

**T.C.
ARTVİN ÇORUH ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI**

**DERİN ÖĞRENME TABANLI PAN-KESKİNLEŞTİRME YÖNTEMLERİNİN
ARAZİ ÖRTÜSÜ HARİTALAMA PERFORMANSLARININ İRDELENMESİ**

YÜKSEK LİSANS TEZİ

Deryanur AŞIKOĞLU

**Danışman
Doç. Dr. Volkan YILMAZ**

ARTVİN-2023

**T.C.
ARTVİN ÇORUH ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI**

**DERİN ÖĞRENME TABANLI PAN-KESKİNLEŞTİRME YÖNTEMLERİNİN
ARAZİ ÖRTÜSÜ HARİTALAMA PERFORMANSLARININ İRDELENMESİ**

YÜKSEK LİSANS TEZİ

Deryanur AŞIKOĞLU

**Danışman
Doç. Dr. Volkan YILMAZ**

ARTVİN-2023

TEZ BEYANNAMESİ

Artvin oruh niversitesi Lisansst Eėitim Enstitsne Yksek Lisans Tezi olarak sunduėum ‘‘Derin ėrenme Tabanlı Pan-Keskinleřtirme Yntemlerinin Arazi rts Haritalama Performanslarının İrdelenmesi’’ bařlıklı bu alıřmayı bařtan sona kadar danıřmanım Do. Dr. Volkan YILMAZ’ın sorumluluėunda tamamladıėımı, bařka kaynaklardan aldıėım bilgileri metinde ve kaynakada eksiksiz olarak gsterdiėimi, alıřma srecinde bilimsel arařtırma ve etik kurallara uygun olarak davrandıėımı taahht ederim. Aksinin ortaya ıkması durumunda her trl yasal sonucu kabul ettiėimi beyan ederim.

Lisansst Eėitim-ėretim ynetmeliėinin ilgili maddeleri uyarınca gereėinin yapılmasını arz ederim.

- ☐ Tezimin tamamı her yerden eriřime aılabilir.
- ☐ Tezim sadece Artvin oruh niversitesi yerleřkelerinden eriřime aılabilir.
- ☐ Tezimin ... ay sreyle eriřime aılmasını istemiyorum. Bu srenin sonunda uzatma iin bařvuruda bulunmadıėım takdirde, tezimin tamamı her yerden eriřime aılabilir.

...../...../20.....

Deryanur AŐIKOėLU

T.C.
ARTVİN ÇORUH ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

DERİN ÖĞRENME TABANLI PAN-KESKİNLEŞTİRME YÖNTEMLERİNİN
ARAZİ ÖRTÜSÜ HARİTALAMA PERFORMANSLARININ İRDELENMESİ

Deryanur AŞIKOĞLU

Tezin Enstitüye Verildiği Tarih : .../.../2023

Tezin Sözlü Savunma Tarih : .../.../2023

Tez Danışmanı :Doç. Dr.Volkan YILMAZ

Jüri Üyesi :Prof. Dr. Halil AKINCI

Jüri Üyesi :Dr. Öğr. Üyesi Ekrem SARALIOĞLU

ONAY:

Bu Yüksek Lisans Tezi, Artvin Çoruh Üniversitesi Lisansüstü Eğitim Enstitüsü Yönetim Kurulunca belirlenen yukarıdaki jüri üyeleri tarafından .../.../..... tarihinde uygun görülmüş ve Enstitü Yönetim Kurulu'nun .../.../..... tarih ve sayılı kararıyla kabul edilmiştir.

.../.../2023

.....

Enstitü Müdürü

ÖNSÖZ

“Derin Öğrenme Tabanlı Pan-Keskinleştirme Yöntemlerinin Arazi Örtüsü Haritalama Performanslarının İrdelenmesi” konusunda yapılan bu çalışma; Artvin Çoruh Üniversitesi Lisansüstü Eğitim Enstitüsü Harita Mühendisliği Anabilim Dalında yüksek lisans tezi olarak hazırlanmıştır.

Elde edilen verilerinin analiz edilmesinde ve tezin yazım aşamasında yardımlarını esirgemeyen hocam Doç. Dr. Volkan Yılmaz’a, çalışmalarında yardımlarını esirgemeyen arkadaşım Mert Gülakar’a ve manevi desteklerini her zaman hissettiğim aileme teşekkür ederim.

Araştırmanın bilimsel ve teknik açıdan uygulayıcılara faydalı olmasını dilerim.

Deryanur AŞIKOĞLU

Artvin - 2023

İÇİNDEKİLER

	<u>Sayfa No</u>
TEZ BEYANNAMESİ.....	I
JÜRİ KABUL TUTANAĞI.....	II
ÖNSÖZ.....	III
İÇİNDEKİLER	IV
ÖZET.....	VII
SUMMARY	VIII
TABLolar DİZİNİ	IX
ŞEKİLLER DİZİNİ	X
KISALTMALAR DİZİNİ	XII
1 GİRİŞ	1
1.1 Genel Bilgiler	1
1.2 Literatür Çalışması	3
1.3 Pan-Keskinleştirme	6
1.3.1 Pan-Keskinleştirmenin Tanımı	6
1.3.2 Pankromatik ve Çok Bantlı Görüntülerin Birleştirilmesi.....	7
1.3.3 Pan-Keskinleştirmede Dikkat Edilmesi Gereken Hususlar.....	8
1.4 Görüntü Sınıflandırma	9
1.5 Kontrollü Sınıflandırma	11
1.6 Derin Öğrenme.....	12
1.6.1 Derin Öğrenmenin Tanımı	12
1.6.2 Yapay Sinir Ağları	13
1.6.2.1 Yapay Sinir Ağları ve Genel Özellikleri.....	13
1.6.2.2 Tek Katmanlı Algılayıcılar	15
1.6.2.3 Çok Katmanlı Algılayıcılar	16
1.6.2.4 İleri Yönde Yayılım	17
1.6.2.5 Maliyet Fonksiyonu	17

1.6.2.6 Optimizasyon ve En İyileme	18
1.6.2.7 Geri Yönde Yayılım.....	19
1.6.2.8 Dropout-DropConnect	20
1.6.2.9 Aktivasyon Fonksiyonları	21
1.6.3 Derin Öğrenmede Kullanılan Kütüphaneler	22
1.6.4 Pan-Keskinleştirmede Derin Öğrenme	24
1.6.5 Evrişimsel Sinir Ağları.....	24
1.6.5.1 Evrişim Katmanı	26
1.6.5.2 Havuzlama Katmanı.....	26
1.6.5.3 Tam Bağlantılı Katman.....	27
2 METARYAL VE YÖNTEM.....	28
2.1 Kullanılan Görüntü Verileri	28
2.2 Pan-Keskinleştirme Yöntemleri	29
2.2.1 Bileşen Değişimi Tabanlı Yöntemler.....	29
2.2.1.1 Optimized Brovey Transform with Haze Correction.....	29
2.2.1.2 Gram Schmidt Yöntemleri	30
2.2.1.3 Partial Replacement Adaptive Component Substitution.....	30
2.2.1.4 Band-Dependent Spatial Detail Yöntemleri	31
2.2.2 Çoklu Çözünürlük Analizi Tabanlı Yöntemler	31
2.2.2.1 Additive Wavelet Luminance Proportional	32
2.2.2.2 Generalized Laplacian Pyramid with Modulation Transfer Function Matched Filter Yöntemleri	32
2.2.2.3 Nonlinear Decomposition Scheme Using Morphological Filtering Based on Half Gradient.....	33
2.2.3 Varyasyonel Yaklaşımlar	33
2.2.3.1 Total Variation	34
2.2.3.2 Sparse Representation of Injected Details	34
2.2.3.3 Principal Component Analysis/Wavelet Model-based Fusion	34

