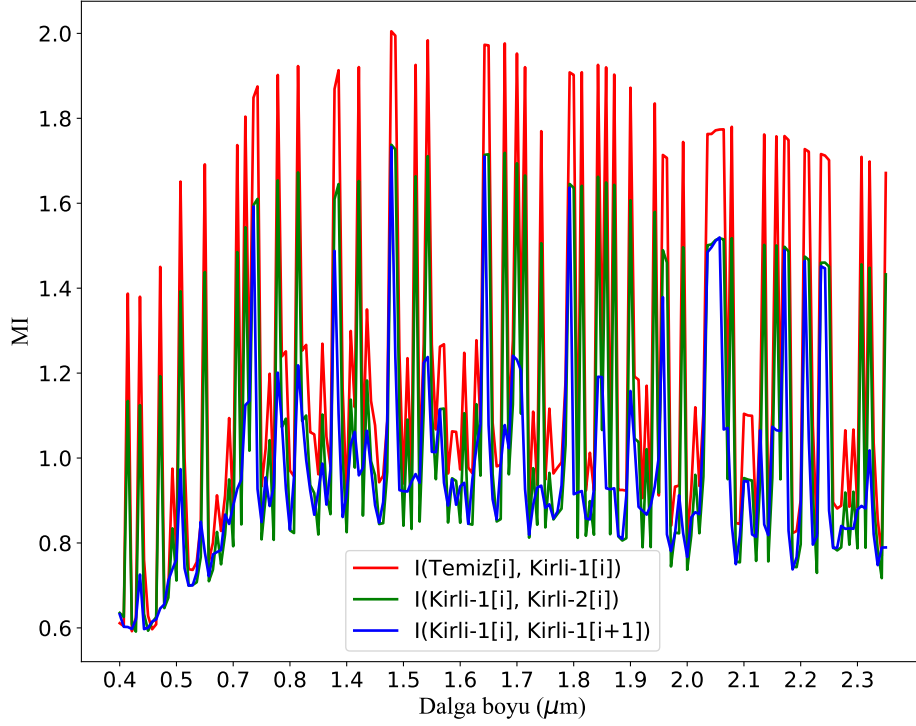
$$I(A, B) = \sum_{a,b} p(a, b) \log \frac{p(a, b)}{p(a)p(b)} \quad (22)$$

Bu denklem kullanılarak Şekil 4.13'te renkli oklarla gösterilen görüntü çiftlerinin her bir bandı için elde edilen karşılıklı bilgi Şekil 4.14'te gösterilmektedir. Bu şekilde farklı görüntü çiftleri arasında hesaplanan karşılıklı bilginin spektral bantlar boyunca benzer bir dağılıma



Şekil 4.13 Eğitim çiftleri renkli oklarla gösterilmektedir. Kırmızı ok: gürültüden temize eğitim çifti, Yeşil ok: gürültüden gürültüye eğitim çifti, Mavi ok: banttan banda eğitim çifti. Banttan banda eğitim çiftinde, görüntülerin dalga boyları farklıdır.

sahip olduğu görülmektedir. Bu sonuçta, temiz bantlar kullanılarak kirli-1 verisi hakkında daha fazla bilgi çıkarılabileceği de anlaşılmaktadır. Öte yandan, başka bir gürültülü veri kullanılarak, hatta bu verinin komşu bantları kullanılarak bile kirli-1 verisi hakkında benzer bilgilerin çıkarılabileceği görülmektedir.

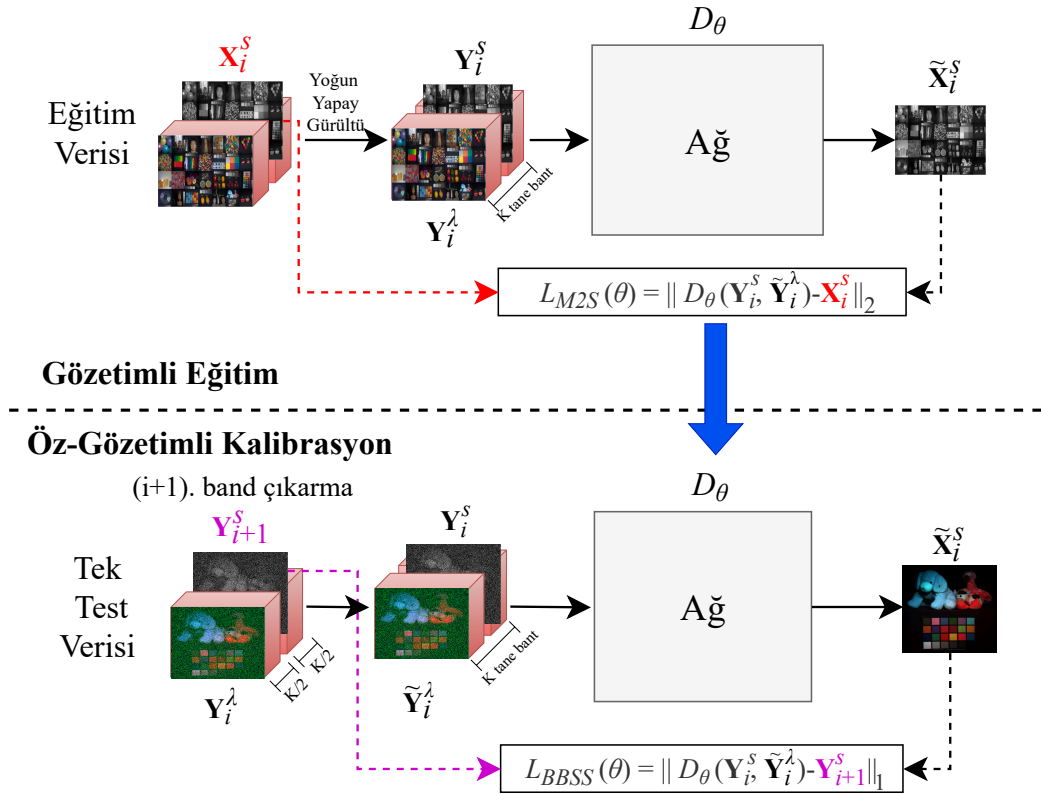


Şekil 4.14 Kırmızı çizgi: i . temiz bant ve i . kirli-1 bant arasındaki karşılıklı bilgi, Yeşil çizgi: i . kirli-1 bandı ile i . kirli-2 bandı arasındaki karşılıklı bilgi, Mavi çizgi: Kirli-1 verisinin $\{i., (i + 1).\}$ bantları arasındaki karşılıklı bilgi.

4.3.1. İki Aşamalı Öğrenme: Kör Bant Öz-Gözetimli Öğrenme

Karşılıklı bilgi ile elde edilen sonuçlardan ilham alarak, Şekil 4.15'te verilen iki aşamalı bir HSG gürültü giderme yöntemi önermekteyiz. Bölüm 1.1.1.'de belirtildiği gibi, ilk aşama, M2S adı verilen gözetimli bir öğrenme tekniği kullanarak HSG'nin bireysel bantlarını gürültüden arındırmak için derin sinir ağı modelini eğitmeyi içermektedir. Bu yöntemde model, gürültülü ve temiz çiftlerinden oluşan bir veri seti kullanılarak eğitilmekte ve gürültü giderme işlemi için hem çok ölçekli uzamsal hem de çok ölçekli spektral bitişik bantları dikkate alınmaktadır. İkinci aşamada ise, temiz veri gerektirmeden ilgili ağı, görülmemiş gürültülü veriler üzerinde kalibre etmek için öz-gözetimli bir öğrenme yaklaşımı önermekteyiz. Yaklaşımımız, Bölüm 2.4.'te ayrıntıları verilen Noise2Noise [95] ve Noise2Void [47] yöntemlerinden ilham almıştır ve hedef bandı çıkararak girdide bir kör nokta oluşturup komşu bandı hedef olarak kullanmayı içermektedir. Bu sayede ağı kalibre

ederek, görülmemiş gürültülü veriler üzerindeki performansını arttırmak mümkündür. Genel olarak, Noise2Noise öğrenme, yalnızca gürültülü gözlemlerin mevcut olduğu görüntüleri gürültüden arındırma yöntemidir. Bu yöntem, aynı görüntünün iki farklı gürültülü gözlemi verildiğinde, iki gözlem arasındaki farkın temiz görüntüyü tahmin etmek için kullanılabileceği fikrine dayanmaktadır. Ancak, bu yöntem, aynı içeriğe sahip ve bağımsız olarak gürültü ile bozulmuş iki farklı görüntü gerektirmektedir.



Şekil 4.15 İki aşamalı öğrenme şemasına genel bakış. Ağ mimarisi uygun herhangi bir mimari olabilmektedir. Örneğin, Bölüm 5.6.'da hem CST3D modelimizi hem de literatürden CNNFormer ve QRN3D'yi modellerini kullanmaktayız.

Yaklaşımımız, *kör bant öz-gözetimli (blind band self-supervised; BBSS)* olarak adlandırılmakta olup, tek bir HSG kullanarak önerilen modeli kalibre etmek için özel olarak tasarlanmıştır. HSG'lerin yüksek çözünürlüklü spektral bilgiye sahip birçok bandı olduğu (≤ 10 nm) ve her bir bandın bağımsız olarak bozulduğu varsayımı dikkate alınmıştır. Bu bağlamda, eğitim işleminin amacı, verilen bir giriş spektral bandı Y_i için, ağ fonksiyonunun

çıktısı $D_\theta(\mathbf{Y}_i)$ ile hedef spektral bandı \mathbf{X}_i arasındaki kaybı en aza indiren parametreler kümesini θ' 'yi bulmaktır. Bu, S2S eğitimi varsayımıyla aşağıdaki şekilde yazılabilir:

$$\operatorname{argmin}_\theta \mathbb{E}_{(\mathbf{Y}_i, \mathbf{X}_i)} \{L(D_\theta(\mathbf{Y}_i), \mathbf{X}_i)\} \quad (23)$$

Noise2Noise [45] yöntemine dayanarak, ağ fonksiyonunun çıktısı $D_\theta(\mathbf{Y}_i)$ ile bitişik spektral band \mathbf{Y}_{i+1} arasındaki kaybı en aza indirmek için komşu bandı hedef olarak kullanmayı önermekteyiz. Bu, verilen giriş spektral bandı \mathbf{Y}_i için aşağıdaki gibi ifade edilebilir:

$$\operatorname{argmin}_\theta \mathbb{E}_{(\mathbf{Y}_i, \mathbf{Y}_{i+1})} \{L(D_\theta(\mathbf{Y}_i), \mathbf{Y}_{i+1})\} \quad (24)$$

M2S öğrenme yaklaşımını takip ederek, yukarıdaki ifadeyi her bandı gürültüden arındırmak için komşu bantlardan gelen spektral bilgiyi ve uzamsal bilgiyi de girdi olarak dahil edecek şekilde değiştirilebilir:

$$\operatorname{argmin}_\theta \mathbb{E}_{(\mathbf{Y}_i, \mathbf{Y}_{i+1})} \{L(D_\theta(\mathbf{Y}_i, \mathbf{Y}_i^\lambda), \mathbf{Y}_{i+1})\} \quad (25)$$

Burada, \mathbf{Y}_i^λ , hedef spektral bandı \mathbf{Y}_{i+1} de dahil olmak üzere, \mathbf{Y}_i 'nin K komşu spektral bandından oluşan bir kümeyi ifade etmektedir. Ancak, hedefteki bant giriş olarak verildiğinde, ağın sadece birim eşlemesini öğrenmesi beklenmektedir. Bunu önlemek için, Noise2Void [47] yönteminin tek bir piksel için yaptığı gibi, hedef bandı girişten çıkararak spektral bantlarda bir kör nokta oluşturmaktayız. Bu nedenle, Denklem 25 aşağıdaki gibi yeniden yazılabilir:

$$\operatorname{argmin}_\theta \mathbb{E}_{(\mathbf{Y}_i, \mathbf{Y}_{i+1})} \{L(D_\theta(\mathbf{Y}_i, \tilde{\mathbf{Y}}_i^\lambda), \mathbf{Y}_{i+1})\} \quad (26)$$

Burada, $\tilde{\mathbf{Y}}_i^\lambda$, komşu spektral bant kümesinden hedef bandı olan \mathbf{Y}_{i+1} çıkarılarak elde edilmektedir. Böylece, girdide bir spektral kör nokta oluşturularak ağın birim eşlemesi öğrenmesi engellenmektedir.

İki aşamalı öğrenme stratejimizin her aşaması için farklı kayıp fonksiyonları kullanmaktayız. Gözetimli öğrenme aşamasında, bir M2S eğitim seti verildiğini kabul edersek, $\{(\mathbf{Y}_i^s, \mathbf{Y}_i^\lambda), \mathbf{X}_i^s\}_{i=1}^N$, burada N eğitim yama sayısını, \mathbf{X}_i^s gürültülü düşük kaliteli yama olan \mathbf{Y}_i^s 'nin temiz karşılığını ve \mathbf{Y}_i^λ , \mathbf{Y}_i^s 'nin gürültülü K bitişik spektral bantlarını temsil etmektedir. Parametre seti θ olan gürültü giderici (D_θ) için yitim fonksiyonu şu şekilde ifade edilmektedir:

$$\mathcal{L}_{M2S}(\theta) = \frac{1}{2N} \sum_{i=1}^N \|D_\theta(\mathbf{Y}_i^s, \mathbf{Y}_i^\lambda) - \mathbf{X}_i^s\|_2 \quad (27)$$

BBSS eğitim seti $\{(\mathbf{Y}_i^s, \tilde{\mathbf{Y}}_i^\lambda), \mathbf{Y}_{i+1}^s\}_{i=1}^N$ verildiğinde, burada \mathbf{Y}_{i+1}^s düşük kaliteli yama olan \mathbf{Y}_i^s 'nin bitişik bandını, ve $\tilde{\mathbf{Y}}_i^\lambda$ bitişik spektral bantlardan hedef bandı (\mathbf{Y}_{i+1}^s) çıkararak elde edilen veri kümesini temsil etmektedir. Önerilen öz-gözetimli eğitim şemasının yitim fonksiyonu aşağıdaki gibi tanımlanmaktadır:

$$\mathcal{L}_{BBSS}(\theta) = \frac{1}{2N} \sum_{i=1}^N \|D_\theta(\mathbf{Y}_i^s, \tilde{\mathbf{Y}}_i^\lambda) - \mathbf{Y}_{i+1}^s\|_1 \quad (28)$$

Hatalar küçük ve tutarlı olduğunda, MSE daha büyük hatalara vurgu yaptığı için daha hızlı eğitim sağlamaktadır. MSE, hata terimini karesini alarak, önemli hatalar için cezayı artırmakta ve modelin eğitim sırasında bunları düzeltmeye öncelik vermesini sağlamaktadır. Bu nedenle, küçük varyasyonlu yoğun gürültü (örneğin, GN) içeren veriler üzerinde bir model eğitilirken, birinci aşamada MSE veya Charbonnier kaybını kullanmayı tercih etmekteyiz. Öte yandan, MAE, tahmin edilen ve hedef görüntüler arasındaki farkların mutlak değerini almaktadır. Bu özellik, MAE'yi doğal olarak aykırı değerlere karşı dayanıklı hale getirmektedir. Bu nedenle, ikinci aşamada, yüksek varyasyonlu seyrek gürültüyü (örneğin, IN) azaltmayı hedeflerken, MAE bu görev için daha uygun olmaktadır.

5. DENEYSEL SONUÇLAR

Bu bölüm, önerilen yöntemlerimizin deneysel değerlendirmesini araştırarak, performanslarını kapsamlı bir şekilde değerlendirmek için hem yapay hem de gerçek dünya veri kümelerini kullanmaktadır. Farklı gürültü türlerinin etkisini izole etmek ve analiz etmek için kontrollü gürültü koşullarına sahip yapay gürültülü veri kümelerini dikkatlice oluşturmaktayız. Gerçek dünya veri kümelerini kullanarak modellerimizi pratik senaryolara uyarlamaktayız. Bu sayede, modellerimizin genelleme ve dayanıklılık yetenekleri hakkında derin bilgiler edinmekteyiz.

Adil ve bilgilendirici bir karşılaştırma sunmak için, alanda yaygın olarak tanınan kıyaslama ölçütlerini kullanmaktayız. Bu karşılaştırmalı analiz, yöntemlerimizin çeşitli gürültü senaryoları ve gerçek dünya karmaşıklıklarında mevcut yaklaşımlara karşı etkinliğinin net bir resmini sunmaktadır.

Yapay ve gerçek veri kümeleri aracılığıyla yöntemlerimizin kapsamlı bir analizini gerçekleştirerek pratik uygulamalarda ve gelecekteki gelişmeler için potansiyellerini ortaya çıkarmayı hedeflemekteyiz.

Bu bölümde sırasıyla, deneylerde kullanılan veri kümelerini tanıtmaktayız, ardından kullanılan yapay gürültü ayarlarına bir giriş yapmaktayız. Daha sonra, her model için deneysel ayarları ve sonuçları sunmaktayız. Ardından, modellerimizin etkinliğini ayrı ayrı göstermek için her bir modelimiz için bir bileşen işlevsellik analizleri çalışması sunmaktayız.

5.1. Veri Kümeleri

Önerilen yöntemlerin etkinliğini değerlendirmek için yedi HSG veri kümesi ele alınmaktadır. Bunlardan bazıları ağları eğitmek ve farklı Gauss ve karışım yapay gürültü ekleyerek deneyler yapmak için kullanılırken, diğerleri önerilen modellerin performansını değerlendirmek için yapay gürültü ve gerçek gürültü deneylerinde kullanılmaktadır. Veri

kümelerinin genel özellikleri Çizelge 5.1’de verilmiş olup deneylerde kullanılan parçalar aşağıdaki şekilde özetlenmektedir:

Çizelge 5.1 Deneylerde Kullanılan Veri Kümelerinin genel özellikleri.

Veri	Sensör	Uzamsal boyut (piksel)	Dalga Boyu (nm)	#bant	#görüntü
ICVL	Specim PS Kappa DX4 kamera	1392×1300	400 - 1000	31	201 görüntü
WDC	HYDICE airborne sensör	1208×307	400 - 2400	210	1 görüntü
CAVE	Apogee Alta U260 kamera	1392×1300	400 - 700	31	32 görüntü
PU	ROSIS sensör	610×610	430 - 860	103	1 görüntü
IP	AVIRIS sensör	145×145	400 – 2500	224	1 görüntü
URBAN	HYDICE hava sensörü	307×307	400 – 2500	210	1 görüntü
HSIDwRD	SOC710-VP kamera	696×520	400 - 700	34	59 temiz ve kirli çift

- *ICVL*¹: Veri kümesi, görünür bant ve yakın kızılötesi bantta çekilmiş görüntüleri içermektedir. 31 spektral bantta 1392×1300 uzamsal çözünürlükte 201 görüntü toplanmıştır. Veri kümesi; eğitim, doğrulama ve test için rastgele üç ayrı segmente ayrılmaktadır. Eğitim süresi göz önünde bulundurularak, modellerimizi eğitmek için 100 görüntü, doğrulama için 20 görüntü ve test için geri kalan görüntüler seçilmektedir. Eğitim veri kümesini genişletmek amacıyla, görüntülerin her biri 64×64 piksel ve 31 spektral bant boyutlarında örtüşen çok sayıda küpe bölmekte ve bu süreçte spektral alanın bütünlüğünü korumaktayız. Ayrıca, eğitim sırasında veri artırımı için döndürme ve ölçekleme gibi dönüşümler uygulamaktayız. Test ve doğrulama için görüntüler 512×512×31 boyutlarına kırılmaktadır.
- *Washington DC Mall (WDC*²): Bu veri HYDICE hava sensörü ile elde edilmiştir. Bu sensör sistemi, görünür ve kızılötesi spektrumun 0.4 ila 2.4 μm bölgesindeki 210 spektral bandı kaydetmektedir. Atmosferik girişimin olduğu 0.9 ve 1.4 μm bölgelerindeki bantlar veri kümesinde çıkarılmıştır. Dolayısıyla, WDC verisinin küp boyutu 1208×307×191 pikseldir. Veri kümesini iki bölüme ayırmaktayız: biri önceden eğitilmiş ağlara ince ayar

¹<http://icvl.cs.bgu.ac.il/hyperspectral/>

²<https://engineering.purdue.edu/~biehl/MultiSpec/hyperspectral.html>

yapmak için, diğeri ise test amaçlı. Orijinal görüntüye yapay karışım gürültü eklenerek simüle edilen veri deneyleri için $200 \times 200 \times 191$ piksellik bir alan kullanılmaktadır.