2.2.3.4 Filter Estimation Based on a Semiblind Deconvolution Framework and High-Pass Modulation Injection Model	35
2.3 Derin Öğrenme Tabanlı Pan-Keskinleştirme Yöntemleri.....	35
2.3.1 Pansharpening Neural Network	35
2.3.2 Deep Convolutional Neural Network Architecture for Pansharpening	38
2.3.2.1 RESNET Mimarisi	40
2.3.3 Multiscale and Multidepth Convolutional Neural Network.....	41
2.3.4 Pansharpening by Combining Machine Learning and Traditional Fusion Schemes	42
2.3.5 Deep Residual Pansharpening Neural Network.....	43
2.4 Pan-Keskinleştirmede Kalite Metrikleri	45
2.5 Destek Vektör Makineleri ile Sınıflandırma Yöntemi	46
2.6 Görüntü Sınıflandırma Doğruluk Analizi	49
3 BULGULAR VE SONUÇLAR.....	52
3.1 Pan-Keskinleştirilmiş Görüntülerin Nitel Değerlendirmesi.....	52
3.2 Pan-Keskinleştirilmiş Görüntülerin Nicel Değerlendirmesi	56
3.3 Pan-Keskinleştirme Yöntemlerinin İşlem Süreleri	59
3.4 Sınıflandırılmış Görüntülerin Değerlendirilmesi	60
4 TARTIŞMA VE SONUÇ.....	66
KAYNAKÇA	71
ÖZGEÇMİŞ.....	82

ÖZET

DERİN ÖĞRENME TABANLI PAN-KESKİNLEŞTİRME YÖNTEMLERİNİN ARAZİ ÖRTÜSÜ HARİTALAMA PERFORMANSLARININ İRDELENMESİ

Pan-keskinleştirme, yüksek çözünürlüklü pankromatik (PAN) görüntünün konumsal özelliklerini düşük çözünürlüklü çok bantlı (ÇB) görüntünün spektral özellikleriyle birleştirerek hem konumsal hem de spektral olarak geliştirilmiş birçok bantlı (ÇB) görüntü üretir. Kırk yılı aşkın bir süredir çok sayıda pan-keskinleştirme yöntemleri geliştirilmiş olup son yıllarda uzaktan algılama alanındaki diğer uygulamalarda olduğu gibi pan-keskinleştirme için de derin öğrenme (DÖ) tabanlı yaklaşımlar geliştirilmiştir. Bu sebeple, DÖ tabanlı yöntemlerin performanslarının incelenmesi ve çeşitli uzaktan algılama uygulamaları için uygulanabilirliklerinin ortaya koyulması gerekmektedir. Çok sayıda pan-keskinleştirme yönteminin önerilmiş olması araştırmacılar için en iyi sonucu veren yöntemi seçmeyi zorlaştırmaktadır. Bu nedenle, bu çalışmanın amacı, önceden eğitilmiş modellere dayanan birçok DÖ tabanlı pan-keskinleştirme yöntemlerinin ve geleneksel yöntemlerin görüntüdeki konumsal keskinliği artırma ve spektral renk doğruluğunu koruma yetenekleri açısından performanslarını değerlendirmek ve bu yöntemlerin başarılı görüntü sınıflandırma sonuçları elde etmek için yeterli olup olmadığını tespit etmektir. Bu amaçla toplam 29 pan-keskinleştirme yönteminden üretilen pan-keskinleştirilmiş görüntülerinin spektral ve konumsal özellikleri niteliksel ve niceliksel olarak değerlendirilerek sınıflandırma performansları incelenmiştir. Çalışma kapsamında IKONOS ve WORLDVIEW2 (WV2) uydularına ait verisetleri kullanılmıştır. Pan-keskinleştirme görüntüleri destek vektör makinesi (DVM) yöntemi ile sınıflandırılarak pan-keskinleştirmenin arazi örtüsü haritalama performansına etkileri irdelenmiştir. Varyasyonel (VY) yöntemler istisnalar hariç olmak üzere diğer yöntemlere göre daha başarılı sonuçlar elde etmiştir. DÖ tabanlı yöntemlerde de pan-keskinleştirme ve sınıflandırma doğruluklarının diğer birçok geleneksel yöntemden daha yüksek olduğu sonucuna varılmıştır. Ayrıca, DÖ tabanlı yöntemlerin performansının, büyük ölçüde eğitimin başarısına ve kullanılan hiperparametrelere bağlı olduğu ortaya koyulmuştur.

Anahtar Kelimeler: Uzaktan algılama, Pan-keskinleştirme, Görüntü sınıflandırma, Derin öğrenme, Yapay zekâ

SUMMARY

ANALYSIS OF LAND COVER MAPPING PERFORMANCE OF DEEP LEARNING BASED PAN-SHARPENING METHODS

Pansharpening enhances both spatial and spectral characteristics of a high-resolution panchromatic (PAN) image by fusing its spatial features with the spectral properties of a lower-resolution multispectral (MS) image, resulting in an improved MS image. Over the past forty years, numerous pansharpening methods have been developed, and in recent years, deep learning (DL) based approaches have emerged for pansharpening, similar to other applications in remote sensing. Therefore, it is important to examine the performance of DL-based methods and assess their applicability for various remote sensing applications. The proliferation of various pansharpening methods makes it challenging for researchers to select the best-performing technique. Hence, the objective of this study is to evaluate the performance of several DL-based pansharpening methods utilizing pre-trained models, along with traditional methods, in terms of enhancing spatial sharpness and preserving spectral color accuracy in images. A total of 29 pansharpening methods were employed to generate pansharpened images, and their spectral and spatial characteristics were qualitatively and quantitatively assessed to investigate classification performance. The study utilized datasets from IKONOS and WORLDVIEW2 (WV2) satellites. The pansharpened images were classified using the Support Vector Machine (SVM) algorithm to investigate the effects of pansharpening on the land cover mapping performance. The variational optimization (VO)-based techniques generally outperformed other methods, with a few exceptions. The DL-based methods were found to result in superior pansharpening and classification accuracy compared to many other traditional approaches. Additionally, it was revealed that the performance of DL-based methods is highly dependent on the success of training and the hyperparameters employed.

Keywords: Remote sensing, Pansharpening, Image classification, Deep learning, Artificial intelligence

TABLÖLAR DİZİNİ

Sayfa No

Tablo 1. Yapay sinir ağların temel avantajları ve dezavantajları (Yılmaz, 2020).....	15
Tablo 2. Görüntü verilerinin özellikleri.....	29
Tablo 3. Karşılaştırılan DÖ tabanlı yöntemler için eğitim sırasında kullanılan parametreler.....	45
Tablo 4. DVM için kullanılan kernel fonksiyonları (Çölkesen ve Kavzoğlu, 2008)..	49
Tablo 5. Pan-keskinleştirme kalite metrik değerleri.....	58
Tablo 6. Kullanılan pan-keskinleştirme yöntemlerinin ortalama işlem süreleri.....	60
Tablo 7. Görüntü sınıflandırma kalite metrik değerleri.....	65

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1. Pan-keskinleştirme (Akoğuz, 2013).....	7
Şekil 2. Örnek uydu görüntüsü (solda) ve sınıflandırılmış görüntü (sağda) (Güngör,2019).....	11
Şekil 3.Kontrollü sınıflandırma (Yılmaz, 2020).....	12
Şekil 4.Derin öğrenme, makine öğrenmesi ve yapay zekâ arasındaki ilişki (Yılmaz,2020).....	13
Şekil 5. Biyolojik sinir hücresi (Yılmaz, 2020).....	14
Şekil 6. Yapay sinir hücresi (Yılmaz, 2020).....	14
Şekil 7. Tek katmanlı yapay sinir ağı yapısı (URL-2; Murat, 2021).....	16
Şekil 8. Çok katmanlı yapay sinir ağı yapısı (Murat, 2021).....	17
Şekil 9. Gİ'nin gösterimi (Seyyarer ve ark., 2020; Murat, 2021).....	19
Şekil 10.(a) İleri beslemeli ağ, (b) Geri beslemeli ağ (Pekel ve Soner, 2017; Yıldırım, 2022).....	20
Şekil 11. Sol: Dropout, sağ: DropConnect (van Doorn, 2014; Ulu, 2016).....	21
Şekil 12. Aktivasyon fonksiyonları (Murat, 2021).....	22
Şekil 13. CNN'nin temel yapısı (CNN, 2019; Şimşek, 2019).....	25
Şekil 14. Evrişim işlemi (Ulu, 2016).....	26
Şekil 15. Maksimum havuzlama katmanı (Rana, 2020; Murat, 2021).....	27
Şekil 16. IKONOS uydu görüntüsü (sağda), WV2 uydu görüntüsü (solda).....	28
Şekil 17.PNN ve PNN-IDX (kesikli kutu dâhil) algoritmalarının üst düzey akış şeması. NI, ÇB'den çıkarılan normalleştirilmiş dizinlerin bir yığınıdır (Vivone ve ark., 2020).....	37
Şekil 18. A-PNN-FT üst düzey iş akışı (Vivone ve ark., 2020).....	38
Şekil 19. L2 kayıp fonksiyonunu kullanan PANNET'in akış şeması (Aiazzi ve ark, 2002; Deng ve ark, 2022).....	39
Şekil 20. RESNET artık modülü (He ve ark., 2016; Ülker ve ark., 2017).....	40
Şekil 21.MSResB'nin çok ölçekli artık blok olduğu L2 kayıp işlevini kullanan MSDCNN'nin akış şeması. Ayrıca, CNNd ve CNNs sırasıyla derin ve sık özellikleri temsil eder (Deng ve ark, 2022).....	42

Şekil 22.L2 kayıp fonksiyonundan yararlanan FUSIONNET'in akış şeması. P _D , spektral boyut boyunca P'nin kopyalanmış versiyonudur (Deng ve ark, 2022).....	43
Şekil 23. L2 kayıp işlevini kullanan DRPNN'nin akış şeması (Deng ve ark., 2022)	44
Şekil 24.(a) Doğrusal olarak ayrılabilen veri setleri için hiper-düzlemin belirlenmesi, (b) Doğrusal olarak ayrılamayan veri setleri için hiper-düzlemin belirlenmesi (Çölkesen ve Kavzoğlu, 2008).....	47
Şekil 25. Kernel fonksiyonu ile verinin daha yüksek bir boyuta dönüşümü (Çölkesen ve Kavzoğlu, 2008).....	48
Şekil 26. Yöntemlerin IKONOS uydusuna ait pan-keskinleştirilmiş görüntüleri.....	54
Şekil 27. Yöntemlerin WV2 uydusuna ait pan-keskinleştirilmiş görüntüleri.....	55
Şekil 28.IKONOS uydusuna ait görüntünün sınıfları (solda), WV2 uydusuna ait görüntünün sınıfları (sağda).....	62
Şekil 29. Yöntemlerin IKONOS uydusuna ait sınıflandırma görüntüleri.....	63
Şekil 30. Yöntemlerin WV2 uydusuna ait sınıflandırma görüntüleri.....	64

KISALTMALAR DİZİNİ

A-PNN	Advanced PNN
A-PNN-FT	Advanced PNN Using Fine-Tuning A-PNN
AWL	Additive Wavelet Luminance
AWLP	AWL Proportional
BD	Bileşen Değişimi
BDSD	Band-Dependent Spatial Detail
BDSD-PC	BDSD with Physical Constraints
BT	Brovey Dönüşümü
BT-H	Optimized Brovey Transform with Haze Correction
C-BDSD	Context-Adaptive BSD
C-GSA	Context-Adaptive GS
C-MTF-GLP-CBD	Context-based MTF-GLP-CBD
ÇB	Çok Bantlı
ÇÇA	Çoklu Çözünürlük Analizi
CNN	Evrişimsel Sinir Ağları
DÖ	Derin Öğrenme
DRPNN	Deep Residual Pansharpening Neural Network
DVM	Destek Vektör Makineleri
FE-HPM	Filter Estimation Based on a Semiblind Deconvolution Framework and HPM Injection Model
FUSIONNET	Pansharpening by Combining Machine Learning and Traditional Fusion Schemes
Gİ	Gradyan İniş
GPU	Grafik İşlem Birimi
GS	Gram Schmidt
GSA	GS Adaptive
GT	Ground Truth
HPM	High-Pass Modulation
MF	Nonlinear decomposition scheme using Morphological Filtering based on half gradient
MÖ	Makine Öğrenme

MSDCNN	Multiscale and Multidepth CNN mimarisi
MTF	Modulation Transfer Function
MTF-GLP	Generalized Laplacian Pyramid with MTF Matched Filter
MTF-GLP-HPM	MTF-GLP with High-Pass Modulation
MTF- GLP-HPM-H	GLP with MTF-matched Filter with HPM Injection Model and Haze Correction
MTF-GLP-HPM-R	Regression-Based MTF-GLP-HPM
MTF-GLP-CBD	GLP with MTF-matched Filter and Context-Based Decision Injection
MTF-GLP-FS	Full-Scale Regression-Based MTF-GLP
PAN	Pankromatik
PANNET	Deep CNN Architecture for Pansharpening
PCA	Principal Component Analysis
PNN	Pansharpening Neural Network
PNN-IDX	PNN Augmenting the Input by Including Several Maps of Nonlinear Radiometric Indexes
PRACS	Partial Replacement Adaptive CS
PWMBF	PCA/Wavelet Model-based Fusion
SGD	Olasılıksal Gradyan İnişi
SR-D	Sparse Representation of Injected Details
SRCNN	Süper Çözünürlüklü Evrişimli Sinir Ağı
RELU	Rektifiye Edilmiş Doğrusal Birimler
TV	Total Variation
VY	Varyasyonel Yaklaşımlar
WV2	WORLDVIEW2

1 GİRİŞ

1.1 Genel Bilgiler

Uzaktan algılama, havadan görüntü elde edilmesini sağlayan sistemler aracılığı veya yeryüzü gözlem uyduları ile yer yüzeyi hakkında fiziksel ve konumsal bilgiler veren verilerin elde edilmesini sağlayan bir alandır (Romero ve ark., 2016; Doğan ve Türkoğlu, 2019). Birçok uygulama için yer yüzeyinin konumsal dağılımı ve çeşitliliği ile ilgili doğru bilgilerin sağlanması önemlidir. Özellikle büyük alanların görüntülenmesi ve bu görüntülerin analizinde uydu görüntü teknolojileri doğru, ekonomik çözümler vermektedir. Algılayıcı tasarım ile uydu teknolojilerindeki teknolojik gelişmeler, doğal kaynakların yönetimini ve çevresel görüntülemeyi de barındıran pek çok yeni araştırma olanakları oluşturmuştur (Cheriyadat, 2014; Çölkesen, 2015; Doğan ve Türkoğlu, 2019). Uydu sistemlerinde bulunan görüntüleme teknolojileri teknolojinin gelişmesiyle birlikte yeryüzüne 0.5 metreden daha yakın düzeyde görüntülere ulaşarak daha yüksek çözünürlüklü uydu görüntüleri elde edilmesini sağlamaktadır (Lupia ve ark., 2017; Doğan ve Türkoğlu, 2019). Yeryüzü objelerinin niteliği, özellikleri ve dağılımları konusunda yeni nesil algılayıcı sistemler vasıtasıyla elde edilen görüntüler detaylı bilgiler sunmaktadır. Görüntülerin kalitesinin artması bu konuya olan ilgiyi arttırmış ve yeni araştırma alanlarına olanak sunmuştur. Yüksek çözünürlüklü uydu görüntüleri üzerinde ağaç ve bina gibi yüzey nesnelerinin görsel olarak tanınması kolaylaştırılarak nesnelerin birbirinden ayırt edilmesi sağlanmıştır (Dixit ve ark., 2017; Kaur ve Sachdeva, 2017; Doğan ve Türkoğlu, 2019).