- *CAVE*³: Apogee Alta U260 kamerası kullanılarak toplanan bu veriler, önerilen modelleri ve diğder derin öğrenme yöntemlerini eğitmek için kullanılmaktadır. Veri kümesi, görünür spektrumun 0.4 ila 0.7 μm bölgesinde 31 spektral bant içermekte ve 512×512 piksel uzamsal çözünürlüğe sahip 32 sahneden oluşmaktadır. Bu 32 görüntüden 25'i ağıları eğitmek için kullanılırken, kalan görüntüler doğrulama ve test amaçları için kullanılmaktadır.
- *Pavia University (PU)*⁴: Bu veriler İtalya'nın Pavia kenti üzerinde ROSIS sensörü ile elde edilmiştir. Spektral aralığı 0.43 ila 0.86 μm olan $200 \times 200 \times 103$ boyutundaki sahne, 12 su soğurma bandı çıkarıldıktan sonra karışım gürültüsü eklenerek yapay veri deneyinde kullanılmaktadır.
- *Indian Pines (IP)*⁵: IP verileri AVIRIS sensörü ile Indian Pines test sahası üzerinde toplanmıştır ve 0.4-2.5 μm [96] dalga boyu aralığında 145×145 piksel ve 224 spektral banttandır oluşmaktadır. Atmosfer ve sudan ciddi şekilde zarar gören bantlar (150-163) çıkarıldıktan sonra, gerçek deneylerde toplam 206 bant kullanılmaktadır.
- *URBAN*⁶: Görüntünün uzamsal çözünürlüğü 307×307 pikseldir ve her piksel 2 metreye 2 metrelik bir zemin alanına karşılık gelmektedir. Spektral olarak görüntü, spektrumun görünür (0.4 μm) ile 2.55 μm arasında değişen 210 dalga boyunda bilgi yakalamaktadır. Spektral çözünürlük 10 nm'dir. Veri, doğal gürültü içeren gerçek dünya durumlarında deneysel sonuçların geçerliliğini doğrulamak için kullanılmaktadır.
- *HSIDwRD*⁷: Bu veriler, 696×520 piksel uzamsal çözünürlüğe ve 0.4 μm ila 0.7 μm arasında 34 spektral banda sahip bir SOC710-VP hiperspektral kamera ile elde edilmiştir. Veri kümesi, uzun pozlama ayarları kullanılarak çekilen 59 temiz görüntü ve kısa

³<https://www1.cs.columbia.edu/CAVE/databases/multispectral/>

⁴<http://lesun.weebly.com/hyperspectral-data-set.html>

⁵<https://purrr.purdue.edu/publications/1947/about?v=1>

⁶<https://rslab.ut.ac.ir/data>

⁷<https://github.com/ColinTaoZhang/HSIDwRD>

pozlama ayarları kullanılarak alınmış temiz verilere karşılık gelen gürültülü görüntüleri içermektedir. Gerçek test deneylerinde, görüntüleri orijinal uzamsal bölgelerinden $512 \times 512 \times 34$ boyutuna kırparak kullanılmaktadır.

5.2. Değerlendirme Metrikleri

Görsel karşılaştırmaya ek olarak, simüle edilmiş veriler üzerinde önerilen yaklaşımların performansını değerlendirmek için yaygın olarak kullanılan üç ölçüt benimsenmektedir: ortalama tepe sinyal-gürültü oranı (peak signal-to-noise-ratio; MPSNR) [97], ortalama yapısal benzerlik indeksi (mean structural similarity index; MSSIM) [98] ve spektral açı eşleyici (spectral angle mapper; SAM) [99]. MPSNR ve MSSIM, sırasıyla Denklem 29'da ve Denklem 30'da verildiği gibi her bir 2B uzamsal görüntü üzerinde hesaplanmakta ve tüm spektral bantlar üzerinden ortalaması alınan uzamsal doğruluğu göstermektedir. Spektral doğruluğu gösteren SAM, Denklem 31'de gösterildiği gibi her 1B spektral vektör üzerinde hesaplanmakta ve tüm uzamsal noktalar üzerinden ortalaması alınmaktadır. Daha yüksek MPSNR ve MSSIM skorları ile daha düşük SAM skoru, daha iyi gürültü giderme sonuçları anlamına gelmektedir.

$$PSNR = 10 \times \log_{10} \left(\frac{MAX^2}{MSE} \right) \quad (29)$$

Burada MAX net görüntünün maksimum piksel değerini ifade etmekte ve MSE tahmin edilen görüntü ile referans net görüntü arasındaki ortalama kare hatayı temsil etmektedir.

$$SSIM(\mathbf{X}_i, \mathbf{Y}_i) = \frac{(2\mu_{\mathbf{X}_i}\mu_{\mathbf{Y}_i} + C_1)(2\sigma_{\mathbf{X}_i\mathbf{Y}_i} + C_2)}{(\mu_{\mathbf{X}_i}^2 + \mu_{\mathbf{Y}_i}^2 + C_1)(\sigma_{\mathbf{X}_i}^2 + \sigma_{\mathbf{Y}_i}^2 + C_2)} \quad (30)$$

Yukarıdaki denklemde $\mu_{\mathbf{X}_i}$ ve $\mu_{\mathbf{Y}_i}$, görüntülerin piksel ortalamasını temsil ederken, $\sigma_{\mathbf{X}_i}^2$ ve $\sigma_{\mathbf{Y}_i}^2$ görüntülerin varyansını ifade etmektedir. $\sigma_{\mathbf{X}_i\mathbf{Y}_i}$, \mathbf{X}_i ve \mathbf{Y}_i 'nin kovaryansını belirtmektedir, C_1 ve C_2 bölmeyi stabilize etmek için kullanılan sabitleri ifade etmektedir.

$$SAM(\mathbf{r}, \mathbf{t}) = \cos^{-1} \left(\frac{\sum_{i=1}^B (r_i t_i)}{\sqrt{\sum_{i=1}^B r_i^2} \sqrt{\sum_{i=1}^B t_i^2}} \right) \quad (31)$$

Denklem 31'de yer alan \mathbf{t} B uzunluğunda tahmin edilen spektral imza ve \mathbf{r} ise B uzunluğunda referans spektral imzadır.

Önerilen modellerin etkinliğini daha iyi değerlendirmek için, gerçek veri deneylerimizde gerçek dünyadan gürültülü HSG veri kümeleri kullanılmaktadır. Yöntemlerin performansı, temiz referans görüntüsü bulunmayan gerçek veriler için bir sınıflandırma işlemi yapılarak değerlendirilmektedir. SVM [100] sınıflandırıcı, gürültü giderme işlemi öncesinde ve sonrasında kullanarak sınıflandırma performansları kıyaslamaktadır. Sonuç olarak, değerlendirme indeksleri olarak toplam doğruluk (overall accuracy; OA) ve kappa katsayısı kullanılmaktadır.

5.3. Yapay Gürültü Ayarları

Eğitim ve test işlemlerinden önce, her spektral banttaki değerler $[0,1]$ aralığına normalize edilmektedir. Gauss gürültü deneyleri için modellerin performansı çeşitli Gauss gürültü yoğunluk seviyeleri ($\sigma = 30, 50, 70$ kör test için σ 30 ile 70 arasında değişmektedir) üzerinden test edilmektedir. Ayrıca, daha gerçekçi ve zorlu senaryolar oluşturmak için simüle edilmiş deneylere beş tür yaygın kullanılan karmaşık gürültü eklenmektedir. Farklı senaryolar aşağıda listelenmektedir:

- **Durum 1:** i.i.d. olmayan GN (σ 10 ila 70 arasında değişen) tüm bantlara etkilemektedir.
- **Durum 2:** Durum 1'deki GN'ye ek olarak, SN bantların 1/3'ünü (sütunların %5-15'i) etkilemektedir.
- **Durum 3:** Durum 1'deki GN'ye ek olarak, bantların 1/3'ünü etkileyen DN (sütunların %5-15) eklenmektedir.

- **Durum 4:** Durum 1'deki GN'ye ek olarak, 10 ila 70 arasında deęişen yoğunluklarla bantların 1/3'ünü etkileyen IN eklenmektedir.
- **Durum 5:** Durum 1'den GN ve Case 2-4'ten her bir bandı en az bir gürültü türünün uygulandıęı karışım gürültü eklenmektedir.

5.4. Performans Deęerlendirmesi: SM-CNN

Önerilen SM-CNN yönteminin etkinlięi hem yapay gürültülü hem de gerçek gürültülü HSG'ler kullanılarak deęerlendirilmektedir. İlk olarak, yöntemin etkinlięi yapay gürültü eklenerek simüle edilmiş veriler kullanılarak doęrulanmaktadır. Daha sonra önerilen yöntem gerçek gürültülü görüntülere uygulanmaktadır. Önerilen yöntem, kodları kamuya açık klasik yaklaşımlar olan TDL [101], LRTF-DFR [62], FastHyMix [71], BM4D [68], LRMR [21], LRTV [22] ve LRTDTV [23] ile karşılaştırılmaktadır. Derin öğrenme alanında, önerilen yöntem HSID-CNN [30], MemNet [73], QRNN3D [32], HDNET [76] ve MAN [88] ile karşılaştırılmaktadır. Adil bir karşılaştırma için, MemNet'i 6 bellek bloęu ve 6 kalıntı bloęu olan bir versiyonunu önerilen yöntem gibi eğitmekteyiz. Bunun için giriş katmanı filtresi K , çıkış katmanı 1 olarak ayarlanmakta ve eğitimi Bölüm 4.1.1.'de önerildięi şekilde gerçekleştirilmektedir. Ek olarak, WDC veri kümesini kullanarak HDNET ve MAN için eğitim gerçekleştirmekteyiz. Öte yandan, *Wie et. al.* [32] QRNN3D aęını bizim durumlarımıza benzer yapay gürültü kullanarak eğittięinden, adil bir karşılaştırma için önceden eğitilmiş aęları tek bir model olarak kullanarak sonuçlar elde etmekteyiz. Burada QRNN3D'nin, [32]'de ayrıntılı olarak açıklandıęı gibi, hem eğitim hem de test seti benzer içerikteyse daha iyi sonuçlar elde edebileceęi belirtilmelidir.

DeneySEL Ayarlar: Bu bölümde, uygulama detaylarını açıklamaktayız. İlk olarak, HSG verileri, simüle veri deneylerinin eğitimi sırasında gürültü eklenmeden önce $[0, 1]$ aralıęına ölçeklendirilmektedir. Daha sonra, yukarıda verilen farklı durumlar için gürültü bileşenleri üretilip orijinal verilere eklenmektedir. Bölüm 4.1.1.'de açıklandıęı gibi, SM-CNN bir bandın gürültüsünü giderirken, hedef bandı içeren K bitişik bandın spektral ilintisini ve $h \times w$ boyutunda yama içindeki uzamsal bilgiyi kullanmaktadır. Yama boyutunu 20×20

ve adımını 10 olarak ayarlamaktayız ve eğitim sırasında veri artırımı için yamaları 0° , 90° , 180° ve 270° döndürmekteyiz. Deneysel bulgulara dayanarak, bitişik spektral bantların sayısı $K = 24$ olarak sabitlenmiştir. Önerilen model ve diğer derin öğrenme yöntemlerini eğitmek için, WDC veri kümesinin bir kısmını kullanmaktayız. Bu verileri iki kısma ayırmaktayız. $200 \times 200 \times 191$ piksel boyutundaki bir kısım test için kullanılırken, kalan kısım eğitim ve doğrulama için kullanılmaktadır. Ayrıca, önerilen yöntem, etkinliğini değerlendirmek için hem simüle edilmiş hem de gerçek veri deneylerinde PU, IP ve HSIDwRD veri kümeleri kullanılarak değerlendirilmektedir. WDC ve PU'nun gürültüsüz olduğu varsayılmakta ve yapay gürültü eklenerek test edilmektedir. Öte yandan, IP ve HSIDwRD birçok bantları doğal olarak gürültülü olduğundan, doğrudan testlerde kullanılmaktadır.

Eğitim Detayları: SM-CNN, PyTorch ile uygulanmış ve NVIDIA TESLA V100 GPU'ları üzerinde eğitilmiştir. Gürültülü HSG yamaları ile bunlara karşılık gelen temiz yamalar arasındaki ortalama mutlak hatayı (MAE) en aza indirerek eğitilmiştir. Ağın parametreleri XavierNormal ilkeyen ile başlatılmış ve Adam optimizasyon algoritması ile güncellenmiştir. Öğrenme oranı 0.0001 olarak ayarlanmış ve yığın boyutu 128 olarak belirlenmiştir. SM-CNN'nin eğitim süresi 100 epok sürmüş ve doğrulama verilerinde en iyi performans kaydedilmiştir. Son olarak, her modelin eğitim süresi yaklaşık 4-5 saat sürmüştür.

5.4.1. Simüle Edilmiş Gürültü Deneyleri

Bu bölümde, yukarıda belirtilen simüle edilmiş test verileri üzerinde önerdiğimiz ağın hem nicel hem de görsel sonuçlarını sunmaktayız. Önerilen model, literatürdeki diğer modellerle karşılaştırılarak tartışılmaktadır.

WDC Veri Kümesi. İlk olarak ağımız 5 karmaşık gürültü durumu için eğitilmekte ve WDC veri kümesi aracılığıyla test edilmektedir. Çizelge 5.2, 1-5 arası durumlar için WDC verileriyle elde edilen rakip yöntemlerin niceliksel karşılaştırmalarını listelemektedir. Çizelgedeki her sütun farklı gürültü durumlarında elde edilen metrik sonuçları göstermektedir. Daha yüksek MPSNR ve MSSIM skorları ile daha düşük SAM skoru, daha iyi gürültü giderme sonuçları anlamına gelmektedir. Kirli HSG satırı yapay


gürültülü verinin farklı durumlar için metrik değerlerini gösterirken, diğer satırlar sırasıyla klasik yöntemlerin, literatürdeki derin yöntemlerin ve önerilen yöntemin sonuçları ile elde edilen metrik değerleri göstermektedir. Çizelgedeki her bir kalite indeksi için en iyi performans koyu renkle, ikinci en iyi performans ise altı çizili olarak işaretlenmektedir.

Çizelge 5.2 WDC Veri Kümesi Üzerinde Beş Karmaşık Gürültü Durumu ile Farklı Gürültü Giderme Yöntemlerinin Nicel Değerlendirmesi.

Yöntem	Durum 1: GN			Durum 2: GN & SN			Durum 3: GN & DN			Durum 4: GN & IN			Durum 5: Karışım Gürültü		
	MPSNR↑	MSSIM↑	SAM↓	MPSNR↑	MSSIM↑	SAM↓	MPSNR↑	MSSIM↑	SAM↓	MPSNR↑	MSSIM↑	SAM↓	MPSNR↑	MSSIM↑	SAM↓
Kirli HSG	18.508	0.690	0.278	18.982	0.711	0.264	17.338	0.653	0.328	15.269	0.531	0.420	13.402	0.500	0.464
BM4D [68]	26.904	0.943	0.093	27.057	0.947	0.091	23.303	0.895	0.158	20.272	0.729	0.251	17.841	0.701	0.297
LRTV [22]	25.464	0.906	0.111	25.839	0.914	0.106	24.895	0.895	0.118	23.253	0.850	0.153	22.842	0.855	0.150
LRMR [21]	28.501	0.964	0.079	28.670	0.965	0.077	25.926	0.944	0.104	23.183	0.865	0.170	21.841	0.864	0.173
LRTDTV [23]	27.999	0.956	0.081	28.376	0.960	0.077	27.602	0.952	0.084	26.393	0.933	0.100	26.041	0.931	0.101
LRTF-DFR[62]	31.603	0.981	0.054	31.987	<u>0.983</u>	0.051	30.621	0.978	0.058	28.988	0.964	0.081	<u>28.559</u>	<u>0.967</u>	<u>0.077</u>
FastHyMix[71]	<u>32.303</u>	0.986	<u>0.052</u>	32.155	0.986	<u>0.052</u>	30.203	<u>0.981</u>	0.059	27.435	0.911	0.129	24.618	0.905	0.133
QRNN3D [32]	27.352	0.963	0.084	27.512	0.965	0.082	27.336	0.964	0.084	26.943	0.960	0.088	26.197	0.952	0.096
HSID-CNN [30]	29.355	0.968	0.071	29.541	0.970	0.069	28.872	0.966	0.075	26.559	0.943	0.097	26.156	0.940	0.101
MemNet [73]	28.126	0.964	0.095	28.398	0.966	0.079	29.913	0.971	0.069	29.702	0.969	0.081	27.082	0.960	0.093
HDNET [76]	29.897	0.972	0.065	30.079	0.974	0.064	29.158	0.969	0.070	26.982	0.951	0.090	26.222	0.945	0.095
MAN [88]	31.971	0.981	0.052	<u>32.060</u>	<u>0.983</u>	0.051	<u>31.664</u>	<u>0.981</u>	<u>0.054</u>	<u>29.973</u>	<u>0.971</u>	<u>0.066</u>	28.205	0.961	0.079
SM-CNN (Bizim)	32.529	<u>0.984</u>	0.048	31.477	0.981	0.054	32.281	0.983	0.050	30.063	0.973	0.064	29.832	0.973	0.066

Ayrıca, Durum 5 için görsel karşılaştırmalar yapmak amacıyla, tüm yöntemlerle elde edilen WDC verilerinin sahte renkli görüntülerini oluşturmak için 57, 27 ve 17 numaralı bantlar seçilmiştir ve bunlar Şekil 5.1’de sunulmaktadır. Spesifik olarak, Şekil 5.1(a) orijinal görüntüyü ve Şekil 5.1(b) gürültülü görüntüyü gösterirken, Şekil 5.1(c)-(n) farklı gürültü giderme yöntemleri uygulandıktan sonra elde edilen görüntüleri göstermektedir. Ayrıca, şekilleri daha detaylı incelemek için bir bölgeyi yakınlaştırmaktayız ve bu bölgeyi şekillerin sağ üst kısmında göstermekteyiz.

Çizelge 5.2’de görülebileceği gibi, önerilen SM-CNN beş karmaşık durumun dördünde en yüksek MPSNR ve MSSIM değerlerini ve en düşük SAM değerlerini elde etmektedir. Özellikle karışım gürültüsü durumunda, önerilen yöntem hem klasik hem de derin yöntemlere kıyasla başarı seviyesini artırmaktadır. Geleneksel yöntemlere bakıldığında BM4D, GN giderimi için etkili bir model olması nedeniyle metrikler bazında Durum 1 ve Durum 2 için oldukça iyi performans göstermiştir. Ancak BM4D özellikle görüntünün pürüzsüzleşmesine ve kenar detaylarının azalmasına neden olmaktadır. Gürültü



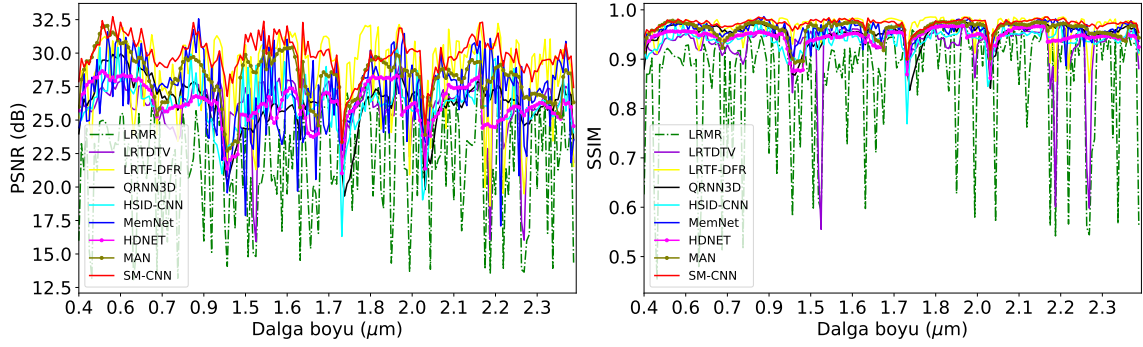
Şekil 5.1 Durum 5'teki karışım gürültülü WDC için sonuçlar. (a) Sahte renkli orijinal görüntü (bantlar: 57, 27, 17), (b) Kirli görüntü, (c) LRTF-DFR, (d) FastHyMix, (e) BM4D, (f) LRTV, (g) LRMR, (h) LRTDTV, (i) QRNN3D, (j) HSID-CNN, (k) MemNet, (l) HDNET, (m) MAN, (n) SM-CNN (Bizim).

karmaşıklığı arttıkça BM4D'nin performansı önemli ölçüde düşmektedir. FastHyMix ilk üç durumda, özellikle de 2. durumda etkileyici bir performans göstermiştir, ancak karışım gürültüsünde etkinliği önemli ölçüde azalmaktadır. Bu yöntem, Şekil 5.1'de gösterildiği gibi artefaktler ortaya çıkarmakta ve bu karmaşık gürültü durumlarıyla başa çıkamamaktadır. Öte yandan, LRTV, LRTDTV ve LRTF-DFR bu durumlar için daha uygun olduklarından, diğer geleneksel yöntemler arasında karmaşık durumlarda daha iyi sonuçlar üretmektedir. Ancak, TV normu tabanlı LRTV ve LRTDTV yöntemleri görüntülerde yumuşatma etkisi göstermektedir. Buna karşın LRMR, karışım durumunda Şekil 5.1'de açıkça görülen artefaktlerden muzdariptir. LRTF-DFR çoğu durumda oldukça iyi sonuçlar üretmektedir. Ancak, bu yöntemler birkaç hiper-parametrelerin dikkatli bir şekilde ayarlanmasını gerektirmektedir. Bu sonuçları üretirken, parametreleri ayarlayarak

en iyi sonuçları üretmek için elimizden gelenin en iyisini yapmaya çalıştık.

Şekil 5.1’de görüldüğü gibi, derin öğrenme yöntemlerinin sonuçları görsel olarak birbirine yakın gözükmekte, ancak önerilen yöntem detayları geri kazanmada iyi görünmektedir. Ayrıca, Çizelge 5.2’deki nicel analiz, önerilen yöntemimizin durum 2 dışında tüm durumlarda ve tüm metrikler bazında üstün olduğunu ortaya koymaktadır. Bu çizelgede, her gürültü durumu için MSSIM metriğindeki yüksek performans, önerilen modelin yapı özelliklerini koruma, kenar ve detay bilgilerini geri kazanmada daha güçlü ve daha sağlam bir yeteneğe sahip olduğunu göstermektedir. Ayrıca, SAM metriğindeki üstün performans, SM-CNN’nin spektral doğruluğu diğer yöntemlere göre daha iyi koruyabildiğini kanıtlamaktadır.

Şekil 5.2, spektral spektrum boyunca simüle edilmiş karışım gürültü durumunda PSNR ve SSIM değerleri ile gürültü giderme sonuçlarını göstermektedir. Burada, geleneksel yöntemler arasında en iyi sonuçları veren LRTDTV ve LRTF-DFR ile birçok klasik yönteme ilham kaynağı olan LRMR’nin sonuçlarını sunmaktayız. Ayrıca, derin modellerin sonuçlarını da göstermekteyiz. Şekil 5.2’deki PSNR ve SSIM değerlerinin spektrum boyunca ortalaması alınarak elde edilen değerler Çizelge 5.2’de verilmektedir. Genel olarak, yöntemimiz hem PSNR hem de SSIM metrikleri açısından neredeyse tüm bantlarda diğerlerinden daha iyi performans göstermektedir. LRMR’nin performansı bantlar arasında dalgalanırken, LRTDTV ve LRTF-DFR spektral spektrum boyunca daha istikrarlı sonuçlar üretmektedir. Bununla birlikte, belirli dalga boylarında (örneğin, yaklaşık $2.2 \mu\text{m}$ ila $2.3 \mu\text{m}$ civarında) LRTDTV ve LRTF-DFR’nin etkinliği azalmaktadır, bu da Şekil 5.2’de PSNR ve SSIM değerlerindeki düşüşle kanıtlanmaktadır. LRMR kadar fazla olmamakla birlikte, MemNet ve HSID-CNN yaklaşımlarının performansı bantlar arasında dalgalanmaktadır. Yöntemimiz, çoğu bantta MemNet’ten daha iyi performans göstermektedir. HDNET ve MAN yöntemlerinin spektral sürekliliğin kesintiye uğradığı noktalarda yöntemimize kıyasla performanslarında düşüş gözükmektedir. QRNN3D yöntemi, spektral spektrum boyunca daha istikrarlı sonuçlar elde etmekte, ancak daha iyi sonuçlar için tek bir model olarak düşünülme yerine yeniden eğitilmesi gerekmektedir [32].



Şekil 5.2 Durum 5 için önerilen ve rakip yöntemlerin gürültü giderme sonuçlarına karşılık gelen spektrum boyunca PSNR ve SSIM değerleri.

PU Veri Kümesi. Bu veriye Durum 5'te verilen karışım gürültüsü eklenmiştir. Farklı gürültüler eklemek için rastgele seçilen bant sayısı hariç tüm koşullar WDC'de olduğu gibi seçilmiştir. Bant sayısı WDC'den daha az olduğundan, rastgele seçilen bantların üçte biri 34 banda karşılık gelmektedir. Sonuç olarak, her bant rastgele en az bir tür gürültü ile bozulmuştur. Bu testi gerçekleştirirken, WDC verileri üzerinde eğitilmiş ağ kullanılmıştır. Önceden eğitilmiş ağın farklı bant sayılarıyla da kullanılabilirliğini göstermek, modelin esnekliğini ve genel geçerliliğini kanıtlamaktadır.

Çizelge 5.3 PU Veri Kümesi Üzerinde 10 Gürültülü Koşuda Farklı Gürültü Giderme Yöntemlerinin Nicel Değerlendirmesi.


Yöntem	MPSNR \uparrow	MSSIM \uparrow	SAM \downarrow
Kirli HSG	14.671 \pm 0.317	0.281 \pm 0.015	0.649 \pm 0.012
BM4D [68]	23.853 \pm 0.212	0.713 \pm 0.010	0.273 \pm 0.008
LRTV [22]	27.786 \pm 1.005	0.838 \pm 0.015	0.204 \pm 0.023
LRMR [21]	26.844 \pm 0.280	0.809 \pm 0.011	0.214 \pm 0.007
LRTDTV [23]	31.038 \pm 0.191	0.901 \pm 0.006	0.142 \pm 0.005
LRTF-DFR[62]	29.696 \pm 0.255	0.902 \pm 0.007	0.138 \pm 0.005
FastHyMix[71]	28.370 \pm 0.290	0.884 \pm 0.007	0.162 \pm 0.007
QRNN3D [32]	31.274 \pm 0.134	0.953\pm0.002	0.107\pm0.002
HSID-CNN [30]	27.185 \pm 0.105	0.837 \pm 0.003	0.189 \pm 0.002
MemNet [73]	29.642 \pm 0.118	0.910 \pm 0.004	0.143 \pm 0.001
HDNET [76]	29.931 \pm 0.186	0.911 \pm 0.004	0.142 \pm 0.003
MAN [88]	30.283 \pm 0.112	0.914 \pm 0.002	0.139 \pm 0.001
SM-CNN (Bizim)	31.359\pm0.119	0.923 \pm 0.002	0.124 \pm 0.001

Çizelge 5.3, karışım gürültüsü ile bozulmuş PU veri kümesi için farklı yöntemlerin gürültü giderme sonuçlarının nicel değerlendirmesini göstermektedir. Farklı bantlar seyrek gürültü

ile bozulduğunda tüm yöntemlerin performans değişikliklerini gözlemlemek için 10 farklı senaryo üzerinde testler gerçekleştirdik. Çizelge, gerçekleştirdiğimiz farklı çalışmaların ortalama ve standart sapmalarını göstermektedir. Önerilen SM-CNN, PU veri kümesi için herhangi bir ince ayar yapmadan en yüksek MPSNR, ikinci en iyi MSSIM ve SAM değerlerini elde etmektedir. QRNN3D, eğitim verilerinin bu verilerle daha iyi eşleşmesi olasılığında kaynaklanabilecek en yüksek MSSIM ve SAM değerleri elde etmektedir. MAN 3B evrişim kullandığından, verilerdeki bant sayısı değiştiği için yeniden eğitilmesi performansını ve uyarlanabilirliğini artıracaktır.


Nitel değerlendirme için, Şekil 5.3 gürültülü verilerin ve gürültü giderme sonuçlarının sahte renkli RGB'lerini göstermektedir. Hem görsel sonuçlara hem de nicel metriklere bakarak, BM4D'nin karışım (mixture) gürültü ile pek başa çıkamadığını görmekteyiz. Şekil 5.3(e)'de SN'nin giderilmediği açıkça gözükmektedir. Ayrıca, BM4D yakınlaştırılmış alandaki tüm detayları yok ettiği için aşırı yumuşatma etkisini göstermektedir. FastHyMix'in gürültü giderme performansı BM4D'den daha iyi görünmektedir, ancak görüntünün renk yoğunluğunu hafifçe değiştirmektedir, bu da Şekil 5.3(d)'deki çatı alanından belli olmaktadır. Kompleks gürültü giderme için daha uygun olan LRMR, LRTV ve özellikle LRTDTV hem nicel hem de nitel açıdan tatmin edici sonuçlar üretmektedir. BM4D kadar olmasa da, TV norm tabanlı yöntemler Şekil 5.3(f) ve (h)'de gösterildiği gibi görüntüyü bulanıklaştırmaktadır. Şekil 5.3(c)'de gösterilen sonuca göre, LRTF-DFR'nin bu özel bantlar için geleneksel yöntemlere kıyasla detayları geri kazanmada daha etkili olduğu görülmektedir. Ancak, Çizelge 5.3'te görüldüğü gibi, LRTF-DFR'nin MPSNR ve MSSIM metrikleri LRTDTV'den daha düşük olduğundan, bazı bantların yeterince düzeltilmemiş olabileceği iddia edilebilir. HSID-CNN, bu bantlar için görüntünün renk yoğunluğunu değiştirmektedir. Önerdiğimiz model, Şekil 5.3'teki yakınlaştırılmış bölgelerde gösterildiği gibi, gürültüyü giderirken detayları koruma açısından daha iyi performans göstermektedir. Bu bantların detaylarını dikkate aldığımızda, derin modeller bizim modelimiz kadar iyi sonuçlar üretmemektedir.

Şekil 5.4, gürültülü PU veri kümesinin her pikseline karşılık gelen SAM değerlerini ve tüm yöntemlerin gürültü giderme sonuçlarının orijinal görüntü boyutlarındaki SAM değerlerini

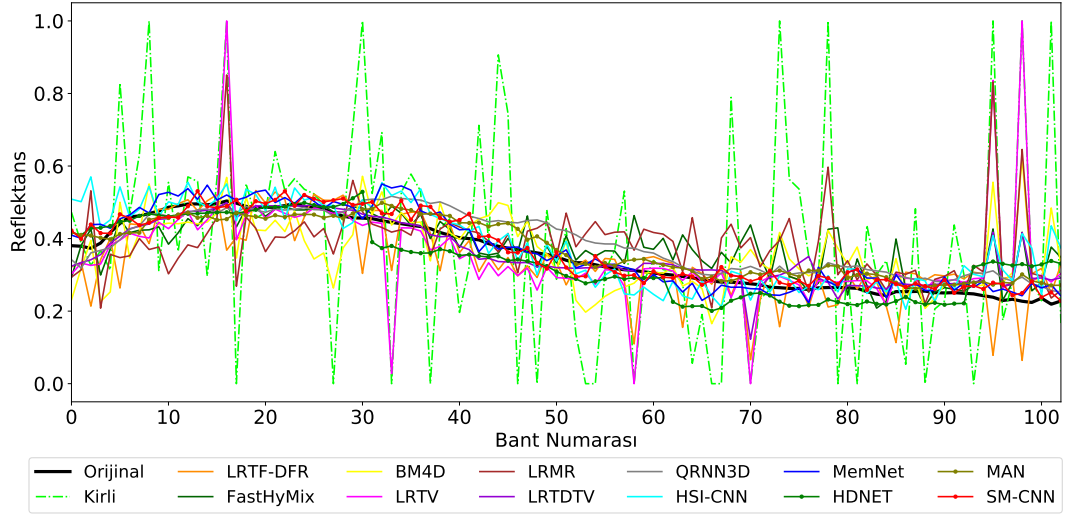


Şekil 5.3 Karışım gürültülü PU için sonuçlar. (a) Sahte renkli orijinal görüntü (bantlar: 60, 32, 10), (b) Kirlili görüntü, (c) LRTF-DFR, (d) FastHyMix, (e) BM4D, (f) LRTV, (g) LRMR, (h) LRTDTV, (i) QRNN3D, (j) HSID-CNN, (k) MemNet, (l) HDNET, (m) MAN, (n) SM-CNN (Bizim).

göstermektedir. Başka bir deyişle, simüle edilmiş karışım gürültünün her bir pikseli spektral olarak ne kadar bozduğunu ve gürültü giderme yöntemlerinin bu bozulmuş spektral bilgiyi geri kazanmada ne kadar başarılı olduğunu göstermektedir. İlgili yöntem için Çizelge 5.3'te verilen değerler, Şekil 5.4'deki SAM değerlerinin ortalaması alınarak elde edilmektedir. Klasik yöntemler arasında, LRTDTV'nin çoğu pikselde en iyi sonuçları elde ettiği görülmektedir. Ayrıca, derin öğrenme yöntemlerinin klasik yöntemlere göre daha iyi sonuçlar verdiği açıkça gözükmemektedir. Bu yöntemleri karşılaştırdığımızda, bozulmanın yoğun olduğu çatı bölgelerinde yöntemlerin performansının azaldığı görülmektedir. Özellikle, QRNN3D bu bölgelerde SM-CNN modelimizden daha iyi sonuçlar elde etmektedir. Bu nedenle, Çizelge 5.3'ten de görülebileceği gibi, ortalamada yöntemimizden biraz daha iyi bir sonuç elde etmektedir.



Şekil 5.4 PU veri kümesinin her bir pikseline karşılık gelen SAM değerleri. (a) Kirli veri, (b) LRTF-DFR, (c) FastHyMix, (d) BM4D, (e) LRTV, (f) LRMR, (g) LRTDTV, (h) QRNN3D, (i) HSID-CNN, (j) MemNet, (k) HDNET, (l) MAN, (m) SM-CNN (Bizim).



Şekil 5.5 PU verisinde (55, 169) pikselinin spektral imza restorasyonunun kalitesi.

SAM metriğine ek olarak, her bir yöntem için spektral imza geri kazanım kalitesini göstermek amacıyla, PU verisinin (59,169) pikselindeki spektral imzalar Şekil 5.5'te verilmektedir. Kirli imza incelendiğinde, bu pikselin genellikle sıfır ortalamalı GN tarafından bozulduğu görülebilir. Bazı bantlarda bir değeri, SN veya IN tarafından bozulduğunu, sıfır değeri ise DN'ye maruz kaldığını göstermektedir. Bazı bantlarda , klasik yöntemler spektral


bilgiyi geri kazanmada başarısız olduğu görülmektedir. Örneğin, LRTV bazı noktalarda IN, SN ve DN türlerini gidermede yetersiz kalmaktadır. Derin öğrenme yaklaşımlarından HSID-CNN, IN veya SN tarafından bozulmuş olan bu pikselin ilk ve son bantlarında imzayı başarılı bir şekilde elde edememektedir. QRNN3D ve HDNET'in orta bantlarda bu piksel için bir sapma oluşturduğunu görmekteyiz. MemNet, MAN ve önerilen yöntem her bantta orijinal imzaya çok yakın bir sonuç üretmektedir. Ayrıca, tüm piksellerin spektral doğruluğunun bir ölçüsü olan SAM metriğinin sonuçlarına baktığımızda, QRNN3D ve önerilen yöntemin en iyi sonuçları elde ettiği görülmektedir.

5.4.2. Gerçek Veri Deneyleri

IP Veri Kümesi. Modelimizi, doğası gereği gürültülü olan IP HSG verisi üzerinde de doğrulamaktayız. IP veri kümesinin bazı bantları bilinmeyen gürültü tarafından ciddi şekilde bozulmuştur. IP için temiz bir referans görüntüsü olmadığından, yöntemlerin performansı SVM sınıflandırıcı sonuçları ile değerlendirmekteyiz. SVM modeli her sınıftan rastgele oluşturulan örneklerin %10'u ile eğitilmiştir. Gerçek deneyde, sınıflandırma doğruluğunu test etmek için 16 gerçek veri sınıfı kullanılmıştır. Çizelge 5.4, gürültü giderme yöntemleri uygulandıktan sonra elde edilen sınıflandırma sonuçlarını ve her bir yöntemin çalışma sürelerini göstermektedir. Çizelgedeki ilk satır yöntemleri, ikinci ve üçüncü satırlar ise sırasıyla gürültü giderme sonuçları kullanılarak elde edilen OA ve kappa katsayısını göstermektedir. Son satırda sadece referans olarak çalışma süresi bilgisi gösterilmektedir. Kodumuzun çalışma süresini optimize etmek için herhangi bir çaba sarf etmediğimizi vurgulamak gerekmektedir. HSID-CNN yönteminin sonucu, varyansı 50 olan GN ile önceden eğitilmiş bir ağ kullanılarak elde edilmiştir. QRNN3D'nin sonucu, önce varyansı 50 olan GN ile eğitilmiş, ardından değişken varyansa sahip GN ile eğitilmiş ağ tarafından elde edilmiştir. Bu ağlar, önerdiğimiz gibi girişteki gürültüye yapısını adapte edemediğinden, eğitimde kullanılan gürültü ile test gürültüsü eşleşmelidir. Öte yandan, bu veri kümesi için MemNet, HDNET, MAN ve önerilen SM-CNN üzerinde özel bir eğitim yapılmamıştır.

Çizelge 5.4 IP Veri Kümesi Üzerinde Sınıflandırma Doğrulukları (SVM, %10 Eğitim Etiketleri) ve Yöntemlerin Çalışma Süreleri.

Yöntem	OA↑	Kappa↑	Çalışma süresi (s)
Kirli HSG	75.79	0.7218	-
TDL [101]	76.79	0.7305	15.295
BM4D [68]	83.97	0.8171	285.151
LRTV [22]	78.72	0.7553	656.192
LRMR [21]	79.44	0.7579	61.842
LRTDTV [23]	78.91	0.7641	229.315
LRTF-DFR [62]	88.49	0.8687	63.298
FastHyMix[71]	76.57	0.7306	0.287
QRNN3D [32]	89.07	0.8747	13.090
HSID-CNN [30]	86.65	0.8338	5.856
MemNet [73]	88.70	0.8713	22.826
HDNET [76]	87.20	0.8533	6.145
MAN [88]	87.33	0.8549	8.887
SM-CNN (Bizim)	89.31	0.8781	12.465



Şekil 5.6 Doğal gürültülü IP veri kümesi sonuçları. (a) Band 2 kullanılarak gürültülü HSG'nin gri tonlamalı görüntüsü, (b) TDL, (c) BM4D, (d) LRTV, (e) LRMR, (f) LRTDTV, (g) LRTF-DFR, (h) FastHyMix, (i) QRNN3D (j) HSID-CNN, (k) MemNet, (l) HDNET, (m) MAN, (n) SM-CNN (Bizim).

Şekil 5.6'da, tüm yöntemlerle elde edilen IP veri kümesinin 2. bandı görsel karşılaştırma için gri tonlamalı bir görüntü olarak sunulmaktadır. Sınıflandırma metriklerine göre, TDL ve FastHyMix'in gerçek gürültüdeki performanslarının yeterince iyi olmadığı görülmektedir. Metriğe dayalı sonuçlardan BM4D'nin daha iyi sonuçlar verdiği anlaşılmaktadır. Karmaşık gürültü giderme yöntemleri olan LRMR, LRTV ve LRTDTV'nin bu bant için iyi bir gürültü giderme performansı gösterdiği, ancak sınıflandırma sonuçlarına göre performanslarının BM4D'den daha düşük olduğu gözükmemektedir. Klasik yöntemler arasında, LRTF-DFR en

iyi sonuçları vermektedir. Derin öğrenme yöntemleri arasında, QRNN3D yönteminin bu bant için bulanıklığa sebep olduğu Şekil 5.6(i)'de gözükmektedir. Önerilen yöntemimiz ise diğer yöntemlerden görsel olarak daha keskin sonuçlar üretmektedir. Ayrıca, önerilen SM-CNN Çizelge 5.4'te verilen sınıflandırma sonuçlarına göre tüm yöntemlerden daha yüksek performans göstermektedir. Burada unutulmaması gereken nokta, HSID-CNN ve QRNN3D'nin test verilerinde en iyi sonuçları almak için özel olarak eğitilmiş olmalarına rağmen önerilen yöntemin gerisinde kalmış olmasıdır.

HSIDwRD Veri Kümesi. Bu ağımız için son deney gerçek gürültülü HSIDwRD veri kümesi üzerinde gerçekleştirilmiştir. Test, WDC verisi ile eğitilmiş ağ kullanılarak herhangi bir ince ayar yapılmadan gerçekleştirilmiştir. Nicel sonuçlar Çizelge 5.5'te sunulmakta ve Şekil 5.7 görsel karşılaştırma için uzun pozlama temiz görüntü, kısa pozlama gürültülü görüntü ve gürültü giderme sonuçlarını göstermektedir. Yöntemimizin etkinliği, sonuçlarımızın tüm metriklerde diğerlerinden üstün olmasıyla kanıtlanmaktadır. Şekil 5.7'de, yöntemimizin görsel olarak daha keskin ve net sonuçlar ürettiği görülebilmektedir.

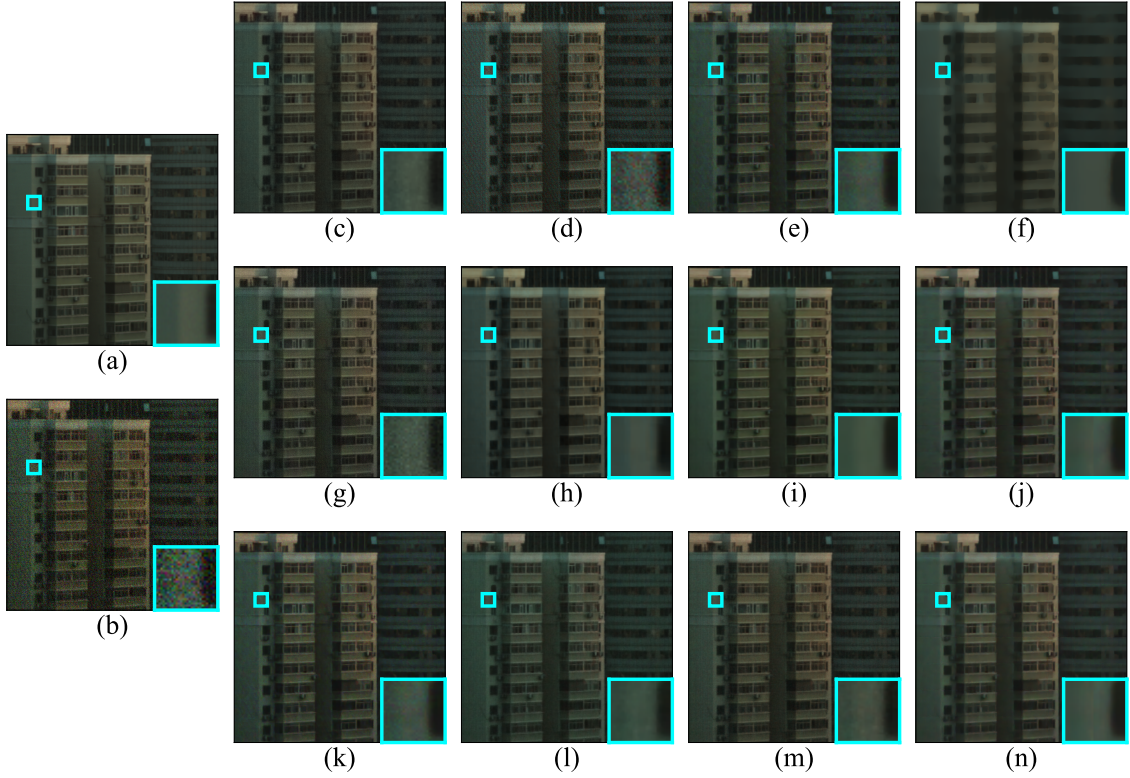
Çizelge 5.5 HSIDwRD Veri Kümesi Üzerinde Farklı Gürültü Giderme Yöntemlerinin Nicel Değerlendirmesi.