Uzaktan algılanmış görüntülerin kalitelerinin değerlendirilebilmesi için birçok çözünürlükten bahsedilebilir: konumsal çözünürlük, spektral çözünürlük, radyometrik çözünürlük ve zamansal çözünürlük. Radyometrik çözünürlük, bir nesneden yansıyan ışığın (enerjinin) yoğunluğundaki çok küçük değişimleri algılayabilme yeteneği olarak bahsedilir. Zamansal çözünürlük, yeryüzünde bir alana ait ne kadar sıklıkta görüntü elde edildiğinin göstergesidir. Başka bir ifade ile bir alan ne kadar fazla sıklıkta görüntülenirse o bölgedeki değişimler çok daha doğru ve sağlıklı analiz edilir (Güngör, 2019). Konumsal çözünürlük, bir uydu görüntüsünde

görülebilien en küçük nesnenin boyutuyla ilişkilendirilir. Diğer bir ifadeyle, konumsal çözünürlük uydu görüntüsünün bir piksel alanının yeryüzündeki karşılığını temsil eder. Öte yandan spektral çözünürlük, yeryüzünden yansıyan elektromanyetik enerjinin kaydedildiği dalga boyu aralığının genişliğine bağlıdır. Elektromanyetik enerji ne kadar dar ve fazla sayıda dalga boyu aralığında depolanıyorsa spektral çözünürlüğün o kadar fazla olduğu anlamına gelmektedir (Yılmaz ve ark., 2021). Birçok uzaktan algılama uygulamasında kullanılan uydu görüntülerinden maksimum seviyede bilgi elde etmek için, bu görüntülerin hem yüksek spektral çözünürlüğe hem de yüksek konumsal çözünürlüğe sahip olması beklenmektedir. Ancak, bu tarz görüntülere ulaşmak her zaman mümkün olamayabilmektedir. Bu sebeple, yüksek spektral çözünürlüklü ÇB görüntüler ile yüksek konumsal çözünürlüklü PAN görüntüler birleştirilir. Bu amaçla kullanılan birçok görüntü birleştirme yöntemi önerilmiştir. Bu birleştirme işleminde, PAN görüntünün konumsal detayları ÇB görüntüyü keskinleştirmek için kullanılır, bu işleme de “pan-keskinleştirme (pansharpening)” denir. Bu uygulamalar bütününde ÇB görüntünün spektral bilgisi korunmaya çalışılırken konumsal çözünürlük artırılır (Pradhan, 2005; Kaplan, 2008). Günümüze kadar literatürde birçok pan-keskinleştirme yöntemi geliştirilmiştir. Bu yöntemlerin çok sayıda olması farklı kategoriler altında sınıflandırılmasını sağlamıştır. Çoklu çözünürlük analizi tabanlı (ÇÇA), bileşen değişimi tabanlı (BD), modülasyon tabanlı ve hibrit yöntemler olmak üzere örnekler verilebilir.

Son yıllarda pan-keskinleştirme için farklı modern yöntemler geliştirilmektedir. DÖ yöntemleri bu modern yöntemlerden biridir. DÖ yöntemlerinin günümüzde çeşitli çalışmalardaki başarıları bu yöntemlerin pan-keskinleştirme alanında kullanımını beraberinde getirmiştir (Yılmaz ve ark., 2021). Gelişen teknoloji sayesinde, makine öğrenmesinin bir alt kolu olan DÖ kavramı bilgisayarlarda artan işlem gücü ve işlemcilerindeki ilerlemelerle yaygın olarak kullanılmaya başlanılmıştır. DÖ algoritmalarında, girdi ve etiketli veriler arasındaki karmaşık ilişkilerle başa çıkmak için derin ağ mimarileri kullanılmaktadır (Kussul ve ark., 2017; Yılmaz, 2020). DÖ algoritmaları, sinir ağlarını içeren ve çeşitli katmanları olan mimari yapılardır. DÖ mimarisindeki bu katmanlar arttıkça derinlik kavramı ortaya çıkmıştır. Uzaktan algılamada DÖ tabanlı yaklaşımlar pan-keskinleştirme, görüntü sınıflandırma,

görüntü ön işleminde, obje tespiti, arazi kullanımı ve arazi örtüsü haritası üretme, görüntü segmentasyonu, obje tabanlı görüntü analizi ve doğruluk analizi gibi birçok uygulama alanında kullanılmaktadır (Ma ve ark., 2019; Yılmaz, 2020).

1.2 Literatür Çalışması

Uzaktan algılama alanında pan-keskinleştirme uygulamaları için birçok yöntem geliştirilmiştir. Çalışmada kullanılan pan-keskinleştirme yöntemleri, BD tabanlı yöntemler, ÇÇA tabanlı yöntemler, VY tabanlı yöntemler ve DÖ tabanlı yöntemler olmak üzere 4 kategoriye ayrılmaktadır.

BD yaklaşımları konumsal bilgileri ayırmak ve onu PAN görüntüsüyle değiştirmek için kaynak ÇB görüntüsünü dönüştürülmüş bir uzaya yansıtma prensibine dayanmaktadır. Bunlardan; Brovey dönüşümünün farklı bir versiyonu olan Optimized Brovey Transform with Haze Correction (BT-H) (Lolli ve ark., 2017) yöntemi, Gram-Schmidt dönüşümü uygulanarak pan-keskinleştirilmiş görüntü üreten Gram-Schmidt (GS) (Laben ve ark., 2000) yöntemi, uyarlanabilir versiyonuyla GS Adaptive (GSA) (Aiazzi ve ark., 2007) yöntemi ve gelişmiş versiyonuyla Context-Adaptive GS (C-GSA) (Restaino ve ark., 2017) yöntemleri geliştirilirken PAN ve ÇB bantları arasındaki farkı minimize etmek için bazı katsayılar hesaplayan Partial Replacement Adaptive CS (PRACS) (Choi ve ark., 2011) yöntemi, karesel ortalama hatayı kullanarak pan-keskinleştirme işlemini gerçekleştiren Band-Dependent Spatial Detail (BDSD) (Garzelli ve ark., 2008) yöntemi, uyarlanabilir versiyonuyla Context-Adaptive BSD (C-BSD) (Garzelli, 2015) yöntemi, bazı fiziksel kısıtlamalar uygulayarak detay görüntüleri elde eden BSD with Physical Constraints (BSD-PC) (Vivone, 2019) yöntemleri literatüre geçmiştir.

ÇÇA yöntemleri, konumsal bileşenlerini çıkarmak için PAN görüntüsüne çok ölçekli bir ayrıştırma dönüşümü uygulayarak pan-keskinleştirilmiş görüntüyü elde etmeyi amaçlar. Literatürde araştırılan yöntemler arasında; yüksek çözünürlük detaylarını ÇB görüntüsünün parlaklık bileşenine ekleyen Additive Wavelet Luminance (AWL) (Nunez ve ark., 1999) yöntemi, bu yöntemin gelişmiş versiyonu olan AWL Proportional (AWLP) (Otazu ve ark., 2005) yöntemi, ayrıştırma aşamasında kendine özel filtre kullanan Nonlinear decomposition scheme using Morphological

Filtering Based on Half Gradient (MF) (Restaino ve ark, 2016) yöntemi, Modulation Transfer Function (MTF) filtresi kullanarak indirgenen PAN görüntüyü girdi PAN görüntüden çıkartarak konumsal bilgi elde eden Generalized Laplacian Pyramid with MTF Matched Filter (MTF-GLP) (Aiazzi ve ark., 2006) yöntemi ve bunların gelişmiş versiyonları olan MTF-GLP with High-Pass Modulation (MTF-GLP-HPM) (Vivone ve ark, 2014) yöntemi, GLP with MTF-matched Filter and Context-Based Decision Injection (MTF-GLP-CBD) (Alparone ve ark., 2007) yöntemi, Context-based MTF-GLP-CBD (C-MTF-GLP-CBD) (Restaino ve ark., 2017) yöntemi, GLP with MTF-matched Filter with HPM Injection Model and Haze Correction (MTF-GLP-HPM-H) (Lolli ve ark., 2017) yöntemi, Full-Scale Regression-Based MTF-GLP (MTF-GLP-FS) (Vivone ve ark., 2018) yöntemi ve Regression-Based MTF-GLP-HPM (MTF-GLP-HPM-R) (Vivone ve ark., 2018) yöntemleridir.

VY tabanlı yöntemler ise optimizasyon modellerinin çözümleriyle ilgilenir. Konumsal bilgilerin korunmasında önemli bir rol oynayan Total Variation (TV) (Palsson ve ark., 2014) yöntemi, kaynak ÇB görüntü verilerinde eksik ayrıntıları hesaplamayı amaç edinen Sparse Representation of Injected Details (SR-D) (Vicinanza ve ark., 2015) yöntemi, dalgacık tabanlı bayes füzyon yönteminin bir uzantısı olan PCA/Wavelet Model-based Fusion (PWMBF) (Zhang ve ark., 2009) yöntemi, ÇB ve PAN görüntüsü arasındaki bulanıklığı modelleyen filtreyi tahmin etmek için yalnızca mevcut görüntüleri kullanarak ve hiçbir ek bilgi içermeyen Filter Estimation Based on a Semiblind Deconvolution Framework and HPM Injection Model (FE-HPM) (Vivone ve ark., 2014) yöntemleri VO tabanlı yöntemler arasında literatüre geçmiştir.

Birçok görüntü işleme görevinde olduğu gibi, DÖ tabanlı yöntemler görüntü sentezlemedeki başarılarından sonra pan-keskinleştirme için de kullanılmaktadır. Pan-keskinleştirme görevi için Evrişimsel Sinir Ağlarının (CNN) eğitim sürecinde Wald protokolü (Wald ve ark., 1997) kullanılmaktadır. Tam çözünürlüklü pan-keskinleştirme işleminde referans görüntüler bulunmadığından eğitim için azaltılmış çözünürlük ayarı (setting) kullanılır (Özçelik, 2020). (Masi ve ark., 2016)'da derin evrişimli sinir ağları kullanarak süper çözünürlük modeline dayanan üç katmanlı bir CNN modeli önermiştir (Özçelik, 2020). CNN tabanlı ilk süper çözünürlük çalışması olarak ise araştırmacılar üç katmanlı bir evrişimsel sinir ağı kullanarak Süper

Çözünürlüklü Evrişimli Sinir Ağı (SRCNN) olarak adlandırılan bir süper çözünürlük modelini yeniden yapılandırmışlardır. Mimari içindeki evrişimli sinir ağları için aktivasyon fonksiyonu olarak Rektifiye Edilmiş Doğrusal Birimler (RELU) kullanılmıştır (Dong ve ark., 2016; Sertel ve ark., 2021). (Yang ve ark., 2017)'de doğrudan görüntüyü kullanmak yerine yüksek geçişli (high-pass) filtreleme kullanırken, yapısal ve spektral özellikleri geliştirmek için alana özgü bilgileri kullanan Deep CNN Architecture for Pansharpening (PANNET) yöntemini önermiştir (Özçelik, 2020). (Wei ve ark., 2017)'de diğer yöntemlerin yanında derin artık öğrenmeyi kullanarak evrişimli bir sinir ağ olan Deep Residual Pansharpening Neural Network (DRPNN) tasarlamışlardır ve DRPNN yönteminin diğer yöntemlerle arasındaki nicel sonuçlarını değerlendirmişlerdir. (Scarpa ve ark., 2018)'de çıkarım aşamasından önce hedef görüntü üzerinde ince ayar yapan önceden eğitilmiş bir model kullanmışlardır. (Masi ve ark., 2016) tarafından önerilen doğal görüntüler için süper çözünürlüklü ağdan ilham alan Pansharpening Neural Network (PNN) yöntemi, bazı indekslerin yardımcı girdi olarak kullanılması sonucu oluşan PNN augmenting the input by including several maps of nonlinear radiometric indexes (PNN-IDX) yöntemini önermişlerdir. Bu önerilere bağlı olarak (Scarpa ve ark., 2018) tarafından PNN yönteminin bir başka versiyonu olarak uyarlanan Advanced PNN (A-PNN) yöntemini ve ince ayar yapılarak oluşturulan Advanced PNN Using Fine-Tuning A-PNN (A-PNN-FT) yöntemlerini geliştirmişlerdir. (Vivone ve ark., 2020)'de bu 4 DÖ tabanlı yöntemleri diğer yöntemlerle karşılaştırmıştır. (Yuan ve ark., 2018)'de pan-keskinleştirme için Multiscale and Multidepth CNN (MSDCNN) adı verilen çok ölçekli ve çok derinlikli bir CNN tabanlı bir mimari önermiştir. (Deng ve ark., 2020)'de, pan-keskinleştirme işlemini ele almak için makine öğrenme (MÖ) teknikleri ile diğer yöntemlerin (CS ve MRA) birleşiminden faydalanan Pansharpening by Combining Machine Learning and Traditional Fusion Schemes (FUSIONNET) yöntemini önermişlerdir. (Özçelik, 2020)'de basit mimariye sahip olan CNN'nin kısıtlı kapasitelerinden kaynaklanan pan-keskinleştirme hatalarını azaltmak için Çekişmeli Üretici Ağ (Generative Adversarial Networks - GAN) mimarisini önermiştir. (Deng ve ark., 2022)'de birçok MÖ yaklaşımını uygulamada kullanarak hem azaltılmış çözünürlükte hem de yüksek çözünürlükte görüntülere pan-keskinleştirme yöntemlerini uygulamıştır ve DÖ tabanlı yöntemlerin başarılı sonuçlarıyla karşılaşmıştır. (Yılmaz ve ark., 2021) tarafından QUICKBIRD,

IKONOS, WV2 uydularına ait PAN ve ÇB görüntülerinin birleştirilmesi için klasik pan-keskinleştirme yöntemleri ile DÖ tabanlı pan-keskinleştirme yöntemlerini uygulamış, elde edilen sonuçlar görsel ve istatistiksel açıdan karşılaştırılmıştır. (Sertel ve ark., 2021)’de diğer yöntemler ile DÖ tabanlı modellerden elde edilen pan-keskinleştirme sonuçlarının performansını ve görsel kalitesini değerlendirmek için ayrıntılı bir karşılaştırmalı analiz yaparak yöntemlerin kararlılığını değerlendirmek için farklı arazi örtüsü özelliklerine sahip bölgeler üzerinde analizler gerçekleştirmiştir.