Metrikler	Kirli	LRTF-DFRFastHy-Mix [62]	BM4D [71]	LRTV [68]	LRMR [22]	LRTD-TV [21]	QRNN-3D [23]	HSID-CNN [32]	MemNet [30]	HDNET [73]	MAN [76]	SM-CNN [88]	(Bizim)
MPSNR↑	20.912	31.069	25.686	30.573	29.139	29.864	29.599	<u>31.894</u>	31.405	28.272	30.801	31.246	32.039
MSSIM↑	0.358	0.922	0.649	0.907	0.904	0.867	0.913	<u>0.938</u>	0.933	0.890	0.922	0.923	0.940
SAM↓	0.552	0.147	0.335	0.163	0.150	0.185	0.154	<u>0.140</u>	0.150	0.240	0.147	0.152	0.139

5.4.3. Bileşen İşlevsellik Analizi

SSMRB boluğunun SM-CNN modelimizdeki işlevselliğini doğrulamak için, durum 5 ile elde edilen karışım gürültülü WDC üzerinde bazı işlevsellik deneyler gerçekleştirilmektedir. Bu amaçla, iki model daha sunmaktayız: Dalga Boyu modülasyonlu CNN (Wavelength Modulating CNN; WM-CNN) ve SM-CNN-Lite.

WM-CNN. Bölüm 5.1.'de belirttiğimiz gibi, atmosferik etkiler ve diğer nedenlerden dolayı HSG verilerinde bazı bantlar göz ardı edilmektedir. Önerilen eğitim, bir bandın gürültüsünü



Şekil 5.7 Gerçek gürültülü HSIDwRD veri kümesi sonuçları. (a) Uzun pozlama sahte renkli temiz görüntü (bantlar: 30, 15, 10), (b) Kısa pozlama kirlili görüntü, (c) LRTF-DFR, (d) FastHyMix, (e) BM4D, (f) LRTV, (g) LRMR, (h) LRTDTV, (i) QRNN3D, (j) HSID-CNN, (k) MemNet, (l) HDNET, (m) MAN, (n) SM-CNN (Bizim).

giderirken komşu spektral bantların bilgilerini kullanmaktadır; ancak bu eksik bantlar nedeniyle komşu bantların bilgileri hızla değişebilmektedir. Bu nedenle, bu eksik bantlar Şekil 5.2'de $0.9 \mu\text{m}$ civarında görüldüğü gibi yöntemlerin performansını etkilemektedir. Ayrıca, HSG sensörleri spektrumun farklı bölgelerinde veri topladığından, gürültü gidericinin de farklı veri kümelerinin dalga boyu bilgilerine uyum sağlaması gerekmektedir. Bu nedenler göz önüne alındığında, gürültü gidericinin SSMM modülünde bulunan K spektral bantlar yerine, gürültü giderilen bandın dalga boyu bilgisi kullanılmaktadır. Bunu yapmak için, gürültüsü giderilecek yamayla aynı boyutlarda bir tensörün her bir elemanı, bu bandın dalga boyu değeri (μm cinsinden) olarak yerleştirilmektedir. Örneğin, $0.4 \mu\text{m}$ dalga boyunda toplanan gürültülü bant için, SSMM'deki modülasyon verisi 20×20 boyutunda bir tensördür ve bu tensörün her bir değeri 0.4 olarak ayarlanmaktadır. Bu tensör, SSMRB

aracılığıyla derin katmanlarda modülasyon verisi olarak kullanıldığından, bu modeli Dalga Boyu Modülasyonlu CNN olarak adlandırmaktayız. Son olarak, SSMM modüllerinin giriş boyutu $20 \times 20 \times K$ 'den 20×20 'ye düştüğünde, WM-CNN'nin eğitilebilir parametre sayısı da orijinal SM-CNN'den daha az olmaktadır.

SM-CNN-Lite. Bu modelde, Şekil 4.3'te gösterilen SM-CNN'deki ardışık SSMRB modüllerinin sayısını azaltmaktayız. Derin katmanda 2 SSMRB yerine tek bir SSMRB kullanmaktayız, ancak Şekil 4.4'de gösterilen SSMM'deki 5 boyutlu çekirdek boyutuna sahip evrişim katmanı ile paralel olarak, doğrudan spektral bilgiyi kullanmak için çekirdek boyutu 1 olan bir katman eklemekteyiz. Daha sonra, bu iki katmanın sonuçlarını birleştirerek ölçek (γ) ve kaydırma (β) parametrelerini oluşturmaktayız. Aynı modülasyon verilerini daha az eğitilebilir parametre ile kullandığında, bu modeli SM-CNN-Lite olarak adlandırmaktayız.


Çizelge 5.6 Karışım Gürültü İçeren WDC Üzerinde Nicel Değerlendirme.

Yöntem	MPSNR \uparrow	MSSIM \uparrow	SAM \downarrow	#param.
SM-CNN	29.832	0.973	0.066	2,404,361
WM-CNN	27.464	0.954	0.086	1,852,361
SM-CNN-Lite	28.570	0.964	0.075	1,867,241

Çizelge 5.6, karışım gürültüsü ile bozulmuş WDC veri kümesi için modelimizin versiyonlarının gürültü giderme sonuçlarının nicel değerlendirmesini ve her modelin parametre sayısını göstermektedir. Nicel sonuçlara bakıldığında, hem WM-CNN hem de SM-CNN-Lite, farklı gürültü türleriyle yoğun şekilde bozulmuş WDC veri kümesi için başarılı sonuçları vermektedir. Bununla birlikte, en iyi performans SM-CNN modeli ile elde edilmektedir.

Farklı K Değerlerinin Etkisinin Araştırılması. Şekil 5.8'de, ağımızın performansı üzerindeki komşu bant sayısının (K) değişiminin etkisini incelemekteyiz. Ağ, karışım gürültü ile kirlenmiş WDC üzerinde 10 farklı K değeri kullanılarak eğitilmiştir. Şekilde gösterildiği gibi, sınırlı sayıda bant kullanmak düşük sonuçlara yol açmakta ve daha geniş bir spektral bilginin önemini ortaya koymaktadır. Bant sayısı arttıkça performansta bir iyileşme gözlemlenmektedir; ancak bu doğrusal bir genel eğilim izlememektedir. Bunun yerine, komşu

bantların sayısı arttıkça hafif dalgalanmalar göstermekte, bu da komşu bantların etkisiyle sinyallerin spektral özelliklerindeki değişiklikleri ortaya koymaktadır.



Şekil 5.8 Farklı sayıda bitişik spektral bant ile gürültü giderme etkinliği.

Atlama Bağlantılarının Sayısının Etkisinin Araştırılması. Çizelge 5.7, önerilen SM-CNN mimarisinde atlama bağlantılarının önemini kapsamlı bir şekilde incelemektedir. WDC veri kümesi üzerinde karışım gürültü senaryosuyla gerçekleştirilen bu sistematik analizde, ağıın giriş katmanından başlayarak atlama bağlantılarını (AB) kademeli olarak kaldırılıp, buna göre eğitim gerçekleştirilmektedir. Sonuçlar, atlama bağlantılarının ağıın performansını artırmada oynadığı kritik rolü açıkça göstermektedir. Atlama bağlantılarının sayısı azaldıkça, yöntemimizin gürültü giderme performansında önemli bir düşüş gözlemlenmektedir. Atlama bağlantılarının eklenmesi, eğitim sırasında daha iyi yakınsamayı sağlamakta, etkili bilgi akışını teşvik etmekte ve gürültü giderme sürecinde temel özelliklerin korunmasını sağlamaktadır.

Çizelge 5.7 Atlama Bağlantılarının Ağı Performansı Üzerindeki Etkisi ($K = 24$).

Metrikler	Son AB	Son iki AB	Son üç AB	Tüm AB
MPSNR	28.766	28.806	29.186	29.832
MSSIM	0.954	0.955	0.958	0.973

5.5. Performans Değerlendirmesi: CST3D

Bu bölümde, deneysel ayarları ana hatlarıyla açıklanmakta ve CST3D modelimizi kullanarak HSG’lerde gerçekleştirilen gürültü giderme deneylerinin sonuçlarını sunmaktayız. Deneysel analizimizde önerilen modeli, başarısını kanıtlamış klasik model tabanlı yaklaşımlarla karşılaştırmaktayız: BM4D [68], BCTF-HSI [102], LRMR [21], LRTDTV [23], LRTF-DFR [62], FastHyDe [70] ve FastHyMix [71]. Ek olarak, yaklaşımımızın etkinliğini SM-CNN modelimiz dahil olmak üzere, HSID-CNN [30], QRNN3D [32], GRUNET [103] ve MemNet [73] gibi bazı CNN tabanlı model ve yakın zamanda önerilen, modern hibrit CNN ve Dönüştürücü modelleri olan SERT [36], SST [85], TRQ3DNet [84] ve HSDT [86] ile karşılaştırarak değerlendirmekteyiz.

Deneysel Ayarlar: Bu bölümde, uygulama detaylarını sunmaktayız. İlk olarak, simüle edilmiş veri deneylerinin eğitimi sırasında, SM-CNN’de olduğu gibi, gürültü ekmeden önce HSG verileri [0, 1] aralığına ölçeklendirmekteyiz. Yapay gürültü ayarları bölümünde verilen farklı durumlar için gürültü bileşenleri oluşturulup orijinal verilere eklenmektedir. Önerilen yaklaşımın etkinliğini değerlendirmek için üç HSG veri kümesi kullanılmıştır. Hem önerilen modeli hem de diğer derin öğrenme yöntemlerini eğitmek için ICVL veri kümesinden 100 görüntü kullanılmaktadır. SM-CNN için belirtilen veri artırma teknikleri bu modelimiz için benzer şekilde uygulanmıştır. Test aşamasında, Gauss sentezlenmiş gürültü deneyleri için ICVL [104] veri kümesi, karmaşık sentezlenmiş gürültü içeren deneyler için ICVL ve WDC [105] veri kümeleri, ve gerçek gürültü ile bozulmuş veriler için HSIDwRD [14] veri kümesi kullanılmıştır.

Eğitim Detayları: Bu modelimiz de diğerinde olduğu gibi PyTorch ile uygulanmış ve NVIDIA TESLA V100 GPU’ları kullanılarak eğitilmiştir. Eğitim stratejimiz, gürültü giderme görevini tek bir modelle ele almak için farklı gürültü türlerini içeren kapsamlı bir veri kümesi üzerinde model eğitimi gerçekleştirmektedir. Eğitim ayarlarının detayları Çizelge 5.8’de sunulmaktadır. Spesifik olarak, tek bir modeli σ değeri 50 olan sabit GN ile 30 epok, σ değeri 30 ile 70 arasında değişen GN içeren verilerle 20 epok ve Durum 1-4’e karşılık gelen gürültülü verilerle 50 epok boyunca eğitmekteyiz. Karışım gürültüyü

Çizelge 5.8 Derin Sinir Ağının Eğitim Aşamaları.

Faz	Gürültü durumu	Epok	Öğrenme oranı
1	σ değeri 50 olan GN	1 → 20	1×10^{-3}
		21 → 30	1×10^{-4}
2	σ değeri 30 ile 70 arasında değişen GN	31 → 35	1×10^{-3}
		36 → 45	1×10^{-4}
		46 → 50	1×10^{-5}
3	Durum 1-4	51 → 85	1×10^{-3}
		86 → 95	1×10^{-4}
		96 → 100	1×10^{-5}

kapsayan Durum 5'in eğitim sırasında hiç görülmediği belirtmek gerekmektedir. Eğitim toplamda 100 epok sürmekte ve farklı epoklar için 16, 32 ve 64 değişen yığın boyutları kullanılmaktadır. İterasyonlar boyunca, öğrenme oranını 10^{-3} 'ten 10^{-5} 'e değiştirmekteyiz. Belirttiğimiz stratejiyle, varsayılan model olarak 24 giriş kanallı (C) modelimiz eğitilmiştir. Tüm sonuçlarımız, doğrulama kümesinde en iyi performansı gösteren varsayılan model kullanılarak üretilmiştir. Şekil 4.5'te gösterilen her katman için 2 Dönüştürücü ($N_i = 2$) kullanılmıştır. Son olarak, tüm sonuçları tek bir modelle elde etmek için 31 bantlık bir spektral pencere kullanılmıştır.

5.5.1. Simüle Edilmiş Gürültü Deneyleri

Bu bölümde, daha önce bahsedildiği gibi, önerdiğimiz CST3D modelinin simüle edilmiş gürültü test verileri üzerindeki nicel ve görsel sonuçlarını sergilemekteyiz. Önerilen modeli, literatürdeki mevcut yaklaşımlarla karşılaştırarak tartışmaktayız.


ICVL Veri Kümesindeki Gauss Gürültüsü. İstatistiksel sonuçlar elde etmek amacıyla Gauss gürültü deneyleri için toplamda 40 veri kullanarak testler gerçekleştirilmektedir. Çizelge 5.9, 40 test verisi üzerindeki gürültü giderme sonuçlarının metriklerinin ortalama ve standart sapmalarını sunmaktadır. Çizelgeye bakıldığında, dört farklı Gauss gürültü yoğunluğu için sonuçlar elde edilmiştir. “Kirli HSG” etiketi taşıyan satır, farklı yoğunluklarda yapay Gauss gürültülü veriler için metrik değerlerini sunarken, kalan satırlar sırasıyla klasik yöntemler, mevcut literatürdeki derin yöntemler ve önerilen yöntem

Çizelge 5.9 ICVL Veri Kümesinde 4 Farklı Gauss Gürültü Seviyesi ile Farklı Gürültü Giderme Yöntemlerinin Nicel Değerlendirmesi.

Yöntem	$\sigma = 30$			$\sigma = 50$			$\sigma = 70$			σ değeri 30 ile 70 arasında değişen GN		
	MPSNR \uparrow	MSSIM \uparrow	SAM \downarrow	MPSNR \uparrow	MSSIM \uparrow	SAM \downarrow	MPSNR \uparrow	MSSIM \uparrow	SAM \downarrow	MPSNR \uparrow	MSSIM \uparrow	SAM \downarrow
Kirli HSG	18.589 \pm 0.002	0.117 \pm 0.042	0.716 \pm 0.338	14.152 \pm 0.001	0.049 \pm 0.023	0.893 \pm 0.316	11.228 \pm 0.002	0.026 \pm 0.013	1.010 \pm 0.286	17.740 \pm 4.286	0.133 \pm 0.133	0.750 \pm 0.417
BM4D [68]	37.741 \pm 2.442	0.928 \pm 0.015	0.111 \pm 0.089	34.999 \pm 2.375	0.884 \pm 0.019	0.148 \pm 0.116	33.232 \pm 2.287	0.845 \pm 0.023	0.177 \pm 0.136	37.152 \pm 1.897	0.915 \pm 0.034	0.138 \pm 0.150
BCTF-HSI [102]	40.840 \pm 2.020	0.959 \pm 0.010	0.061 \pm 0.044	38.412 \pm 1.849	0.936 \pm 0.017	0.075 \pm 0.054	36.774 \pm 1.746	0.915 \pm 0.024	0.089 \pm 0.068	40.249 \pm 1.319	0.948 \pm 0.033	0.074 \pm 0.074
LRMR [21]	33.182 \pm 1.634	0.745 \pm 0.025	0.159 \pm 0.193	29.460 \pm 1.978	0.578 \pm 0.064	0.210 \pm 0.228	26.881 \pm 2.213	0.467 \pm 0.094	0.259 \pm 0.250	32.506 \pm 2.260	0.723 \pm 0.099	0.191 \pm 0.259
LRTDTV [23]	36.871 \pm 2.879	0.922 \pm 0.028	0.081 \pm 0.049	35.106 \pm 2.431	0.899 \pm 0.031	0.101 \pm 0.062	33.822 \pm 2.504	0.877 \pm 0.033	0.117 \pm 0.069	36.322 \pm 1.851	0.915 \pm 0.027	0.094 \pm 0.075
LRTF-DFR[62]	35.282 \pm 2.850	0.819 \pm 0.064	0.131 \pm 0.073	32.417 \pm 2.567	0.730 \pm 0.086	0.163 \pm 0.109	31.879 \pm 3.135	0.741 \pm 0.121	0.140 \pm 0.085	35.119 \pm 3.516	0.805 \pm 0.100	0.142 \pm 0.100
FastHyDe [70]	40.648 \pm 1.763	0.965 \pm 0.011	0.069 \pm 0.056	38.332 \pm 1.916	0.946 \pm 0.017	0.093 \pm 0.071	35.983 \pm 2.555	0.925 \pm 0.027	0.125 \pm 0.095	40.331 \pm 1.867	0.960 \pm 0.015	0.087 \pm 0.094
HSID-CNN [30]	39.862 \pm 1.638	0.982 \pm 0.006	0.075 \pm 0.089	37.750 \pm 1.446	0.974 \pm 0.008	0.089 \pm 0.080	34.857 \pm 1.294	0.947 \pm 0.016	0.143 \pm 0.174	38.407 \pm 1.849	0.973 \pm 0.014	0.106 \pm 0.157
GRUNET [103]	40.364 \pm 1.439	0.984 \pm 0.005	0.066 \pm 0.073	38.033 \pm 1.334	0.974 \pm 0.007	0.083 \pm 0.086	35.759 \pm 1.042	0.957 \pm 0.011	0.123 \pm 0.144	39.078 \pm 2.118	0.977 \pm 0.012	0.093 \pm 0.134
QRNN3D [32]	41.970 \pm 1.470	0.988 \pm 0.003	0.050 \pm 0.057	39.551 \pm 1.442	0.980 \pm 0.006	0.059 \pm 0.066	37.322 \pm 1.277	0.968 \pm 0.011	0.105 \pm 0.179	40.579 \pm 2.070	0.982 \pm 0.010	0.080 \pm 0.155
SERT [36]	42.309 \pm 1.672	<u>0.989\pm0.004</u>	0.049 \pm 0.048	40.121 \pm 1.587	<u>0.982\pm0.005</u>	0.055\pm0.059	36.724 \pm 1.231	0.965 \pm 0.016	0.105 \pm 0.213	40.869 \pm 2.146	0.983 \pm 0.012	0.077 \pm 0.160
SST [85]	41.740 \pm 1.827	0.988 \pm 0.007	0.055 \pm 0.072	39.837 \pm 1.723	<u>0.982\pm0.008</u>	<u>0.056\pm0.054</u>	36.607 \pm 1.555	0.953 \pm 0.039	0.141 \pm 0.342	40.396 \pm 2.172	0.979 \pm 0.026	0.107 \pm 0.282
TRQ3DNet [84]	42.096 \pm 2.008	<u>0.989\pm0.004</u>	<u>0.047\pm0.051</u>	39.760 \pm 1.780	<u>0.982\pm0.007</u>	0.055\pm0.058	37.237 \pm 1.788	<u>0.974\pm0.008</u>	0.066\pm0.071	40.652 \pm 2.475	<u>0.984\pm0.009</u>	0.056\pm0.070
HSDT [86]	<u>42.562\pm1.534</u>	0.988 \pm 0.004	0.055 \pm 0.079	<u>40.407\pm1.497</u>	<u>0.982\pm0.007</u>	0.070 \pm 0.114	<u>38.265\pm1.223</u>	0.966 \pm 0.019	0.114 \pm 0.232	<u>41.242\pm2.094</u>	<u>0.980\pm0.017</u>	0.094 \pm 0.216
CST3D (Bizim)	43.228\pm1.585	0.991\pm0.003	0.044\pm0.054	40.922\pm1.555	0.984\pm0.005	0.055\pm0.071	38.888\pm1.423	0.976\pm0.009	<u>0.078\pm0.136</u>	41.943\pm2.144	0.986\pm0.008	<u>0.064\pm0.124</u>

tarafından elde edilen metrik değerlerini temsil etmektedir. Her kalite indeksi için en iyi performans koyu renkle, ikinci en iyi performans ise altı çizili olarak vurgulanmaktadır. Ayrıca, çizelgede sunulan sonuçları elde etmek için klasik model tabanlı yöntemler için hiper-parametreleri titizlikle ince ayar yapılmıştır. Farklı hiper-parametre ayarları ile model tabanlı yöntemler için sonuçların değişebileceğini belirtmek önemlidir. Tüm derin yöntemler aynı eğitim sürecinden geçmiştir. Son olarak, her derin model için tüm sonuçlarımız, doğrulama kümesinde en iyi performansı gösteren tek bir model kullanılarak üretilmiştir.

Çizelge 5.9'da görüldüğü gibi, özellikle Gauss gürültü için kullanılan BM4D, BCTF-HSI ve FastHyDe gibi model tabanlı yaklaşımlar, diğer klasik yöntemlere kıyasla daha yüksek nicel sonuçlar elde etmektedir. Ayrıca, bu yöntemler düşük gürültü seviyelerinde bazı CNN tabanlı yöntemlere (örneğin, HSI-CNN, GRUNET) kıyasla iyi sonuçlar vermektedir. Ancak, artan gürültü yoğunluğu altında bu yöntemlerin performansı düşmektedir. CNN yöntemleri arasında, QRNN3D yöntemi en iyi sonuçları sağlamaktadır. Yakın zamanda tanıtılan hibrit CNN ve Dönüştürücü modelleri, nicel sonuçlarla kanıtlandığı üzere üstün performans sergilemektedir. Bu hibrit aileye ait olan modelimiz, kendisine en yakın modele MPSNR bazında 0.7 dB'ye kadar fark elde etmektedir. Ayrıca, MSSIM metrik sonuçlarını analiz edildiğinde, modelimiz tüm senaryolarda tutarlı bir şekilde en iyi performansı gösterdiği görülmektedir. SAM metriği açısından, modelimiz çeşitli gürültü seviyelerinde birinci veya ikinci sırada yer almaktadır.