1.3 Pan-Keskinleştirme

1.3.1 Pan-Keskinleştirmenin Tanımı

Çeşitli kaynaklardan toplanmış bilgilerin ve verilerin kullanılması sonucunda geliştirilmiş/iyileştirilmiş bilgiye ulaşmayı sağlayan işleme veri birleştirme işlemi denir. (Pohl ve ark., 1998)’de, bu genel kavram üzerinden görüntü birleştirmenin tanımını “Görüntü birleştirme, iki veya daha fazla farklı görüntünün belirli bir algoritma kullanılarak yeni bir görüntü oluşturmak üzere bir araya gelmesinden oluşan kombinasyonudur” olarak tanımlandırmıştır. Bu tanımlama sonucunda uzaktan algılamada pan-keskinleştirme, yüksek konumsal çözünürlüklü PAN görüntülerini kullanarak, ÇB görüntülerinin konumsal çözünürlüğünün iyileştirilmesi konusuyla ilgilenmektedir. Bundan dolayı şekil 1’de gösterildiği gibi pan-keskinleştirme, yüksek konumsal çözünürlüklü görüntüdeki konumsal detayların çıkarılarak, bu detayların konumsal çözünürlüğü düşük olan görüntüye eklenmesi şeklinde modellenabilir (Akoğuz, 2013).

Pan-keskinleştirme işlemi dört önemli aşamadan oluşmaktadır (Akoğuz, 2013):

1. ÇB görüntüsünün PAN görüntüye eşçakıştırılması(co-registration)
2. ÇB görüntüsünün ölçeğinin artırılması
3. PAN görüntüsünden konumsal ayrıntıların çıkartılması
4. Çıkarılan konumsal ayrıntıların ÇB görüntüsüne eklenmesi



Şekil 1. Pan-keskinleştirme (Akoğuz, 2013).

1.3.2 Pankromatik ve Çok Bantlı Görüntülerin Birleştirilmesi

Görüntü birleştirme modelinde, PAN görüntüsünden alınmış konumsal bilgiler ile ölçeği PAN boyutunda ölçeklenmiş ÇB görüntüsü bir ağırlık katsayısı ile çarpılarak, sonucunda birleştirilmiş ÇB görüntüsü oluşturulur (Akoğuz, 2013).

$$\hat{M} = \tilde{M} + w\tilde{P} \quad (1.1)$$

Bu denklem'de $\hat{M}$, pan-keskinleştirilmiş ÇB görüntüsünü; $\tilde{M}$, ölçeği büyütülmüş ÇB görüntüsünü; $\tilde{P}$, PAN görüntüden elde edilen konumsal detayları; w , ölçeklenmiş ÇB görüntüsüne eklenecek olan detay miktarını kontrol eden ağırlık katsayısını göstermektedir (Akoğuz, 2013).

Yukarıda gösterilmiş olan bu formül, birçok pan-keskinleştirme yönteminde kullanılmakta olup son yıllarda geliştirilmeye çalışılan karmaşık pan-keskinleştirme modellerine tamamen uymamaktadır. Buna bağlı olarak pan-keskinleştirme yöntemlerinin bu kadar fazla olması aralarında kategorilere ayrılma ihtiyacı oluşturmuştur. Pan-keskinleştirme algoritmalarının anlaşılması için yöntemlerin kategorilere ayrılması önemlidir (Collet ve ark., 2009; Akoğuz, 2013). Uzaktan

algılama topluluğunun pan-keskinleştirme yöntemleri için genel olarak kabul ettiği kategoriler şu şekildedir (Akoğuz, 2013):

1. BD tabanlı yöntemler
2. ÇÇA tabanlı yöntemler
3. Modülasyon tabanlı yöntemler
4. Hibrit yöntemler

1.3.3 Pan-Keskinleştirmede Dikkat Edilmesi Gereken Hususlar

Pan-keskinleştirme yöntemleri gerçekleştirilirken uygulamanın başarısını etkileyen birçok sebep ortaya çıkabilmektedir. İlk olarak çalışmalarda kullanılan PAN ve ÇB görüntülerinin konumsal çözünürlükleri arasında fark ne kadar fazla olursa pan-keskinleştirme işlemi o derece zor olmaktadır (Yılmaz ve Gungor, 2016; Serifoglu Yılmaz ve ark., 2020). Üstelik kullanılan PAN ve ÇB görüntüleri aynı sensör tarafından üretilip üretilmediği de pan-keskinleştirmenin başarısına doğrudan etki eden hususlardan biridir. Farklı sensörlerden alınan görüntüler elektromanyetik spektrumun farklı aralıklarına duyarlı olmaları nedeniyle bu görüntüler birleştirildiğinde renk bozulmalarına sebebiyet verecektir (Serifoglu Yılmaz ve ark., 2020). Bir diğer husus ise ÇB ve PAN görüntülerinin projeksiyon bilgilerinin yani koordinat sistemlerinin aynı olmasıdır. Eğer bu görüntüler farklı projeksiyon bilgilerine sahipse pan-keskinleştirme sonucunda oluşan görüntüdeki konumsal detaylarda kayıklıklar meydana gelecektir. Dikkat edilmesi gereken bir diğer faktörde, kullanılan PAN ve ÇB görüntülerinin çekim tarihlerinin birbirine yakın olması yüksek pan-keskinleştirme başarısı sağlamaktadır. Çekim tarihleri arasındaki fark fazla ise bir görüntüdeki konumsal detaylar diğer görüntüde olmayacağı için pan-keskinleştirilmiş görüntüde yapay renkler oluşarak spektral bozulma meydana gelecektir (Pohl ve ark., 1998; Serifoglu Yılmaz ve ark., 2020). Ayrıca uygulamada kullanılacak olan görüntülerde çeşitli radyometrik ya da atmosferik bozulmalar varsa bunların uygulamadan önce giderilmesi pan-keskinleştirme performansını olumlu yönde etkileyecektir. Bunların dışında pan-keskinleştirme başarısını etkileyen faktörlerden biri de kullanıcının tecrübesidir. Kullanıcı pan-keskinleştirme yöntemleri hakkında ne kadar bilgiye sahip olursa bu yöntemlerin avantajları ve

dezavantajlarına göre hangi durumlarda hangi yöntemlerin kullanması gerektiğini bilebilir ve bu da pan-keskinleştirme performansını maksimum düzeye ulaştırabilmektedir (Serifoglu Yilmaz ve ark., 2020).

Pan-keskinleştirme yöntemleri farklı çalışmalarda farklı performanslar sergileyebilmektedir. Pan-keskinleştirme yöntemlerinin farklı çalışmalarda farklı performans göstermesinin birkaç nedeni vardır. İlk olarak, görüntü alanlarının özellikleri kullanılan pan-keskinleştirme yönteminin performansını doğrudan etkilemektedir. Bir pan-keskinleştirme yönteminin görüntülerdeki farklı renk frekanslarına sahip arazi örtüsü ve arazi örtüsü üzerindeki nesnelerin farklı performans göstermesi yöntemin sonucu için önemlidir (Yilmaz ve ark., 2021). İkinci olarak, kaynak görüntülerin özellikleri pan-keskinleştirme performansında önemli bir rol oynamaktadır. Bir pan-keskinleştirme yönteminin tek sensörlü ve çok sensörlü kaynak görüntülerde farklı performans göstermesi beklenir. Bir diğeri ise pan-keskinleştirme yöntemi sonucunun kalitesini değerlendirmek için kullanılan farklı nicel ölçütler farklı yargılara yol açabilir. Kalite ölçütlerinin kendilerine has avantajları ve dezavantajları olduğundan, bir kalite ölçütü bir pan-keskinleştirme sonucunu başarılı olarak gösterebilirken, aynı sonuç başka bir kalite ölçütü tarafından düşük kaliteli olarak değerlendirebilir. Pan-keskinleştirilmiş görüntülerin kalitesini %100 başarı ile ölçebilecek standart bir kalite metriği bulunmadığından, farklı çalışmalarda farklı kalite metrikleri kullanılmakta, bu da farklı pan-keskinleştirme sonuçları hakkında farklı yargılara varılmasına neden olabilmektedir (Yilmaz ve ark., 2021).