Şekil 5.9 ICVL için $\sigma = 30$ ile elde edilen sonuçlar. Sol üst köşedeki görüntüler, orijinal ve işlenmiş görüntüler arasındaki farklılıkları vurgulayan, 20 kat ölçeklenmiş ve ters çevrilmiş hata haritalarını göstermektedir (yani, $1 - 20 \times \{\text{temiz-işlenmiş}\}$). Hata haritaları, 3 bant farkı alındığı için renkli görünmektedir. Daha beyaz alanlar daha düşük hata seviyelerini temsil etmektedir. (a) Sahte renkli temiz görüntü (bantlar: 29, 16, 8), (b) Kirlili görüntü, (c) BM4D, (d) BCTF-HSI (e) LRMR, (f) LRTDTV, (g) LRTF-DFR, (h) FastHyDe, (i) HSID-CNN, (j) GRUNET, (k) QRNN3D, (l) SERT, (m) SST, (n) TRQ3DNet, (p) HSDT, (r) CST3D (Bizim).

Görsel karşılaştırmaları daha sezgisel ve anlaşılır hale getirmek için $\sigma = 30$ durumunda, tüm yöntemlerle elde edilen ICVL verilerinin sahte renkli görüntülerini oluşturmak üzere 29, 16 ve 8 bantları seçilmiştir. Bu görüntüler Şekil 5.9'da sunulmaktadır.

Çizelge 5.10 ICVL Veri Kümesi Üzerindeki Beş Karmaşık Gürültü Senaryosunda Farklı Gürültü Giderme Yöntemlerinin Nicel Değerlendirmesi.

Yöntem	Durum 1: GN			Durum 2: GN & SN			Durum 3: GN & DN			Durum 4: GN & IN			Durum 5: Karışım gürültü		
	MPSNR↑	MSSIM↑	SAM↓	MPSNR↑	MSSIM↑	SAM↓	MPSNR↑	MSSIM↑	SAM↓	MPSNR↑	MSSIM↑	SAM↓	MPSNR↑	MSSIM↑	SAM↓
Kirli HSG	17.698	0.162	0.861	17.887	0.157	0.841	17.727	0.160	0.860	15.355	0.126	0.882	14.255	0.108	0.916
BM4D [68]	33.374	0.774	0.232	33.060	0.772	0.229	30.651	0.721	0.275	28.025	0.610	0.490	24.976	0.531	0.527
BCTF-HSI [102]	38.303	0.935	0.083	37.863	0.929	0.100	35.241	0.897	0.124	31.075	0.804	0.472	28.307	0.779	0.496
LRMR [21]	32.795	0.732	0.147	32.799	0.731	0.147	31.858	0.706	0.179	30.510	0.661	0.302	29.414	0.653	0.312
LRTDTV [23]	36.497	0.917	0.086	36.384	0.917	0.083	34.913	0.904	0.103	35.958	0.915	0.093	33.840	0.890	0.134
LRTF-DFR[62]	33.478	0.751	0.183	33.306	0.737	0.193	32.809	0.750	0.210	32.405	0.758	0.240	31.409	0.760	0.242
FastHyMix[71]	40.421	0.959	0.084	37.218	0.899	0.118	35.490	0.870	0.128	33.542	0.858	0.481	26.894	0.656	0.518
HSID-CNN [30]	38.635	0.978	0.071	38.187	0.976	0.076	38.319	0.976	0.073	35.434	0.945	0.154	34.552	0.942	0.154
GRUNET [103]	40.906	0.987	0.057	40.610	0.986	0.059	40.631	0.986	0.059	38.896	0.975	0.078	37.884	0.973	0.083
QRNN3D [32]	42.858	0.991	0.041	42.599	0.991	0.044	42.502	0.991	0.044	40.575	0.976	0.076	39.695	0.976	0.075
SERT [36]	42.689	0.991	0.040	42.381	0.990	0.041	42.044	0.990	0.042	40.258	0.980	0.062	38.277	0.975	0.069
SST [85]	42.663	0.991	0.041	42.354	0.991	0.042	42.089	0.991	0.043	40.861	<u>0.981</u>	<u>0.064</u>	38.444	0.980	<u>0.060</u>
TRQ3DNet [84]	43.152	<u>0.992</u>	<u>0.037</u>	42.878	<u>0.992</u>	<u>0.038</u>	42.936	<u>0.992</u>	<u>0.038</u>	<u>41.217</u>	0.983	0.060	<u>40.428</u>	<u>0.983</u>	0.059
HSDT [86]	<u>43.435</u>	<u>0.992</u>	0.039	<u>43.322</u>	0.991	0.041	<u>43.344</u>	0.991	0.041	40.800	0.973	0.084	40.403	0.977	0.076
CST3D (Bizim)	44.298	0.993	0.033	44.138	0.993	0.034	44.256	0.993	0.034	42.114	0.983	<u>0.064</u>	41.547	0.984	0.059

Spesifik olarak, Şekil 5.9(a) orijinal görüntüyü, Şekil 5.9(b) ise gürültülü görüntüyü göstermektedir. Şekil 5.9(c)-(r), farklı gürültü giderme yöntemleri uygulandıktan sonra elde edilen görüntüleri temsil etmektedir. Farklılıkları nispeten daha iyi göstermek için, temiz veri ile fark alınarak aynı ölçüde ölçeklenmiş hata haritaları görüntülerin sol üst köşesine yerleştirilmiştir. Farklılıkları daha iyi görmek için şekle yakınlaştırma yapmak daha iyi olacaktır. Oluşturulan görüntüler ve temiz veriden alınan farkları incelendiğinde, yöntemimiz son derece temiz görsel sonuçlar üretmektedir.


ICVL Veri Kümesindeki Karmaşık Gürültü. İstatistiksel olarak gürbüz sonuçlar elde etmek ve aykırı değerlerin etkisini en aza indirmek için, beş karmaşık gürültü senaryosu boyunca 40 veri kullanarak kapsamlı bir deneysel değerlendirme gerçekleştirmekteyiz. Bu yaklaşım, yöntemlerin farklı gürültü koşulları altındaki performansını temsil eden bulgular elde etmemizi sağlamaktadır. Çizelge 5.10, 40 test verisi üzerindeki gürültü giderme için ortalama performans metriklerini özetlemektedir. Çizelgede okunurluğu arttırmak adına standart sapmalar belirtilmemektedir. Bu deneyde, karmaşık gürültü durumları için özel olarak tasarlanmış FastHyDe'nin bir versiyonu olan FastHyMix'in sonuçlarını sunmaktayız.

FastHyMix ve BCTF-HSI, gürültü karmaşıklığı düşük olduğunda çok iyi performans gösteren model tabanlı yöntemlerdir, ancak Çizelge 5.10'da görüldüğü gibi, gürültü karmaşıklığının yüksek olduğu karışım durumunda performansları dramatik bir şekilde düşmektedir. Öte yandan, LRTDTV ve LRTF-DFR tüm durumlarda nispeten istikrarlı

sonular gstermektedir. Yukarıda belirtildiđi gibi, tm derin modeller benzer ekilde eđitilmiř ve eđitim ařamasında karıřım durum olan Durum 5 gsterilmemiřtir. Buna rađmen, CNN tabanlı yntemlerin, zellikle QRNN3D'nin, geleneksel model tabanlı yntemlere kıyasla daha iyi sonular verdiđini gzlemlenmektedir. Hibrit modeller yine ok bařarılı sonular gstermektedir ve modelimiz (CST3D) her durumda ok bařarılı nicel sonular retmektedir. Eđitim sırasında hi grlmemiř olan Durum 5'teki bařarisının, en yakın modelden 1 dB MPSNR'den daha iyi olduđunu grmekteyiz. Modelimiz, Durum 4'teki SAM deđeri hari, tm durumlarda ve tm metriklerde olduka bařarılı performans gstermektedir.

Grsel deđerlendirme iin, Őekil 5.10'da temiz veriye ait sahte renkli RGB grnt, Durum 5 grlts ieren grltl veri ve yntemlerin grlt giderme sonuları verilmektedir. Bu Őekil, farklı grlt giderme yntemlerinin grlty giderirken temel grnt detaylarını koruma performansını net bir Őekilde grsel olarak vurgulamaktadır. Grsel karřılařtırma srecini iyileřtirmek amacıyla, her grntnn sol st křesine leklenmiř ve ters evrilmiř hata haritalarını sunmaktayız. Hem grsel sonular hem de nicel metrikler dikkate alındıđında; BM4D, BCTF-HSI, LRMR ve FastHyMix'in karıřım grltyle etkili bir Őekilde bařa ıkmakta zorlanmaktadır. Diđer model tabanlı yntemler nispeten iyi nitel sonular sađlamaktadır. Derin yntemler arasındaki fark, sađladıđımız hata haritası ieren grselden kolayca anlařılmaktadır. Bu farkı incelediđimizde, modelimizin grnty dřk hata ile geri kazandıđını grmekteyiz. Modelimiz, grsel detayları koruma yeteneđi ile ne ıkmakta ve grlt giderme srecinde orijinal grntnn karmařık detaylarını ve dokusunu geri kazanmaktadır.

WDC Veri Kmesindeki Karmařık Grlt. Uzaktan algılanan WDC veri kmesinin test blmnde, yukarıda belirtilen beř zorlu grlt senaryosu ile modelimizin ve tm rakip yaklařımların performansını deđerlendirmekteyiz. izelge 5.11 bu sonuları sunmaktadır. izelgede her kalite metriđi iin en iyi performans koyu renk ile, ikinci en iyi performans ise altı izili olarak belirtilmektedir. Bu sonulardan, nerilen hibrit modelimizin etkinliđi aıka gzkmektedir. Daha nce belirtildiđi gibi, SM-CNN'nin performansı TRQ3D, SST, SERT ve CST3D gibi hibrit modellere kıyasla daha dřk kalmaktadır. Bu, ilgili



Şekil 5.10 Durum 5'teki karışım gürültülü ICVL için sonuçlar. Sol üst köşedeki görüntüler, orijinal ve işlenmiş görüntüler arasındaki farklılıkları vurgulayan, 10 kat ölçeklenmiş ve ters çevrilmiş hata haritalarını göstermektedir (yani, $1 - 10 \times \{\text{temiz-işlenmiş}\}$). Hata haritaları, 3 bandın farkı alındığı için renkli görünmektedir. Daha beyaz alanlar daha düşük hata seviyelerini temsil etmektedir. (a) Sahte renkli temiz görüntü (bantlar: 29, 16, 8), (b) Kirlili görüntü, (c) BM4D, (d) BCTF-HSI (e) LRMR, (f) LRTDTV, (g) LRTF-DFR, (h) FastHyMix, (i) HSID-CNN, (j) GRUNET, (k) QRNN3D, (l) SERT, (m) SST, (n) TRQ3DNet, (p) HSDT, (r) CST3D (Bizim).

yöntemlerin global spektral ve uzamsal bilgileri etkili bir şekilde entegre etmelerinden kaynaklanmaktadır. SM-CNN modelimiz; QRNN3D, HSID-CNN ve diğer CNN tabanlı yöntemlerden daha iyi performans göstermektedir. Tüm karmaşık durumlarda, CST3D


Çizelge 5.11 WDC Veri Kümesi Üzerindeki Beş Karmaşık Gürültü Senaryosunda Farklı Gürültü Giderme Yöntemlerinin Nicel Değerlendirmesi.

Yöntem	Durum 1: GN			Durum 2: GN & SN			Durum 3: GN & DN			Durum 4: GN & IN			Durum 5: Karışım gürültü		
	MPSNR↑	MSSIM↑	SAM↓	MPSNR↑	MSSIM↑	SAM↓	MPSNR↑	MSSIM↑	SAM↓	MPSNR↑	MSSIM↑	SAM↓	MPSNR↑	MSSIM↑	SAM↓
Kirli HSG	18.508	0.690	0.278	18.982	0.711	0.264	17.338	0.653	0.328	15.269	0.531	0.420	13.402	0.500	0.464
BM4D [68]	26.904	0.943	0.093	27.057	0.947	0.091	23.303	0.895	0.158	20.272	0.729	0.251	17.841	0.701	0.297
LRMR [21]	28.501	0.964	0.079	28.670	0.965	0.077	25.926	0.944	0.104	23.183	0.865	0.170	21.841	0.864	0.173
BCTF-HSI [102]	24.407	0.916	0.122	24.380	0.916	0.123	22.262	0.878	0.155	20.998	0.808	0.202	19.474	0.780	0.224
LRTDTV [23]	27.999	0.956	0.081	28.376	0.960	0.077	27.602	0.952	0.084	26.393	0.933	0.100	26.041	0.931	0.101
LRTE-DFR[62]	31.603	0.981	0.054	31.987	0.983	0.051	30.621	0.978	0.058	28.988	0.964	0.081	28.559	0.967	0.077
FastHyMix[71]	32.303	0.986	0.052	32.155	0.986	0.052	30.203	0.981	0.059	27.435	0.911	0.129	24.618	0.905	0.133
MemNet [73]	28.126	0.964	0.095	28.398	0.966	0.079	29.913	0.971	0.069	29.702	0.969	0.081	27.082	0.960	0.093
HSID-CNN [30]	29.355	0.968	0.071	29.541	0.970	0.069	28.872	0.966	0.075	26.559	0.943	0.097	26.156	0.940	0.101
QRNN3D [32]	29.692	0.972	0.070	28.849	0.966	0.077	29.353	0.970	0.073	29.277	0.970	0.074	27.388	0.955	0.091
SERT [36]	33.794	0.988	0.042	33.256	0.987	0.045	32.771	0.985	0.048	32.644	0.985	0.048	30.284	0.976	0.063
SST [85]	33.855	0.988	0.042	<u>33.911</u>	<u>0.989</u>	<u>0.041</u>	<u>33.515</u>	<u>0.987</u>	<u>0.043</u>	32.047	0.982	0.051	30.005	0.975	0.062
TRQ3DNet [84]	34.082	<u>0.989</u>	<u>0.040</u>	33.447	0.987	0.044	33.098	0.986	0.046	33.069	0.986	0.046	31.697	0.981	0.054
HSDT [86]	<u>34.194</u>	<u>0.989</u>	<u>0.040</u>	33.654	0.988	0.043	33.226	<u>0.987</u>	0.045	<u>33.331</u>	<u>0.987</u>	<u>0.045</u>	<u>32.542</u>	<u>0.984</u>	<u>0.053</u>
SM-CNN (Bizim)	32.529	0.984	0.048	31.477	0.981	0.054	32.281	0.983	0.050	30.063	0.973	0.064	29.832	0.973	0.066
CST3D (Bizim)	34.824	0.991	0.037	34.210	0.990	0.040	33.884	0.989	0.041	33.879	0.989	0.041	33.070	0.986	0.046


modelimiz tutarlı bir şekilde en yüksek MPSNR ve MSSIM değerlerine ulaşarak üstün gürültü giderme performansı sergilemektedir. Ayrıca, en düşük SAM değerlerini göstererek spektral bilginin başarılı bir şekilde korunduğunu kanıtlamaktadır.

Karışım gürültü (Durum 5) için görsel karşılaştırmaları kolaylaştırmak amacıyla, WDC verisinde 153, 99 ve 39 bantlarını seçerek sahte renkli görüntüler oluşturmaktayız. Şekil 5.11, orijinal ve gürültülü görüntülerle birlikte, her bir HSG gürültü giderme yaklaşımının sonuçlarını göstermektedir. Ek olarak, sonuçların daha ayrıntılı incelenebilmesi için, temiz veri ile fark alınarak ölçeklenmiş ve ters çevrilmiş hata haritalarını da görüntülerin sol üst köşesine yerleştirmekteyiz. Görüldüğü gibi, bazı klasik yöntemler tatmin etmeyen sonuçlar verirken, derin öğrenme yöntemleri yüksek performans sergilemektedir. Önerdiğimiz yöntem, ince ölçekli detayları geri kazanmada belirgin bir şekilde üstünlük göstermekte olup, derin öğrenme tabanlı yaklaşımlar arasında en iyi seçenek olarak öne çıkmaktadır.

Şekil 5.12, spektral spektrum boyunca simüle edilmiş karışık gürültü durumu için PSNR ve SSIM metriklerini içeren gürültü giderme sonuçlarını göstermektedir. Yer kısıtlaması nedeniyle, yöntemlerin bazılarını dahil etmemekteyiz. Genel olarak, yöntemimiz hem PSNR hem de SSIM metrikleri dikkate alındığında neredeyse tüm spektral bantlarda diğerlerinden daha iyi performans göstermektedir. Ayrıca, diğer bazı yöntemlerde gözlemlenen spektrum boyunca belirgin bir dalgalanma yöntemimizin sonucunda bulunmamaktadır.



Şekil 5.11 Durum 5'teki Karışım gürültülü WDC için sonuçlar. Sol üst köşedeki görüntüler, orijinal ve işlenmiş görüntüler arasındaki farklılıkları vurgulayan, 10 kat ölçeklenmiş ve ters çevrilmiş hata haritalarını göstermektedir (yani, $1 - 10 \times \{\text{temiz-işlenmiş}\}$). Hata haritaları, 3 bandın farkı alındığı için renkli görünmektedir. Daha beyaz alanlar daha düşük hata seviyelerini temsil etmektedir. (a) Sahte renkli temiz görüntü (bantlar: 153, 99, 39), (b) Kirlili görüntü, (c) BM4D, (d) BCTF-HSI, (e) LRMR, (f) LRTDTV, (g) LRTF-DFR, (h) FastHyMix, (i) MemNet, (j) HSID-CNN, (k) QRNN3D, (l) SERT, (m) SST, (n) TRQ3DNet, (p) HSDT, (r) CST3D (Bizim).



Şekil 5.12 Durum 5 için önerilen ve rakip yöntemlerin gürültü giderme sonuçlarına karşılık gelen spektrum boyunca PSNR ve SSIM değerleri.

5.5.2. Gerçek Veri Deneyi

HSIDwRD Veri Kümesi. Gerçek veri deneyleri, doğal gürültülü bir veri kümesi olan HSIDwRD üzerinde gerçekleştirilmiştir. Test, ICVL verisi ile eğitilmiş ağ kullanılarak herhangi bir ince ayar yapılmadan gerçekleştirilmiştir. Nicel sonuçlar Çizelge 5.12’de verilmektedir. Görsel karşılaştırma için Şekil 5.13, uzun pozlama görüntüsü, kısa pozlama gürültülü görüntü ve gürültü giderme sonuçlarını sergilemektedir. Ayrıca, görüntüleri daha detaylı incelemek için bir bölgeye yakınlaştırma yaparak bu bölgeyi görüntülerin sağ alt kısmında göstermekteyiz. Yöntemlerimizin (SM-CNN ve CST3D) etkinliği, tüm metriklerde diğerlerinden üstün performans göstererek kanıtlanmaktadır. Şekil 5.13’te CST3D’nin görsel olarak daha keskin ve net sonuçlar verdiği açıktır. Son olarak, çalışma süresi bilgisi Çizelge 5.12’nin son sütununda sağlanmaktadır. CST3D yöntemimiz, çalışma süresi iyileştirmesi için özel bir kod optimizasyonu yapılmadan takdire şayan bir hız göstermektedir, ancak HSDT en optimal sonuçları elde etmekte ve yöntemimizi geçmektedir. M2S stratejisi her bandı ayrı ayrı elde etmeyi gerektirdiğinden, SM-CNN’nin görüntüyü işlemesi daha uzun süre almaktadır.

SAM metriğine ek olarak, her yöntemin spektral imza restorasyon etkinliğini göstermek amacıyla, gerçek HSIDwRD verisindeki (272, 272) pikselinin spektral imzaları Şekil 5.14’te sunulmaktadır. Şeklin sağ üst köşesinde, öncelikle temiz kabul ettiğimiz uzun pozlama ile elde edilen spektral imza gösterilmektedir. Ardından, kısa pozlama ile elde edilen gürültülü

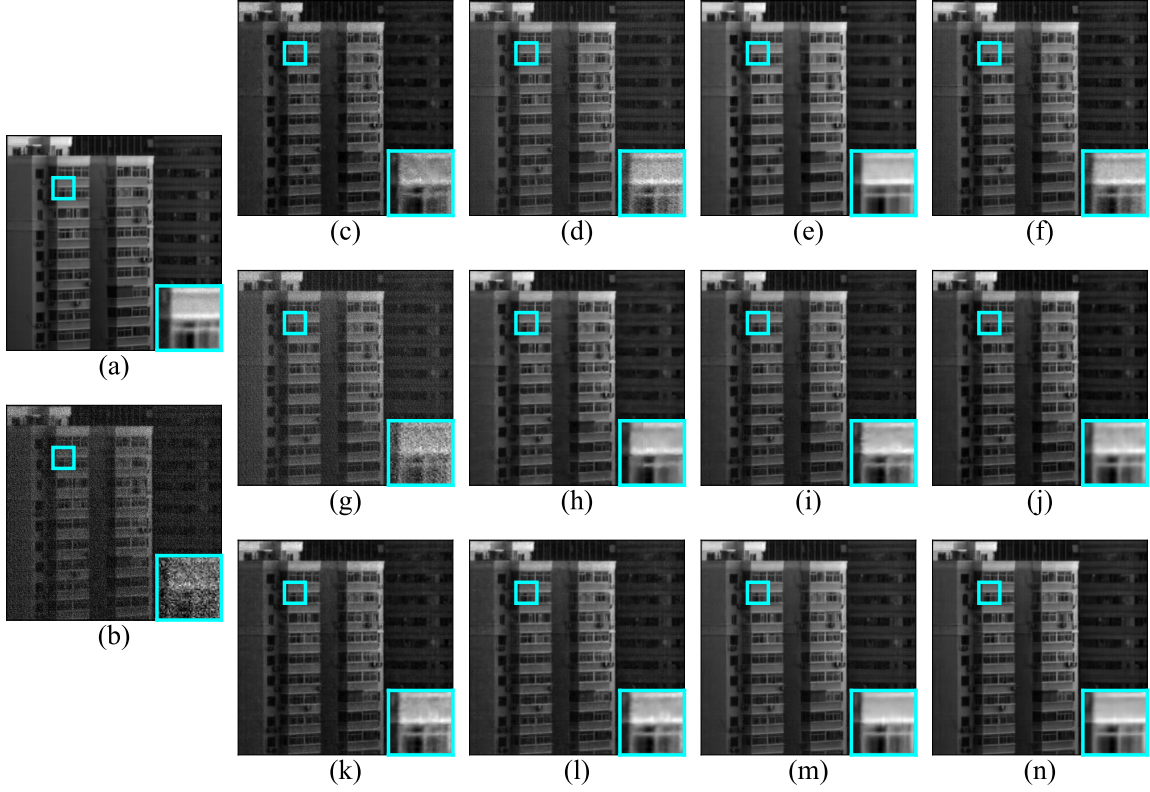
Çizelge 5.12 HSIDwRD Veri Kümesi Üzerinde Farklı Gürültü Giderme Yöntemlerinin Nicel Değerlendirmesi ve Yöntemlerin Çalışma Süreleri.

Yöntem	MPSNR↑	MSSIM↑	SAM↓	Çalışma süresi (s)
Kirli HSG	20.912	0.358	0.552	-
BM4D [68]	28.529	0.815	0.193	616.286
LRMR [21]	29.864	0.867	0.185	754.499
LRTDTV [23]	29.599	0.913	0.154	334.582
LRTF-DFR[62]	31.069	0.922	0.147	268.817
FastHyMix[71]	25.686	0.649	0.335	2.413
HSID-CNN [30]	31.405	0.933	0.150	2.304
QRNN3D [32]	31.657	0.935	0.142	0.213
SERT [36]	31.398	0.934	0.142	0.354
SST [85]	31.867	0.936	0.143	4.600
TRQ3DNet [84]	31.457	0.934	0.142	0.604
HSDT [86]	31.669	0.934	0.141	0.017
SM-CNN (Bizim)	32.039	<u>0.940</u>	<u>0.139</u>	12.465
CST3D (Bizim)	<u>32.030</u>	0.941	0.132	0.034

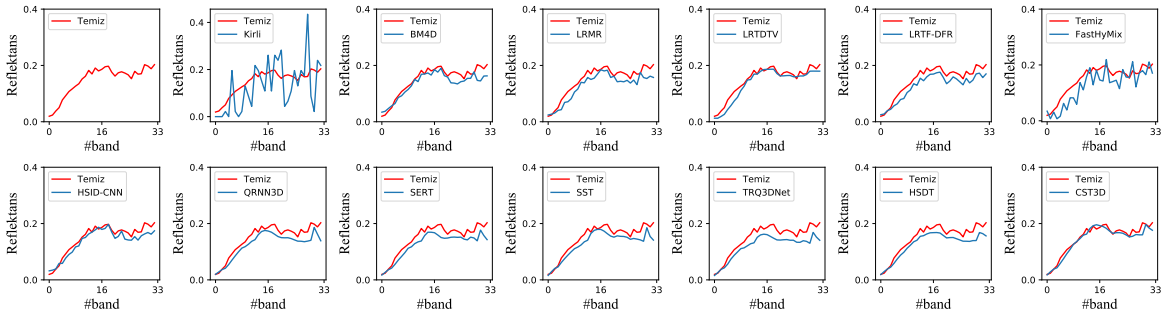
pikselin ve uzun pozlama ile elde edilen pikselin imzalarını üst üste koyarak göstermekteyiz. Son olarak, gürültü giderilmiş piksellerin imzalarını uzun pozlama imzasıyla üst üste koyarak sunmaktayız. Gürültülü imzadan da anlaşılacağı gibi, bu piksel bilinmeyen gerçek gürültü tarafından ciddi şekilde bozulmuştur. Şekil incelendiğinde, teknikler başlangıç bantlarında üstün restorasyon sergilerken, etkinlikleri sonraki bantlarda azalma eğilimindedir. Yaklaşımımızı incelediğimizde, bant 16'ya kadar diğer tüm yöntemlerden daha iyi performans göstermekte ve sonraki bantlarda daha doğru imza restorasyonu sağlamaktadır.

5.5.3. Bileşen İşlevsellik Analizi

CST3D modelimizin bileşenlerinin etkinliğini değerlendirmek için, karışım gürültü (durum 5) ile kirletilmiş WDC ve ICVL verileri üzerinde bazı analiz çalışmaları gerçekleştirmekteyiz. Tüm analizler Çizelge 5.13'te verilmektedir. Çizelgede, varsayılan modelimiz hem WDC hem de ICVL veri kümeleri için kalın yazı tipi ile vurgulanmaktadır. Diğer satırlardaki sonuçlar ilgili veri için bu kalın yazı tipiyle belirtilen sonuçlarla



Şekil 5.13 Doğal gürültülü HSIDwRD veri kümesi sonuçları. Her görüntüde, sağ alt köşede renkli bir kutunun içinde yakınlştırılmış bir bölge gösterilmektedir. (a) Band 32 kullanılarak uzun pozlama HSG'nin gri tonlamalı görüntüsü, (b) Kısa pozlama kirli görüntü, (c) BM4D, (d) LRMR, (e) LRTDTV, (f) LRTF-DFR, (g) FastHyMix, (h) HSID-CNN, (i) QRNN3D, (j) SERT, (k) SST, (l) TRQ3DNet, (m) HSDT, (n) CST3D (Bizim).



Şekil 5.14 HSIDwRD verisindeki (272, 272) pikselinin spektral imza restorasyon kalitesi.

kıyaslandığını vurgulamak gerekmektedir. Bulgularımızı doğrulamak için, her modelin ortalama performansını elde etmek amacıyla, ICVL veri kümesi üzerinde 40 veri kullanarak kapsamlı bir değerlendirme gerçekleştirmekteyiz.

Çizelge 5.13 WDC ve ICVL Veri Kümelerinde Durum 5 Karışım Gürültü ile Bileşen Analiz Çalışmasının Nicel Değerlendirmesi.

Düzen	#Kanal	Modülator	Birleştirme	Aktivasyon Fonk.	Veri	MPSNR↑	MSSIM↑	SAM↓	#param.
Seri	24	Var	-	Yok	WDC	32.562	0.985	0.059	1.56M
Paralel	24	Yok	dwconv3	Yok	WDC	32.636	0.985	0.048	1.50M
Paralel	24	Var	dwconv3	Var	WDC	33.055	0.986	0.046	1.59M
Paralel	24	Var	dwconv3	Yok	WDC	33.070	0.986	0.046	1.59M
Paralel	24	Var	conv3	Yok	ICVL	41.095	0.986	0.055	3.67M
Paralel	4	Var	dwconv3	Yok	ICVL	39.010	0.978	0.064	0.09M
Paralel	8	Var	dwconv3	Yok	ICVL	40.474	0.981	0.060	0.20M
Paralel	16	Var	dwconv3	Yok	ICVL	40.867	0.982	0.060	0.74M
Paralel	24	Var	dwconv3	Yok	ICVL	41.547	0.984	0.059	1.59M
Paralel	32	Var	dwconv3	Yok	ICVL	41.519	0.983	0.065	2.77M

CSA ve SSA Düzenleri. Burada, CSA ve SSA'nın seri veya paralel bağlandığında ağır performansını incelemekteyiz. Karışım gürültülü WDC ile gerçekleştirilen seri bağlama inceleme sonuçları, Çizelge 5.13'ün ilk satırında sunulmaktadır. Seri olarak bağlandığında, öznitelik birleştirme gerekmediğinden derinlemesine 3B evrişim kullanılmaktadır. Buna bağlı olarak parametre sayısında azalma görünmektedir. Paralel bağlantı (Çizelge 5.13'ün 4. satırı) PSNR'de yaklaşık 0.5dB'lik bir kazanç sağladığını görmekteyiz.

Modülatorlerin Varlığı. Bölüm 4.2.1.'de, modülatorlerin eğitim ve dikkat üzerindeki etkileri incelenmektedir. Bu bölümde, sonuçları ve parametre sayısını değerlendirmekteyiz. Öğrenilebilir modülatorler kullanılmadığında, parametre sayısı biraz azalmakta, ancak performansımızın yaklaşık 0.4dB düştüğünü (Çizelge 5.13'ün 4. satırına göre) görmekteyiz. Bu sonuçlar, Çizelge 5.13'ün ikinci satırında verilmektedir.

Aktivasyon Fonksiyonun Varlığı. Daha önce belirtildiği gibi, SGate bloğumuzdaki eleman bazında çarpmanın doğasındaki doğrusalsızlık, ek aktivasyon fonksiyonlarına olan ihtiyacı ortadan kaldırmaktadır. Bloğumuza bir sigmoit fonksiyonu dahil edildiğinde sonuçları analiz etmekteyiz. Çizelge 5.13'ün üçüncü satırı, MPSNR sonucunun biraz kötüleştiğini göstermektedir. Ancak, diğer metriklerin değerleri orijinal modelimizle aynı kalmaktadır. Bu nedenle, tasarımıımızda aktivasyon fonksiyonların gereksiz olduğu sonucuna varmaktayız.

Birleştirme. Dikkat çıktılarının paralel olarak birleştirilmesi sırasında, öznitelik birleştirme için 3B evrişim (conv3) veya derinlemesine 3B evrişim (dwconv3) kullanılmaktadır. Çizelge 5.13'ün beşinci satırında verilen bulgularımız, conv3 kullanılması parametre sayısını önemli ölçüde artırırken (Çizelge 5.13'ün 9. satırına göre), metrik iyileştirmeleri sağlamadığını göstermektedir. Aslında, PSNR metriği conv3 uygulamasının daha kötü sonuçlara yol açtığını göstermektedir.

Giriş Kanal Sayısı. Son olarak, varsayılan modelimizin giriş kanal sayısını değiştirerek deneyler gerçekleştirmekteyiz. Kanal sayısı 4, 8, 16, 32 ve varsayılan kanal sayısı (24) ile sonuçları Çizelge 5.13'ün 6. ila 10. satırlarında sunmaktayız. Giriş kanal sayısını azaltmanın bir sonucu olarak, modelimizin yapısı nedeniyle derin katmandaki kanal sayısı da azalmaktadır. Buna bağlı olarak, parametre sayısının kanal sayısına göre önemli ölçüde değiştiğini görmekteyiz. Kanal sayıları azaldıkça MSSIM ve SAM sonuçlarını incelediğimizde, yöntemimizin daha az parametreyle de çok iyi sonuçlar elde ettiğini gözlemlemekteyiz. Bu değerler arasında dramatik farklılıklar gözükmemekte, çünkü değerler zaten oldukça yüksektir. MPSNR'ye baktığımızda, kanal sayısını 24'ten 4'e düşürüldüğünde 2.5dB azaldığını görmekteyiz. Kanal sayısını 24'ten 32'ye çıkartıldığında şaşırtıcı bir şekilde sonuçlar iyileşmek yerine kötüleşmektedir. Bu nedenle, 24 kanalı varsayılan olarak belirlemekteyiz. Ayrıca, kanal sayısı 4 olduğunda bile modelimizin karşılaştırdığımız yöntemlerin çoğuna kıyasla yüksek sonuçlar verdiği belirtilmelidir.

5.6. Performans Değerlendirmesi: Gürültü Giderici Ağların Öz-Gözetimli Kalibrasyonu

Bu bölümde, BBSS öğrenme yöntemimizin simüle edilmiş gürültü ve gerçek test verileri üzerindeki hem nicel hem de nitel sonuçlarını sunmaktayız. İki aşamalı öğrenmenin etkinliğini göstermek amacıyla, BBSS öğrenme, gözetimli eğitim aşamasında daha önce görülmemiş gürültü veya veri ile gerçekleştirilmekte ve başarılı sonuçlar elde edilmektedir.

5.6.1. Simüle Edilmiş Gürültü Deneyleri

Bu bölümde, BBSS yöntemimizle eğitilen farklı ağların simüle edilmiş veriler üzerindeki sonuçlarını sunmaktayız. Nicel ölçümler ve görselleştirmeler kullanarak etkinliğini analiz etmekteyiz. Ayrıca, yaklaşımımızı mevcut çalışmalarla karşılaştırmaktayız.

CAVE Veri Kümesi Üzerinde BBSS Öğrenme. İlk olarak, HSG gürültü giderme için literatürden [56] uyarlayarak modifiye edilmiş bir hibrit CNN-Dönüştürücü mimarisi kullanmaktayız ve bu modeli CNNFormer olarak adlandırmaktayız. Ardından, Çizelge 5.8’de açıklanan stratejiyi izleyerek, ağları Gauss gürültülü veriler üzerinde 50 epok boyunca gözetimli öğrenme ile eğitmekteyiz. Daha sonra, GN ile eğitilen modelleri, tüm bantlara bağımsız ve özdeş dağılımlı olmayan (non-i.i.d.) GN ekleyip, bantların üçte birini rastgele seçerek %10 ila %70 arasında değişen yoğunluklarda IN eklediğimiz bir senaryoda (Bölüm 5.3.’te Durum 4) test etmekteyiz. Sonrasında, CNNFormer modelini 50. epoktaki ağırlıklarla başlatarak, önerilen BBSS öğrenme stratejisini kullanıp gürültülü test verileri üzerinde kalibre etmekteyiz. Bu öz-gözetimli eğitim aşaması toplamda 34 epoktan oluşmaktadır.

Çizelge 5.14, bu deneyin nicel sonuçlarını göstermektedir. Önerilen öğrenme şemasının performansını değerlendirmek için klasik yaklaşımlar (öğrenme tabanlı olmayan) BM4D [68], BCTF-HSI [102], NMoG [106], LLRGTV [107] ve GLF [108] ile karşılaştırılmaktadır. Ayrıca, HSG’leri gürültüden arındırmak için önerilen CNN tabanlı QRNN3D [32] ve hibrit CNN-Dönüştürücü tabanlı TRQ3D [84] ile karşılaştırma gerçekleştirmekteyiz. Bu modellerin hepsi HSG’leri gürültüden arındırmada etkinlik göstermiş modelleridir. Derin modelleri CNNFormer ile aynı şekilde eğitimini gerçekleştirdikten sonra test verisi üzerinde koşturarak sonuçları oluşturmaktayız.

Şekil 5.15’te, CAVE verilerinden seçilen bir test verisi, bu verinin gürültülü versiyonu ve QRNN3D [32] ve TRQ3D [84] sonuçları ile CNNFormer modelimizin iki versiyonunun gürültü giderme sonuçlarını sunmaktayız: biri sadece GN ile eğitilmiş, diğeri ise BBSS


¹-P Gauss gürültüsü ile eğitilmiş modelleri temsil eder.

Çizelge 5.14 CAVE Veri Kümesi Üzerindeki Nicel Sonuçlar.

Yöntem	MPSNR \uparrow	MSSIM \uparrow
Noisy HSI	16.421	0.137
BM4D [68]	27.951	0.592
BCTF-HSI [102]	30.773	0.759
NMoG [106]	26.711	0.608
LLRGTV[107]	31.468	0.800
GLF[108]	29.370	0.767
QRNN3D-P ¹ [32]	25.119	0.599
TRQ3D-P ¹ [84]	24.855	0.604
CNNFormer-P ¹	27.804	0.646
CNNFormer + BBSS	34.341	0.904

ile kalibre edilmiş. QRNN3D, TRQ3D ve CNNFormer modellerimizin gözetimli öğrenme aşamasında dürtü gürültüsü (IN) ile eğitilmemiş olması nedeniyle çıktı sonuçları artefaktlar (görüntü hataları) göstermektedir. Sonuçlar, yalnızca GN ile eğitilen ağ modellerinin test verilerindeki dürtü gürültüsünü kısmen azaltabildiğini ve bunun da düşük doğruluk ve genel olarak zayıf performansa yol açtığını göstermektedir. Bu, ağ modellerinin gözetimli eğitim aşamasında benzer gürültülerle karşılaşmamış olmasından kaynaklanmaktadır. Gauss gürültüsü üzerinde eğitilen ağlar, küçük varyasyonları yumuşatmaya odaklanmaktadır. Ancak, dürtü gürültüsünün neden olduğu keskin değişikliklerle başa çıkmak için donanımlı değillerdir. Öte yandan, BBSS kalibrasyon aşamasının CNNFormer ağının performansını artırmadaki faydaları açıkça görülmektedir. Hem MPSNR hem de MSSIM metrik skoruna göre, Çizelge 5.14'te listelenen klasik yöntemlere kıyasla oldukça başarılı sonuçlar elde etmekteyiz. Ayrıca, kalibrasyon sürecinin hızlı ve verimli olduğunu, tek bir veri örneği kullanılarak hızlı bir şekilde tamamlandığını belirtmek gerekmektedir. Sonuç olarak, iki aşamalı eğitim süreci, ağın daha önce karşılaşmadığı gürültüyü azaltmada ve önerilen ağın adaptasyonunu artırmada güçlü performans ve verimlilik gösterdiği açıktır.

WDC Veri Kümesi Üzerinde BBSS Öğrenme. Bu örnekte, Bölüm 4.2.'de tanımlanan CST3D modelimizi BBSS öğrenme stratejisi kullanarak eğitmekteyiz ve bu modeli ICVL üzerinde önceden eğitilmiş bir model ve WDC üzerinde gözetimli öğrenme ile ince ayar yapılmış bir versiyonla karşılaştırmaktayız. Çizelge 5.15 üç koşunun sonuçlarını sunmaktadır. Önceden



Şekil 5.15 İki aşamalı öğrenme yaklaşımının etkinliğini gösteren görsel örnekler. (a) Sahte renkli CAVE verisi (bantlar: 30,15,10), (b) Her bantı GN ile kirlenmiş ve bantların üçte birinin rastgele seçilip %10 ile %70 arasında değişen yoğunlukta IN eklenmiş gürültülü görüntü, (c) GN ile eğitilmiş QRNN3D sonucu, (d) GN ile eğitilmiş TRQ3D sonucu, (e) GN ile eğitilmiş CNNFormer sonucu, (f) Gürültülü görüntüyle 34 epok BBSS öğrenme kullanılarak eğitilmiş CNNFormer sonucu.

eğitilmiş model (CST3D-P-ICVL) karmaşık gürültüler üzerinde eğitilmiş olmasına rağmen, WDC senaryolarına uygulandığında zayıf performans göstermektedir. Önceden eğitilmiş modelin performansının özellikle karışım gürültü durumunda önemli ölçüde düşük kaldığı gözlemlenmektedir. Bu durum, eğitim verileri ile test verileri arasındaki uyumsuzluğu göstermektedir. Çizelge 5.1’de görüldüğü gibi, ICVL ve WDC veri kümeleri arasındaki spektral bant aralığının farklı olması önceden eğitilmiş modelin performansını etkilediğini söyleyebiliriz.

¹-P-ICVL Tablo 5.8’de açıklanan stratejiyi izleyerek ICVL veri setleri üzerinde önceden eğitilmiş modeli ifade etmektedir.

²-FT WDC veri setleri üzerinde ince ayar yapılmış modeli ifade etmektedir.

Çizelge 5.15 WDC Veri Kümesinde Beş Karmaşık Gürültü Durumu ile Farklı Öğrenme Yaklaşımlarının Nicel Değerlendirmesi.


Yöntem	Durum 1: GN			Durum 2: GN & SN			Durum 3: GN & DN			Durum 4: GN & IN			Durum 5: Karışım gürültü		
	MPSNR↑	MSSIM↑	SAM↓	MPSNR↑	MSSIM↑	SAM↓	MPSNR↑	MSSIM↑	SAM↓	MPSNR↑	MSSIM↑	SAM↓	MPSNR↑	MSSIM↑	SAM↓
Kirli HSG	18.508	0.690	0.278	18.982	0.711	0.264	17.338	0.653	0.328	15.269	0.531	0.420	13.402	0.500	0.464
CST3D-P-ICVL ¹	30.429	0.976	0.063	30.562	0.977	0.062	29.839	0.973	0.067	29.021	0.965	0.076	23.684	0.915	0.133
CST3D-BBSS	<u>31.836</u>	<u>0.981</u>	<u>0.050</u>	<u>31.453</u>	<u>0.978</u>	<u>0.053</u>	<u>31.053</u>	<u>0.978</u>	<u>0.054</u>	<u>31.203</u>	<u>0.979</u>	<u>0.054</u>	<u>31.205</u>	<u>0.978</u>	<u>0.055</u>
CST3D-FT ²	34.824	0.991	0.037	34.210	0.990	0.040	33.884	0.989	0.041	33.879	0.989	0.041	33.070	0.986	0.046

Sonraki adımda, CST3D modelimizi Çizelge 5.8’de detaylandırıldığı gibi 100. epoktan gelen ağırlıklarla başlatıp temiz veri kullanmadan gürültülü WDC verileri üzerinde önerilen BBSS öğrenme stratejisini kullanarak kalibre etmekteyiz. Bu öz-gözetimli eğitim aşaması, tüm gürültülü durumlar için 50 epoktan oluşmaktadır. Öz-gözetimli kalibrasyon (CST3D-BBSS) ve önceden eğitilmiş modeller için tablonun sonuçları incelendiğinde, tüm durumlarda metrik bazında iyileşmeler gözlemlenmektedir. Karışım durumunda, öz-gözetimli kalibrasyon önceden eğitilmiş modele kıyasla MPSNR’de yaklaşık 7 dB’lik bir artış göstererek önemli bir performans artışı sağlamaktadır. SAM metriğine bakıldığında, önemli bir azalma görülmektedir. Bu da, BBSS öğrenmenin spektral bant restorasyonu için modelin performansı arttırdığını göstermektedir.