1.4 Görüntü Sınıflandırma

Görüntü sınıflandırma, uzaktan algılama uygulamaları arasında en çok kullanılan uygulamalardan birisidir. Uzaktan algılanmış görüntülerin sınıflandırılması ile birlikte yeryüzündeki nesneler ile ilgili detaylı bilgiler elde edilebilir. Görüntü sınıflandırmadaki amaç görüntü üzerindeki her bir pikselin renk değerlerine göre bir renge atanarak tematik görüntüler elde edilmesidir (Güngör, 2019). Başka bir deyişle, görüntüdeki her pikselin arazide ilgili olduğu özellik sınıfına atanmasıdır. Bu işlemde görüntüye ait pikseller ve bu piksellerin gri değerleri ile yapılan istatistiksel hesaplamalar esas alınır. Bu gri değerlere bağlı olarak, çeşitli sınıflandırma


yöntemleri kullanılarak piksel sınıfları belirlenir (Ayhan ve ark., 2003; Yılmaz, 2012).

Görüntü sınıflandırmada soruna yaklaşım ve çözüm, başlangıçta mevcut olan veri ve bilgilerin türüne ve miktarına bağlıdır. Sınıflandırma için hangi bant kombinasyonlarının kullanılacağını belirlemek, çalışma alanındaki ÇB veri alanlarının korelasyonunun incelenmesini gerektirir. Bunu yapmak için bir korelasyon matrisi oluşturularak korelasyon katsayılarına bakılmalı ve sınıflandırma için minimum korelasyona sahip bandın kullanılması gerekmektedir. Korelasyon matrisi, farklı değişkenler ve özellikler arasındaki ilişkiyi ölçen bir matris olup korelasyon katsayısı da bu ilişkiyi nicel olarak ifade eden bir değerdir. Bu değer genellikle -1 ile 1 arasında değişmektedir (Ayhan ve ark., 2003; Yılmaz, 2012).

Görüntü sınıflandırma uygulaması genel itibariyle aşağıda gösterilen adımlardan oluşmaktadır (Kansu, 2006; Yılmaz, 2012);

1. İlk olarak sınıflandırma projesi tasarlanır. Sınıflandırma uygulamasında kullanılacak olan sınıfların kaç adet olması gerektiğine ve bu sınıfların ne olduğuna karar verilir. Bu sınıflar yeşil alanlar, yol, su, bina veya kent alanları olabilir ve bu sınıflar projeye bağlı olarak çeşitlendirilebilir. Tabi en başta yapılması gereken, sınıflandırma uygulamasında kullanılacak olan verileri elde etmektir.
2. Arazide bulunan her bir sınıfı temsil edecek şekilde imzalar (signature) toplanır ya da yazılımlarda kümeleme yapılır. İmzalar toplanırsa, seçilen imzanın tanımlanan sınıfla eşleşmesi gerekir. Gereğinden fazla imza kullanılmamasına dikkat edilmelidir.
3. Sınıflandırmada kullanılan çeşitli yöntemler içinden projeye en uygun algoritma tercih edilerek sınıflandırma işlemi yapılır.
4. Sınıflandırma işleminden sonra ihtiyaca bağlı olarak, sonuç görüntüsüne geometrik düzeltme yapılarak görüntüye koordinat eklenir.
5. Sonuç olarak sınıflandırma işleminin doğruluk analizleri (accuracy assessment) yapılır ve sınıflandırma sonuçları arazi ile karşılaştırılarak sınıflandırma doğruluğu değerlendirilir.

Görüntü sınıflandırma birçok uygulama alanlarında kullanılmaktadır. Bunlar arasında kent planlarının üretimi, deniz veya akarsu kirliliği tespiti, arazi örtüsü veya arazi kullanım haritalarının üretimi, kaçak yapıların tespiti, hastalık teşhisi, görüntülerden detay çıkarımı, görüntülerde değişim analizi vb. gibi örnekler verilebilir (Güngör, 2019). Şekil 2’ de örnek bir WV2 uydu görüntüsü ve görüntünün sınıflandırılması ile elde edilmiş tematik görüntü gösterilmiştir (Güngör, 2019).




Şekil 2. Örnek uydu görüntüsü (solda) ve sınıflandırılmış görüntü (sağda) (Güngör, 2019).

Literatürde çok sayıda görüntü sınıflandırma algoritması geliştirilmiştir. Sınıflandırma algoritmaları genellikle iki başlık altında toplanır. Bunlar kontrolsüz (unsupervised) ve kontrollü (supervised) görüntü sınıflandırma şeklindedir (Liu ve ark., 2009; Güngör, 2019). Bu tez kapsamında kontrollü sınıflandırma yaklaşımlarından faydalanılmıştır.

1.5 Kontrollü Sınıflandırma

Kontrollü sınıflandırma kullanıcının kontrolünde ve görüntü verilerine dayalı olarak gerçekleştirilir. Bu veriler birçok şekilde elde edilebilir; hava fotoğrafları analiz edilerek, arazi çalışmaları yapılarak ya da sınıflandırma yapılacak konu ile ilgili mevcut haritalardan ulaşılabilmektedir (Mather, 1987; Çölkesen, 2009). Kontrollü sınıflandırmada görüntünün kaç sınıfa ayrılacağı ve bu sınıfların ne olacağı önceden belirlenir (URL-1; Çölkesen, 2009). Kontrollü sınıflandırma, piksel değerlerini içeren bir özellik dosyası oluşturmak için çalışma alanındaki yeryüzü özelliklerini tanımlayan yeteri sayıdaki örnekleme alanlarını kullanır. Kontrol alanı tarafından örneklenen özellik dosyası görüntü verilerine uygulanarak hesaplanan olasılık

değerine göre her piksel benzer sınıflara atanır (Çölkesen, 2009). Literatürde kullanılan birçok kontrollü sınıflandırma yöntemleri vardır. Destek Vektör Makineleri (DVM), Mahalanobis Mesafesi, En Yakın Mesafe, Paralelkenar, Maksimum Benzerlik ve Yapay Sinir Ağları bunlardan bazılarıdır (Güngör, 2019). Kontrollü sınıflandırma şekil 3'te gösterilmektedir (Yılmaz, 2020).



Şekil 3. Kontrollü sınıflandırma (Yılmaz, 2020).

1.6 Derin Öğrenme

1.6.1 Derin Öğrenmenin Tanımı

DÖ, MÖ'nün bir alt kümesi olmakla beraber makine öğrenmesi de yapay zekânın bir alt kümesidir (Şekil 4). MÖ istenen bir problem için kural setlerini kullanarak çözüme ulaşmaktadır. Yani verilen verilere ve kurallara göre işlem yapar. DÖ ise bir problem için verilen modellere göre örnekleri değerlendirerek probleme çözüm getirmesini sağlar. Geleneksel MÖ ile DÖ metodlarını ayıran en temel özellik, insan yardımı olmadan ses, görüntü veya metin veri setlerinden otomatik bir şekilde temsillerini öğrenebilmesidir. Bu sayede karmaşık yapay zekâ problemlerini çözmede DÖ mimarisi büyük imkân sağlamaktadır. DÖ mimarileri ham verilerden özellik öğrenmenin yanında, veri sayısı arttıkça öngörme doğruluğu da artmaktadır. Bilgisayarların Graphics Processing Unit (GPU) donanımlarının hızının artması derin öğrenme konusunun bu kadar yaygın kullanılmasının başlıca sebebidir (Yılmaz,

2020). DÖ, verileri işlerken ve karar vermede kullanılmak üzere kalıplar oluştururken çalışan insan beynini taklit etmektedir. DÖ, üç veya daha fazla katmana sahip bir sinir ağından oluşmaktadır. Ek gizli katmanlara sahip sinir ağlarının kullanılması, yaklaşık tahminler yapabilen bir katmanlı sinir ağlarına kıyasla doğruluk açısından daha iyi sonuçlar vermektedir. DÖ, üzerinde çalışmak için büyük miktarda veriye ihtiyaç duyar ve ayrıca karmaşık yapısı nedeniyle bu verileri işlemek için çok güçlü donanımlara ihtiyaç duymaktadır (Mutlu, 2022). Kısacası DÖ'nün amacı insan beynine benzer bir yapı modelleyerek karar verme ve öğrenme işlemlerini en yüksek doğrulukla gerçekleştirebilmektir (Deng ve ark., 2014; Ünlü, 2019).