Son olarak, önceden eğitilmiş modelin temiz veri içeren WDC veri kümesi üzerinde ince ayar (CST3D-FT) yapılması, beklendiği gibi, en iyi performansı sağlamaktadır. Ancak, öz-gözetimli kalibrasyon sonuçlarının bu üst sınıra oldukça yakın olması dikkat çekicidir. Aslında, bu sonuçlar, temiz veri olmadığında BBSS kalibrasyonunun modelin performansını arttırmadaki etkinliğini açıkça göstermektedir.

5.6.2. Gerçek Veri Deneyi

URBAN veri kümesinin bazı bantları seyrek gürültüye maruz kalırken, bazıları atmosferik etkiler nedeniyle yoğun gürültüden etkilenmiştir. Bu bölümde, CAVE veri kümesine benzer şekilde, ağırları GN ile eğitilmiş modelle (Tablo 5.8’de verilen 50. epok) iklendirmekte ve ardından URBAN verisi üzerinde BBSS öğrenme ile kalibre ettikten sonra aynı veriler ile test sonuçlarını üretmekteyiz. Bu deneyde iki model kullanılmaktadır:



Şekil 5.16 URBAN verinin altı farklı spektral bandından alınmış gri tonlamalı görüntüler. (a) Orijinal kirli bantlar, (b) BM4D, (c) BTC-HSI, (d) GLF, (e) GN ile eğitilmiş QRNN3D sonuçları, (f) Gürültülü görüntüyle 50 epok BBSS öğrenme kullanılarak eğitilmiş CNNFormer sonuçları, (g) GN ile eğitilmiş CST3D sonuçları, (h) Gürültülü görüntüyle 50 epok BBSS öğrenme kullanılarak eğitilmiş CNNFormer sonuçları.

önerilen CST3D modelimiz ve QRNN3D modeli. Sonuçları oluşturduktan sonra, farklı yöntemler kullanılarak elde edilen bazı bantların orijinal ve gürültü giderilmiş versiyonlarını

Şekil 5.16’da sunmaktayız.

Şekilde anlaşıldığı üzere, hem klasik (özellikle BTC-HSI ve GLF) hem de derin öğrenme yaklaşımları (GN ile eğitilmiş ve BBSS öğrenme ile kalibre edilmiş versiyonları dahil) düşük gürültülü 76 ve 87 numaralı bantlarda başarılı sonuçlar elde etmektedir. Ancak, asıl farklılıkları gürültünün daha fazla bozduğu bantlarda (104, 139, 150 ve 207) görmekteyiz. Klasik yöntemlerde ve önceden eğitilmiş modellerde gürültü etkilerinin az ya da çok ortadan kaldırılamadığı açıkça görülmektedir. Neyse ki, hem CST3D hem de QRNN3D modelleri bu veriler için BBSS öğrenme ile kalibre edildiğinde sonuçların iyileştiği ve artefaktlerin başarılı bir şekilde ortadan kaldırıldığı görülmektedir. Sonuç olarak, öz-kalibrasyon yöntemi, hem CST3D hem de QRNN3D ağlarının karmaşık gürültü içeren gerçek dünya verileri üzerindeki performansını önemli ölçüde artırmaktadır.

6. SONUÇLAR

HSG'ler çok sayıda spektral banda sahip olduklarından görüntüdeki objeleri ayırt edilmesini kolaylaştırmaktalar. HSG sensörleri genellikle bir uçak veya uyduya monte edilip zorlu çevresel koşullarda çalışmaktalar. Bu nedenle, gürültüye kolayca maruz kalmaktalar. HSG'lerin işlenmesi için bu gürültünün ortadan kaldırılması son derece önemli bir konudur. HSG'lerdeki gürültü, analiz aşamalarında performansı olumsuz etkileyebilmekte ve verilerden faydalı bilgileri çıkarmayı zorlaştırmaktadır. HSG gürültü giderme, görüntü kalitesini iyileştirmek ve faydalı bilgilerin çıkarılmasını kolaylaştırmak için gürültüyü öğrenme ve ardından bertaraf etme işlemidir.

Gürültü giderme alanında, CNN'ler verilerin yerel uzamsal-spektral özniteliklerini etkili bir şekilde yakalama yetenekleri sebebiyle HSG restorasyonunda sıklıkla kullanılmaktadır. Bu yapılar, verideki karmaşık desenleri öğrenebilmekte ve önemli uzamsal-spektral bilgileri korurken gürültüyü bertaraf edebilmektedir. Bu etkili gürültü giderme süreci, ardışık işlemlerin (hedef takibi, sınıflandırma vb.) performansını ve doğruluğunu artırılmasına yol açmaktadır. Fakat, CNN'ler kendilerini görüntünün içeriğine göre uyarlayamamakta ve global öznitelikleri yakalamak için çok derin katmanlara ihtiyaç duymaktadır. Bu iki özellik, HSG'lerin değişken içeriklere sahip olması ve yerel bilgilerin gürültü tarafından zarar görmesi gibi durumlarda etkili bir şekilde öznitelik çıkartmak için oldukça önem arz etmektedir. Bu dezavantajları ele alarak, bu tez çalışmasında HSG gürültü giderme için iki yeni dinamik ağ önerilmektedir. Bu ağlar, HSG'lerdeki her türlü gürültü çeşidini gideren veya bunların birleşiminde oluşan bozulmaları etkili bir şekilde restore eden mimarilerdir. Kendilerini görüntünün içeriğine göre uyarlama yeteneklerinden dolayı gürültü gidermede yüksek performans göstermektedirler.

İlk olarak, HSG'lerde sıklıkla görünen GN, SN, IN, DN ve bunların birleşimiyle oluşan karışım gürültü türlerini gidermek için SM-CNN isminde bir yapı sunmaktayız. SM-CNN komşu bantları kullanarak orta bandın gürültüsünü giderme mimarisi sayesinde, farklı uzamsal-spektral özelliklere sahip verileri tek bir modelle ele alabilmektedir. Ayrıca,

önerdiğimiz SSMRB , giriş verisine dayalı dinamik öznitelikleri çıkartarak ağımızın farklı gürültülere uyum sağlamasına olanak tanımaktadır. Sonuçların niteliksel ve niceliksel değerlendirmesi, önerilen yapının hem yapay gürültü hem de modellenemeyen gerçek dünya gürültü türlerinde diğer CNN tabanlı modellerden daha verimli olduğunu göstermektedir. Daha önce de belirttiğimiz gibi, modelimiz global bilgileri etkili bir şekilde yakalama yeteneği sınırlı olduğu için bazı Dönüştürücü tabanlı modellere kıyasla daha düşük performans sergilemektedir. Çünkü, hem yerel detayları hem de uzak bölgeler arasındaki ilintileri inceleyerek, görüntünün daha derin bir analizi sağlanabilmektedir.

Yakın tarihte, Dönüştürücü'ler global öznitelikleri yakalamak için bir alternatif olarak önerilmiştir. Dönüştürücü'ler, öz-dikkat mekanizmaları sayesinde uzun mesafeli ilişkileri yakalamakta ve görüntü hakkında daha verimli çıkarımlar sağlamaktadır. Öte yandan, Dönüştürücü'lerin öz-dikkat modülü, görüntüdeki yakın piksellerin uzak piksellerden daha ilintili olduğu gerçeğini göz ardı etmektedir. Bu sebeple, yerel ilintileri modellemeyi öğrenmek için büyük miktarda eğitim verisine ihtiyacı duymaktadır. Bu ihtiyaç, sınırlı veriye sahip HSG analiz işlemleri için istenmeyen bir durumdur. Bütün bunları göz önüne alarak, bu çalışmada, hibrit bir CNN- Dönüştürücü modeli önermekteyiz. Bu iki yapıyı birleştirerek, her iki yaklaşımın da güçlü yönlerinden yararlanmak ve gürültü giderme işleminde yüksek performans elde etmek amaçlanmaktadır.

İkinci bir mimari olarak, HSG'ler için özel tasarlanmış yeni bir gürültü giderme ağı olan CST3D modelimizi ayrıntılarıyla tanıtmaktayız. CST3D, diğer modelimizde olduğu gibi tek bir modelle çeşitli gürültü türlerini (GN, SN, IN, DN, karışım gürültü ve modellenemeyen gerçek dünya gürültüleri) etkili bir şekilde gidermektedir. Modelimizdeki Dönüştürücü katmanları iki dikkat mekanizmasından oluşmaktadır: global spektral bilgileri yakalayan spektral öz-dikkat ve kanallar arası global bilgiyi yakalayan uzamsal ve spektral detayları birlikte işleyen kanal bazlı öz-dikkat. Ayrıca, bu iki öz-dikkat mekanizmasında hem spektral hem de öznitelik kanalları için öğrenilebilir modülatörler yer almaktadır. Bu modülatörler sayesinde, gürültü giderme sürecinde ilgili bantlara öncelik verilmesi, dikkat odağını keskinleştirilmesi ve eğitimi istikrara kavuşturmak sağlanmaktadır. Bunun yanı sıra, yerel bilgileri etkili ve hızlı yakalamak için Dönüştürücü'lerin yapısında veya ayrı

olarak 3B evriřim katmanları kullanılmaktadır. Görsel ve nicel deęerlendirmeler aracılıęıyla, önerilen modelimizin alanındaki en iyi yöntemlere kıyasla üstün performans sergilediđini göstermekteyiz. CNN'ler ile Dönüřtürücüleri birleřtirerek hesaplama karmařıklıęını azaltan ve yerel bilgileri hızlıca öğrenen hibrit bir model önersek de, bu karmařıklıęı yeni yaklařımlarla ele almak için daha fazla arařtırma gerekmektedir. Teknolojik ilerlemeler bu karmařıklıęın üstesinden gelse bile enerji tasarrufu ve verimli kaynak kullanımını konusundaki ilerlemenin son derece önemli olduđunu vurgulamak isteriz.

Buna mukabil, HSG gürültü giderme için kritik noktalardan biri de ađın eđitimidir. Bu minvalde, gözetimli öğrenme sıklıkla kullanılan bir eđitim türü olmaktadır. Bu eđitim türünde ađın kirli görüntüden temiz görüntüye dođrusal olmayan bir eřleřme öğrenmesi için çok sayıda eđitim çifti oluřturulmakta ve temiz veri gözetiminde ađ eđitilmektedir. Ancak, çok sayıda veri toplamak HSG'ler için zorlu ve maliyetli bir süreçtir. Literatürde halka açık olarak sunulan veri sayısı oldukça kısıtlıdır. Dolayısıyla, gözetimli eđitim genellikle yapay olarak modellenen gürültü, temiz verilere eklenerek gerçeleştirilmektedir. Bu yapay gürültü üzerinde eđitilen modeller daha sonra gerçek veriler üzerinde test edilmektedir. Ancak, gerçek gürültülü test verileri üzerindeki başarı eđitim ařamasındaki modellenen gürültülerin bu verideki gürültüye uyumlu olmasına baęlıdır. Bu çalışmada modellediđimiz karmařık gürültü durumları ile eđitim yapmak, performansı arttırdıđını göstermekteyiz. Buna raęmen, HSG'lerdeki uzamsal ve spektral çeřitlilik ađların genelleme yeteneđini olumsuz etkilediđini görmekteyiz. Bu nedenle, öz-gözetimli öğrenme, test verileri üzerindeki uyumu arttırmada alternatif bir yaklařım sunmaktadır. Bu yöntem, ađların yalnızca gürültülü veriler üzerinde eđitilmesine ve ađın kirli veriler iđerisindeki ilintileri öğrenmesine olanak tanımaktadır. Son zamanlarda, öz-gözetimli eđitimle ilgili yöntemlere ilgi artmaktadır. Ancak, önerilen yöntemlerin başarısı HSG'ler için çeřitlilik gösteren önsel bilgilere dayanmaktadır.

Son olarak, bu tez, gözetimli eđitim sırasında görülmemiř gürültü desenleri iđereren HSG'ler için iki ařamalı bir öğrenme stratejisi sunmaktadır. İlk ařama, gözetimli öğrenme modelinin yapay olarak modellenmiř yoğun gürültüler ile temiz veri gözetiminde ađların eđitimini iđeremektedir. İkinci ařama, öz gözetimli kalibrasyon ile yalnızca gürültülü verileri kullanarak modelin belirli gürültü için uyum saęlamasını iđeremektedir. Bu ikinci ařamada,

orta spektral bandı tahmin etmek için komşu bantlar hedef olarak kullanılmaktadır. Ağı anlamlı ilişkiler öğrenmeye zorlamak ve yalnızca girdiyi kopyalamayı engellemek için hedef olarak kullanılan bant, giriş verilerinden çıkartılarak spektral kör bir bölge oluşturulmaktadır. Önerdiğimiz bu öz-gözetimli yöntemle modelin daha önce görmediği gürültü türlerine uyumunu arttırdığını ve buna bağlı olarak modelin gürültü giderme yeteneğini iyileştirdiğini göstermekteyiz. Sonuç olarak, bu yöntemimizde eğitim çifti oluşturmak için doğrudan komşu bantları kullanılmaktadır ve herhangi bir önsel bilgiyi kullanmamaktayız. Bununla beraber, HSG'ler çok kapsamlı bilgiler içermekte ve farklı verileri kapsayan öznelikler çıkartılarak yeni yöntemler geliştirmek açık bir alan olarak kalmaktadır.

Gelecek araştırmalarımız, HSG gürültü giderme alanında durum uzayı modeli (state space model; SSM) tabanlı yeni modeller geliştirme üzerinde olacaktır. SSM'ler kontrol teorisinde bir sistemin dinamiklerini içsel değişkenler olarak bilinen durumlar aracılığıyla temsil etmek için güçlü araçlar olarak kullanılmaktadır. Yakın tarihte, Mamba mimarisi [109], SSM'lerden yararlanarak Dönüştürücü modellere rakip olan yeni bir yaklaşım sunmaktadır. Mamba, veri bağımlı SSM mimarisi kullanarak Dönüştürücü'lere kıyasla global bilgileri daha verimli bir şekilde yakalamaktadır. Bu mimari, görsel görevler için de uyarlanabilir [110, 111] ve HSG restorasyonu için bir alternatif sunma potansiyeline sahiptir.

Diğer potansiyel içerem alanlar aşağıdaki gibi listelenebilir:

- **DİFÜZYON MODELLER:** Bu üreteç modelleri, bir görüntüyü bozmaya yönelik ileri yönde aşamalı olarak gürültü eklenen bir süreç ve eklenen gürültüyü gideren öğrenilebilir bir ters süreç içermektedir. Literatürde, bu modeller HSG gürültüsünü gidermek için RGB destekli görüntüler kullanılmaktadır [112].
- **GÜDÜMLÜ MODELLER:** Eğitim veya test süreci sırasında yönlendirme veya ek bilgi içeren bir sinir ağı mimarisi türüdür. Güdüm bilgileri başka sensörlerden veya doğrudan HSG'den gelebilmektedir. Örneğin, çıkarılan özgün görüntüler (eigenimages) kullanılarak bu tür bir yönlendirme sağlanabilmektedir [113].

- RGB2HSG: RGB görüntülerden HSG veri oluşturmak için düşük maliyetli yöntemler içermektedir. Son zamanlardaki ilerlemeler, bu dönüşümü sağlamak için 3B CNN'lerin eğitilmesini içermektedir [114].

KAYNAKLAR

- [1] Joseph N Pelton, Scott Madry, and Sergio Camacho-Lara. *Handbook of satellite applications*. Springer Publishing Company, Incorporated, **2012**.
- [2] Paul Gader, Alina Zare, Ryan Close, Jen Aitken, and Grady Tuell. Muufl gulfport hyperspectral and lidar airborne data set. *Univ. Florida, Gainesville, FL, USA, Tech. Rep. REP-2013-570*, **2013**.
- [3] Lujendra Ojha, Mary Beth Wilhelm, and Scott L Murchie et al. Spectral evidence for hydrated salts in recurring slope lineae on Mars. *Nature Geoscience*, 8(11):829–832, **2015**.
- [4] Prasad S Thenkabail and John G Lyon. *Hyperspectral remote sensing of vegetation*. CRC press, **2016**.
- [5] Xiangyong Cao, Feng Zhou, and Lin Xu et al. Hyperspectral image classification with markov random fields and a convolutional neural network. *IEEE Trans. Image Process.*, 27(5):2354–2367, **2018**.
- [6] Haoyang Yu, Zhen Xu, Ke Zheng, Danfeng Hong, Hao Yang, and Meiping Song. Mstnet: A multilevel spectral–spatial transformer network for hyperspectral image classification. *IEEE Trans. Geosci. Remote Sens.*, 60:1–13, **2022**.
- [7] José M Bioucas-Dias, Antonio Plaza, Nicolas Dobigeon, Mario Parente, Qian Du, Paul Gader, and Jocelyn Chanussot. Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression-based approaches. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 5(2):354–379, **2012**.
- [8] Sefa Kucuk and Seniha Esen Yuksel. Total utility metric based dictionary pruning for sparse hyperspectral unmixing. *IEEE Trans. Comput. Imaging*, 7:562–572, **2021**.

- [9] Sefa Kucuk and Seniha Esen Yuksel. Pointwise mutual information based graph laplacian regularized sparse unmixing. *IEEE Geosci. Remote Sens. Lett.*, 19:1–5, **2022**.
- [10] Orhan Torun and Seniha Esen Yuksel. Unsupervised segmentation of LiDAR fused hyperspectral imagery using pointwise mutual information. *Int. J. Remote Sens.*, 42(17):6461–6476, **2021**.
- [11] Asgeir Bjorgan and Lise Lyngsnes Randeberg. Towards real-time medical diagnostics using hyperspectral imaging technology. In *Biomed Spectrosc Imaging. IV*, volume 9537, pages 137 – 145. SPIE, **2015**.
- [12] Markel San Nicolas, Aitor Villate, Iker Alvarez-Mora, Maitane Olivares, Oier Aizpurua-Olaizola, Aresatz Usobiaga, and José Manuel Amigo. Nir-hyperspectral imaging and machine learning for non-invasive chemotype classification in cannabis sativa l. *Computers and Electronics in Agriculture*, 217:108551, **2024**.
- [13] Yihang Lu, Xuan Zheng, Haonan Xin, Haoliang Tang, Rong Wang, and Feiping Nie. Ensemble and random collaborative representation-based anomaly detector for hyperspectral imagery. *Signal Process.*, 204:108835, **2023**. ISSN 0165-1684.
- [14] Tao Zhang, Ying Fu, and Cheng Li. Hyperspectral image denoising with realistic data. In *IEEE/CVF ICCV*, pages 2248–2257. **2021**.
- [15] Tahereh Bahraini, Abbas Ebrahimi-Moghadam, Morteza Khademi, and Hadi Sadoghi Yazdi. Bayesian framework selection for hyperspectral image denoising. *Signal Process.*, 201:108712, **2022**. ISSN 0165-1684.
- [16] Torbjørn Skauli. Sensor noise informed representation of hyperspectral data, with benefits for image storage and processing. *Optics Express*, 19(14):13031–13046, **2011**.

- [17] Kostadin Dabov, Alessandro Foi, Vladimir Katkovnik, and Karen Egiazarian. Image denoising by sparse 3-d transform-domain collaborative filtering. *IEEE Trans. Image Process.*, 16(8):2080–2095, **2007**.
- [18] Shuhang Gu, Lei Zhang, Wangmeng Zuo, and Xiangchu Feng. Weighted nuclear norm minimization with application to image denoising. In *IEEE CVPR*, pages 2862–2869. **2014**.
- [19] Matteo Maggioni, Vladimir Katkovnik, Karen Egiazarian, and Alessandro Foi. Nonlocal transform-domain filter for volumetric data denoising and reconstruction. *IEEE Trans. Image Process.*, 22(1):119–133, **2013**.
- [20] Minchao Ye, Yuntao Qian, and Jun Zhou. Multitask sparse nonnegative matrix factorization for joint spectral–spatial hyperspectral imagery denoising. *IEEE Trans. Geosci. Remote Sens.*, 53(5):2621–2639, **2015**.
- [21] Hongyan Zhang, Wei He, Liangpei Zhang, Huanfeng Shen, and Qiangqiang Yuan. Hyperspectral image restoration using low-rank matrix recovery. *IEEE Trans. Geosci. Remote Sens.*, 52(8):4729–4743, **2014**.
- [22] Wei He, Hongyan Zhang, Liangpei Zhang, and Huanfeng Shen. Total-variation-regularized low-rank matrix factorization for hyperspectral image restoration. *IEEE Trans. Geosci. Remote Sens.*, 54(1):178–188, **2016**.
- [23] Yao Wang, Jiangjun Peng, Qian Zhao, Yee Leung, Xi-Le Zhao, and Deyu Meng. Hyperspectral image restoration via total variation regularized low-rank tensor decomposition. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 11(4):1227–1243, **2018**.
- [24] Kaixuan Wei and Ying Fu. Low-rank bayesian tensor factorization for hyperspectral image denoising. *Neurocomputing*, 331:412–423, **2019**.
- [25] Yi Chang, Luxin Yan, Xi-Le Zhao, Houzhang Fang, Zhijun Zhang, and Sheng Zhong. Weighted low-rank tensor recovery for hyperspectral image restoration. *IEEE Trans. on Cybernetics*, 50(11):4558–4572, **2020**.

- [26] Haijin Zeng, Xiaozhen Xie, and Jifeng Ning. Hyperspectral image denoising via global spatial-spectral total variation regularized nonconvex local low-rank tensor approximation. *Signal Process.*, 178:107805, **2021**.
- [27] Yang Chen, Wenfei Cao, Li Pang, and Xiangyong Cao. Hyperspectral image denoising with weighted nonlocal low-rank model and adaptive total variation regularization. *IEEE Trans. Geosci. Remote Sens.*, pages 1–1, **2022**.
- [28] Shuang Xu, Jianshe Zhang, and Chunxia Zhang. Hyperspectral image denoising by low-rank models with hyper-laplacian total variation prior. *Signal Process.*, 201:108733, **2022**.
- [29] Yi Chang, Luxin Yan, Houzhang Fang, Sheng Zhong, and Wenshan Liao. Hsi-denet: Hyperspectral image restoration via convolutional neural network. *IEEE Trans. Geosci. Remote Sens.*, 57(2):667–682, **2019**.
- [30] Qiangqiang Yuan, Qiang Zhang, Jie Li, Huanfeng Shen, and Liangpei Zhang. Hyperspectral image denoising employing a spatial–spectral deep residual convolutional neural network. *IEEE Trans. Geosci. Remote Sens.*, 57(2):1205–1218, **2019**.
- [31] Alessandro Maffei, Juan M. Haut, Mercedes Eugenia Paoletti, Javier Plaza, Lorenzo Bruzzone, and Antonio Plaza. A single model cnn for hyperspectral image denoising. *IEEE Trans. Geosci. Remote Sens.*, 58(4):2516–2529, **2020**.
- [32] Kaixuan Wei, Ying Fu, and Hua Huang. 3-d quasi-recurrent neural network for hyperspectral image denoising. *IEEE Trans. Neural Netw. Learn Syst.*, 32(1):363–375, **2021**.
- [33] Erting Pan, Yong Ma, Xiaoguang Mei, Fan Fan, Jun Huang, and Jiayi Ma. Sqad: Spatial-spectral quasi-attention recurrent network for hyperspectral image denoising. *IEEE Trans. Geosci. Remote Sens.*, 60:1–14, **2022**.

- [34] Xiangyong Cao, Xueyang Fu, Chen Xu, and Deyu Meng. Deep spatial-spectral global reasoning network for hyperspectral image denoising. *IEEE Trans. Geosci. Remote Sens.*, 60:1–14, **2022**.
- [35] Yizeng Han, Gao Huang, Shiji Song, Le Yang, Honghui Wang, and Yulin Wang. Dynamic neural networks: A survey. *IEEE Trans. Pattern Anal. Mach. Intell.*, 44(11):7436–7456, **2021**.
- [36] Miaoyu Li, Ji Liu, Ying Fu, Yulun Zhang, and Dejing Dou. Spectral enhanced rectangle transformer for hyperspectral image denoising. In *Proc. of the IEEE/CVF CVPR*, pages 5805–5814. **2023**.
- [37] Orhan Torun, Seniha Esen Yuksel, Erkut Erdem, Nevrez Imamoglu, and Aykut Erdem. Hyperspectral image denoising via self-modulating convolutional neural networks. *Signal Process.*, 214:109248, **2024**.
- [38] Orhan Torun, Seniha Esen Yuksel, Erkut Erdem, and Aykut Erdem. Dual-attention hybrid cnn-transformer for hsi denoising. *unpublished*, **2024**.
- [39] Qiang Zhang, Qiangqiang Yuan, Jie Li, Xinxin Liu, Huanfeng Shen, and Liangpei Zhang. Hybrid noise removal in hyperspectral imagery with a spatial–spectral gradient network. *IEEE Trans. Geosci. Remote Sens.*, 57(10):7317–7329, **2019**.
- [40] Zhiqiang Wang, Zhenfeng Shao, Xiao Huang, Jiaming Wang, and Tao Lu. Sscan: A spatial–spectral cross attention network for hyperspectral image denoising. *IEEE Geosci. Remote. Sens. Lett.*, 19:1–5, **2022**.
- [41] Kai Zhang, Wangmeng Zuo, Yunjin Chen, Deyu Meng, and Lei Zhang. Beyond a gaussian denoiser: Residual learning of deep cnn for image denoising. *IEEE Trans. Image Process.*, 26(7):3142–3155, **2017**.
- [42] Fengchao Xiong, Jun Zhou, Qinling Zhao, Jianfeng Lu, and Yuntao Qian. Mac-net: Model-aided nonlocal neural network for hyperspectral image denoising. *IEEE Trans. Geosci. Remote Sens.*, 60:1–14, **2022**.

- [43] Qian Shi, Xiaopei Tang, Taoru Yang, Rong Liu, and Liangpei Zhang. Hyperspectral image denoising using a 3-d attention denoising network. *IEEE Trans. Geosci. Remote Sens.*, 59(12):10348–10363, **2021**.
- [44] Orhan Torun, Seniha Esen Yuksel, Erkut Erdem, and Aykut Erdem. Self-supervised calibration of the denoising networks for hsi. In *IGARSS*. IEEE, **2024**.
- [45] Jaakko Lehtinen, Jacob Munkberg, Jon Hasselgren, Samuli Laine, Tero Karras, Miika Aittala, and Timo Aila. Noise2noise: Learning image restoration without clean data. *ICML*, pages 2965—2974, **2018**.
- [46] Yuntao Qian, Honglin Zhu, Ling Chen, and Jun Zhou. Hyperspectral image restoration with self-supervised learning: A two-stage training approach. *IEEE Trans. Geosci. Remote Sens.*, 60:1–17, **2021**.
- [47] Alexander Krull, Tim-Oliver Buchholz, and Florian Jug. Noise2void-learning denoising from single noisy images. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, pages 2129–2137. **2019**.
- [48] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Łukasz Kaiser, and Illia Polosukhin. Attention is all you need. *Advances in neural information processing systems*, 30, **2017**.
- [49] Alexey Dosovitskiy, Lucas Beyer, Alexander Kolesnikov, Dirk Weissenborn, Xiaohua Zhai, Thomas Unterthiner, Mostafa Dehghani, Matthias Minderer, Georg Heigold, Sylvain Gelly, et al. An image is worth 16x16 words: Transformers for image recognition at scale. *arXiv preprint arXiv:2010.11929*, **2020**.
- [50] Nicolas Carion, Francisco Massa, Gabriel Synnaeve, Nicolas Usunier, Alexander Kirillov, and Sergey Zagoruyko. End-to-end object detection with transformers. In *European conference on computer vision*, pages 213–229. Springer, **2020**.

- [51] Tero Karras, Samuli Laine, Miika Aittala, Janne Hellsten, Jaakko Lehtinen, and Timo Aila. Analyzing and improving the image quality of stylegan. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, pages 8110–8119. **2020**.
- [52] Ze Liu, Yutong Lin, Yue Cao, Han Hu, Yixuan Wei, Zheng Zhang, Stephen Lin, and Baining Guo. Swin transformer: Hierarchical vision transformer using shifted windows. In *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pages 10012–10022. **2021**.
- [53] Zhendong Wang, Xiaodong Cun, Jianmin Bao, Wengang Zhou, Jianzhuang Liu, and Houqiang Li. Uformer: A general u-shaped transformer for image restoration. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 17683–17693. **2022**.
- [54] Hugo Touvron, Matthieu Cord, Matthijs Douze, Francisco Massa, Alexandre Sablayrolles, and Hervé Jégou. Training data-efficient image transformers & distillation through attention. In *International Conference on Machine Learning*, pages 10347–10357. PMLR, **2021**.
- [55] Jie Hu, Li Shen, and Gang Sun. Squeeze-and-excitation networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 7132–7141. **2018**.
- [56] Liangyu Chen, Xiaojie Chu, Xiangyu Zhang, and Jian Sun. Simple baselines for image restoration. *arXiv preprint arXiv:2204.04676*, **2022**.
- [57] Syed Waqas Zamir, Aditya Arora, Salman Khan, Munawar Hayat, Fahad Shahbaz Khan, and Ming-Hsuan Yang. Restormer: Efficient transformer for high-resolution image restoration. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 5728–5739. **2022**.

- [58] Dmitry Ulyanov, Andrea Vedaldi, and Victor Lempitsky. Deep image prior. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 9446–9454. **2018**.
- [59] Wei He, Hongyan Zhang, Liangpei Zhang, and Huanfeng Shen. Hyperspectral image denoising via noise-adjusted iterative low-rank matrix approximation. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 8(6):3050–3061, **2015**.
- [60] Feng Zhang, Kai Zhang, Wenbo Wan, and Jiande Sun. 3d geometrical total variation regularized low-rank matrix factorization for hyperspectral image denoising. *Signal Process.*, page 108942, **2023**.
- [61] Qiangqiang Yuan, Liangpei Zhang, and Huanfeng Shen. Hyperspectral image denoising employing a spectral–spatial adaptive total variation model. *IEEE Trans. Geosci. Remote Sens.*, 50(10):3660–3677, **2012**.
- [62] Yu-Bang Zheng, Ting-Zhu Huang, Xi-Le Zhao, Yong Chen, and Wei He. Double-factor-regularized low-rank tensor factorization for mixed noise removal in hyperspectral image. *IEEE Trans. Geosci. Remote Sens.*, 58(12):8450–8464, **2020**.
- [63] Chengxun He, Le Sun, Wei Huang, Jianwei Zhang, Yuhui Zheng, and Byeungwoo Jeon. Tslrn: Tensor subspace low-rank learning with non-local prior for hyperspectral image mixed denoising. *Signal Process.*, 184:108060, **2021**.
- [64] Na Liu, Wei Li, Ran Tao, Qian Du, and Jocelyn Chanussot. Multi-graph-based low-rank tensor approximation for hyperspectral image restoration. *IEEE Trans. Geosci. Remote Sens.*, 60:1–14, **2022**.
- [65] Hongyan Zhang, Jingyi Cai, Wei He, Huanfeng Shen, and Liangpei Zhang. Double low-rank matrix decomposition for hyperspectral image denoising and destriping. *IEEE Trans. Geosci. Remote Sens.*, 60:1–19, **2022**.

- [66] Na Liu, Wei Li, Yinjian Wang, Ran Tao, Qian Du, and Jocelyn Chanussot. A survey on hyperspectral image restoration: From the view of low-rank tensor approximation. *Sci. China Inf. Sci.*, 66(4):140302, **2023**.
- [67] Jiangtao Peng, Weiwei Sun, Heng-Chao Li, Wei Li, Xiangchao Meng, Chiru Ge, and Qian Du. Low-rank and sparse representation for hyperspectral image processing: A review. *IEEE Geosci. Remote Sens. Mag.*, 10(1):10–43, **2022**.
- [68] Matteo Maggioni, Vladimir Katkovnik, Karen Egiazarian, and Alessandro Foi. Nonlocal transform-domain filter for volumetric data denoising and reconstruction. *IEEE Trans. Image Process.*, 22(1):119–133, **2013**.
- [69] Wei He, Quanming Yao, Chao Li, Naoto Yokoya, Qibin Zhao, Hongyan Zhang, and Liangpei Zhang. Non-local meets global: An iterative paradigm for hyperspectral image restoration. *IEEE Trans. Pattern Anal. Mach. Intell.*, 44(4):2089–2107, **2022**.
- [70] Lina Zhuang and José M Bioucas-Dias. Fast hyperspectral image denoising and inpainting based on low-rank and sparse representations. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 11(3):730–742, **2018**.
- [71] Lina Zhuang and Michael K Ng. Fasthymix: Fast and parameter-free hyperspectral image mixed noise removal. *IEEE Trans. Neural Netw. Learn. Syst.*, pages 1–15, **2021**.
- [72] Bin Zhao, Magnus O Ulfarsson, Johannes R Sveinsson, and Jocelyn Chanussot. Hyperspectral image denoising using spectral-spatial transform-based sparse and low-rank representations. *IEEE Trans. Geosci. Remote Sens.*, 60:1–25, **2022**.
- [73] Ying Tai, Jian Yang, Xiaoming Liu, and Chunyan Xu. Memnet: A persistent memory network for image restoration. In *IEEE ICCV*, pages 4539–4547. **2017**.

- [74] Oleksii Sidorov and Jon Yngve Hardeberg. Deep hyperspectral prior: Single-image denoising, inpainting, super-resolution. In *IEEE/CVF ICCVW*. **2019**.
- [75] Yu-Chun Miao, Xi-Le Zhao, Xiao Fu, Jian-Li Wang, and Yu-Bang Zheng. Hyperspectral denoising using unsupervised disentangled spatio-spectral deep priors. *IEEE Trans. Geosci. Remote Sens.*, 60:1–16, **2022**.
- [76] Xiaowan Hu, Yuanhao Cai, Jing Lin, Haoqian Wang, Xin Yuan, Yulun Zhang, Radu Timofte, and Luc Van Gool. Hdnet: High-resolution dual-domain learning for spectral compressive imaging. In *Proceedings of the IEEE/CVF CVPR*, pages 17542–17551. **2022**.
- [77] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. U-net: Convolutional networks for biomedical image segmentation. In *Proc. MICCAI*, pages 234–241. Springer, **2015**.
- [78] Hang Su, Varun Jampani, Deqing Sun, Orazio Gallo, Erik Learned-Miller, and Jan Kautz. Pixel-adaptive convolutional neural networks. In *Proc. of the IEEE CVPR*, pages 11166–11175. **2019**.
- [79] Zitong Zhang, Qiaoyu Ma, Heng Zhou, and Na Gong. Nested transformers for hyperspectral image classification. *Journal of Sensors*, 2022, **2022**.
- [80] Jiaqi Zou, Wei He, and Hongyan Zhang. Lessformer: Local-enhanced spectral-spatial transformer for hyperspectral image classification. *IEEE Trans. Geosci. Remote Sens.*, 60:1–16, **2022**.
- [81] Yuanhao Cai, Jing Lin, Xiaowan Hu, Haoqian Wang, Xin Yuan, Yulun Zhang, Radu Timofte, and Luc Van Gool. Mask-guided spectral-wise transformer for efficient hyperspectral image reconstruction. In *Proc. CVPR*, pages 17502–17511. **2022**.

- [82] Chengjun Wang, Miao Zhong Xu, Yonghua Jiang, and et al. Translution-snet: A semisupervised hyperspectral image stripe noise removal based on transformer and cnn. *IEEE Trans. Geosci. Remote Sens.*, 60:1–14, **2022**.
- [83] Fengfeng Wang, Jie Li, Qiangqiang Yuan, and Liangpei Zhang. Local–global feature-aware transformer based residual network for hyperspectral image denoising. *IEEE Trans. Geosci. Remote Sens.*, 60:1–19, **2022**.
- [84] Li Pang, Weizhen Gu, and Xiangyong Cao. Trq3dnet: A 3d quasi-recurrent and transformer based network for hyperspectral image denoising. *Remote Sensing*, 14(18):4598, **2022**.
- [85] Miaoyu Li, Ying Fu, and Yulun Zhang. Spatial-spectral transformer for hyperspectral image denoising. In *Proceedings of the AAAI Conference on Artificial Intelligence*, volume 37, pages 1368–1376. **2023**.
- [86] Zeqiang Lai and Ying Fu. Hybrid spectral denoising transformer with learnable query. *arXiv preprint arXiv:2303.09040*, **2023**.
- [87] Aditya Dixit, Anup Kumar Gupta, Puneet Gupta, Saurabh Srivastava, and Ankur Garg. Unfold: 3d u-net, 3d cnn and 3d transformer based hyperspectral image denoising. *IEEE Trans. Geosci. Remote Sens.*, **2023**.
- [88] Zeqiang Lai and Ying Fu. Mixed attention network for hyperspectral image denoising. *arXiv preprint arXiv:2301.11525*, **2023**.
- [89] Han V Nguyen, Magnus O Ulfarsson, and Johannes R Sveinsson. Hyperspectral image denoising using sure-based unsupervised convolutional neural networks. *IEEE Trans. Geosci. Remote Sens.*, 59(4):3369–3382, **2020**.
- [90] Magauiya Zhussip, Shakarim Soltanayev, and Se Young Chun. Extending stein’s unbiased risk estimator to train deep denoisers with correlated pairs of noisy images. *Advances in neural information processing systems*, 32, **2019**.

- [91] Wei-Hao Wu, Ting-Zhu Huang, Xi-Le Zhao, Jian-Li Wang, and Yu-Bang Zheng. Hyperspectral image denoising via tensor low-rank prior and unsupervised deep spatial–spectral prior. *IEEE Trans. Geosci. Remote Sens.*, 60:1–14, **2022**.
- [92] Qiang Zhang, Qiangqiang Yuan, Meiping Song, Haoyang Yu, and Liangpei Zhang. Cooperated spectral low-rankness prior and deep spatial prior for hsi unsupervised denoising. *IEEE Trans. on Image Process.*, 31:6356–6368, **2022**.
- [93] Zhongshun Jiang, Honglin Zhu, Yi Qiu, and Yuntao Qian. A self-supervised hyperspectral image restoration method based on convolutional sparse coding and superpixel segmentation. In *IEEE IGARSS*, pages 1760–1763. IEEE, **2022**.
- [94] L. Zhuang et al. Eigenimage2eigenimage (e2e): A self-supervised deep learning network for hyperspectral image denoising. *IEEE Trans. Neural Netw. Learn. Syst.*, **2023**.
- [95] Behnood Rasti, Paul Scheunders, Pedram Ghamisi, Giorgio Licciardi, and Jocelyn Chanussot. Noise reduction in hyperspectral imagery: Overview and application. *Remote Sensing*, 10(3):482, **2018**.
- [96] Marion F Baumgardner, Larry L Biehl, and David A Landgrebe. 220 band aviris hyperspectral image data set: June 12, 1992 indian pine test site 3. *Purdue University Research Repository*, 10:R7RX991C, **2015**.
- [97] Arvind Kumar Singh, HV Kumar, GR Kadambi, JK Kishore, J Shuttleworth, and J Manikandan. Quality metrics evaluation of hyperspectral images. *ISPRS Archives*, 8, **2014**.
- [98] Zhou Wang, Alan C Bovik, Hamid R Sheikh, and Eero P Simoncelli. Image quality assessment: from error visibility to structural similarity. *IEEE Trans. Image Process.*, 13(4):600–612, **2004**.

- [99] Roberta H Yuhas, Alexander FH Goetz, and Joe W Boardman. Discrimination among semi-arid landscape endmembers using the spectral angle mapper (sam) algorithm. In *JPL Aviris Workshop.*, volume 1, pages 147–149. **1992**.
- [100] Rick Archibald and George Fann. Feature selection and classification of hyperspectral images with support vector machines. *IEEE Geosci. Remote. Sens. Lett.*, 4(4):674–677, **2007**.
- [101] Yi Peng, Deyu Meng, Zongben Xu, Chenqiang Gao, Yi Yang, and Biao Zhang. Decomposable nonlocal tensor dictionary learning for multispectral image denoising. In *IEEE CVPR*, pages 2949–2956. **2014**.
- [102] Kaixuan Wei and Ying Fu. Low-rank bayesian tensor factorization for hyperspectral image denoising. *Neurocomputing*, 331:412 – 423, **2019**. ISSN 0925-2312.
- [103] Zeqiang Lai, Kaixuan Wei, and Ying Fu. Deep plug-and-play prior for hyperspectral image restoration. *Neurocomputing*, 481:281–293, **2022**.
- [104] Boaz Arad and Ohad Ben-Shahar. Sparse recovery of hyperspectral signal from natural rgb images. In *Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part VII 14*, pages 19–34. Springer, **2016**.
- [105] Qian Wang, Lifu Zhang, Qingxi Tong, and Feizhou Zhang. Hyperspectral imagery denoising based on oblique subspace projection. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 7(6):2468–2480, **2014**.
- [106] Y. Chen et al. Denoising hyperspectral image with non-iid noise structure. *IEEE Trans. Cybern.*, 48(3):1054–1066, **2017**.
- [107] W. He et al. Hyperspectral image denoising using local low-rank matrix recovery and global spatial–spectral total variation. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 11(3):713–729, **2018**.

- [108] L. Zhuang and J.M. Bioucas-Dias. Hyperspectral image denoising based on global and non-local low-rank factorizations. In *ICIP*, pages 1900–1904. **2017**.
- [109] Albert Gu and Tri Dao. Mamba: Linear-time sequence modeling with selective state spaces. *arXiv preprint arXiv:2312.00752*, **2023**.
- [110] Yue Liu, Yunjie Tian, Yuzhong Zhao, Hongtian Yu, Lingxi Xie, Yaowei Wang, Qixiang Ye, and Yunfan Liu. Vmamba: Visual state space model. *arXiv preprint arXiv:2401.10166*, **2024**.
- [111] Lianghui Zhu, Bencheng Liao, Qian Zhang, Xinlong Wang, Wenyu Liu, and Xinggang Wang. Vision mamba: Efficient visual representation learning with bidirectional state space model. *arXiv preprint arXiv:2401.09417*, **2024**.
- [112] Keli Deng, Peng Wang, and Yuntao Qian. Rgb images enhancing hyperspectral image denoising with diffusion model. In *ICASSP 2024-2024 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 2960–2964. IEEE, **2024**.
- [113] Lina Zhuang, Michael K Ng, Lianru Gao, and Zhicheng Wang. Eigen-cnn: Eigenimages plus eigennoise level maps guided network for hyperspectral image denoising. *IEEE Transactions on Geoscience and Remote Sensing*, **2024**.
- [114] Vibhuti Dabas, Garima Jaiswal, Mohit Agarwal, Ritu Rani, and Arun Sharma. Construction of hyperspectral images from rgb images via cnn. *Multimedia Tools and Applications*, pages 1–20, **2024**.