Şekil 4. Derin öğrenme, makine öğrenmesi ve yapay zekâ arasındaki ilişki (Yılmaz, 2020).

1.6.2 Yapay Sinir Ağları

1.6.2.1 Yapay Sinir Ağları ve Genel Özellikleri


Biyolojik öğrenme mekanizmalarını simüle ederek oluşturulan yapay sinir ağları, popüler bir MÖ tekniğidir. Bu sistemler, uyum sağlayabilen ve öğrenebilen karmaşık ağları oluşturur. Nöron olarak adlandırılan hücreler insan sinir sistemini oluşturur. Bu nöronlar birbirine aksonlar ve dendritlerle bağlıdır ve bu bağlantı bölgelerine sinaps adı verilir. Biyolojik nöronlarda girdi dendritler, çıktı ise aksonlar tarafından sağlanır (Şekil 5) (Yılmaz, 2020). Sinaptik bağlantıların gücü genellikle dış uyaranlara bağlı olarak değişmektedir. Canlı organizmalarda öğrenmenin nasıl gerçekleştiğini bu değişim göstermektedir (Aggarwal, 2018; Yılmaz, 2020). Hesaplama birimleri ağırlıklar aracılığıyla birbirine bağlıdır. Ağırlıklar, biyolojik

sinir ağlarında sinaptik bağlantıların gücü ile aynı rolü oynar. (Yılmaz, 2020).



Şekil 5. Biyolojik sinir hücresi (Yılmaz, 2020).

Bir sinir ağındaki nöronlar için her girdi, o birim üzerinde hesaplanan işlevi etkileyen bir ağırlıkla ölçeklenir (Şekil 6) (Yılmaz, 2020). Yapay sinir ağları; girdi katmanını, gizli katmanlar ve çıktı katmanlarından oluşmaktadır (Buduma, 2016; Yılmaz, 2020). Gizli katmanın iki önemli özelliği vardır. İlk olarak, gizli katmanlar yalnızca diğer gizli katmanlardan veya giriş katmanlarından veri alır. İkincisi, gizli katmanlar yalnızca çıktı katmanına veya diğer gizli katmanlara veri sağlar. Gizli katmanlar, sinir ağının girdiyi anlamasına yardımcı olur ve çıktı oluştururlar. Bilim insanları, sinir ağ kalıplarını öğrenmelerinde yardımcı olmak için yanlılık (bias) eklerler (Mukhopadhyay ve Mukhopadhyay, 2018; Yılmaz, 2020).



Şekil 6. Yapay sinir hücresi (Yılmaz, 2020).

Yapay sinir ağları birçok temel özelliğe sahiptir. Bu nedenle, tahmin amaçlı birçok karmaşık uygulamada ve veri analizinin birçok alanında kullanılır. Bu özelliklerden bazıları şunlardır: Uygulanabilirlik, doğrusal olmama, genelleştirilebilirlik, fazla

miktarda deęişken ve parametre kullanabilmesi, öğrenebilmesidir (Öztürk ve Şahin, 2018; Yılmaz, 2020). Yapay sinir aęları lineer fonksiyonlar içermedięinden birçok alanda kullanılabilir. Dolayısıyla yapay sinir aęlarının bu uygulamaların gerçekleştirilme sürecinde birçok avantajı ve dezavantajı bulunmaktadır (Yazıcı ve ark., 2007; Yılmaz, 2020). Bunlar modelin analizi için bilinmesi gereken ve modeli etkileyen önemli faktörlerdir. Bu faktörler tablo 1’de gösterilmektedir (Mijwel, 2018; Yılmaz, 2020).

Tablo 1. Yapay sinir aęların temel avantajları ve dezavantajları (Yılmaz, 2020).


Avantajlar	Dezavantajlar
Daha önce görmedięi örneklem hakkında bilgi üretebilir	Modelin eğitim süresinin bilinmemesidir
Bilgiler oluşturulan aęda saklanabilir	Girdi verisinin sinir aęının anlayacaęı bir şekilde düzenlenmesi gerekir
Kendi kendine öğrenebilir	Model üretilirken belirli kurallar yoktur
Hataları tolere edebilir	Güçlü donanım gerektirir
Paralel işlem yapabilme kapasitesine sahiptir	-
Sinir aęı genelleştirilebilir	-

1.6.2.2 Tek Katmanlı Algılayıcılar

Giriş katmanı, hesaplama katmanı ve çıkış katmanı, tek katmanlı bir sinir aęı yapısını oluşturur. Bu yapıda girdi deęerleri belirlenen ağırlıklarla çarpılır, genel bir toplama işlemi yapılır ve çıktı katmanına gönderilir. Yapay sinir aęının oluşturduęu matematiksel işlem formülü Denklem 1.2’de verilmiştir. Bu denklemde w ile gösterilen ağırlık deęerleri ile x olarak gösterilen girdi özniteliklerine çarpma işlemi uygulanır ve hesaplanan deęer denklemde b ile ifade edilen yanlılık (bias) deęeri ile toplanır. Aktivasyon fonksiyonu ile sonuç işlendikten sonra elde edilen deęer sıfırdan büyük ise 1, deęil ise 0 sonucunu üretir (Murat, 2021).

$$f(x) = \begin{cases} 1, & w \cdot x + b > 0 \text{ ise} \\ 0, & \text{değilse} \end{cases} \quad (1.2)$$

Şekil 7’de tek katmanlı bir yapay sinir ağı gösterilmektedir. Denklem 1.2’de gösterilen formüle uygun olarak $x_1, x_2, \dots, x_m$ şeklinde gösterilen her girdi değeri $w_1, w_2, \dots, w_m$ şeklinde ifade edilen ağırlık değerleriyle işleme tabi tutulmakta ve bir çıktı değeri üretmektedir (Murat, 2021).




Şekil 7. Tek katmanlı yapay sinir ağı yapısı (URL-2; Murat, 2021).

1.6.2.3 Çok Katmanlı Algılayıcılar

Tek katmanlı yapay sinir ağları geliştirilerek daha karmaşık ve derin ağ problemlerini çözmek için çok katmanlı algılayıcılar geliştirilmiştir. Bunlar, girdi ve çıktı katmanları arasında gizli katmanlara sahip sinir ağlarıdır. Gizli katmanlardaki nöronlarının görevi, giriş değerleri yani öznitelikler ile ağırlık değerleri çarpılarak elde edilen formülleri aktivasyon fonksiyonuna tabi tutarak sonraki katman için girdi değeri olarak oluşmasını sağlamaktır. Çok katmanlı yapay sinir ağlarının yapısı şekil 8’de (Murat, 2021) gösterilmiştir. Birden çok katman kullanılarak daha derin ağlar oluşturulur ve tek katmanlı yapay sinir ağlarında gerçekleştirilen işlem adımları arttırılır. Giriş katmanındaki her girdi değeri, ilk gizli katmandaki tüm nöronlar tarafından işlenir. Çok katmanlı bir sinir ağında ne kadar çok gizli katman varsa, bu işlem o kadar sık tekrarlanır. Giriş değerlerine uygun olarak çıktı katmanında çıktı

değerleri üretilir (Murat, 2021).



Şekil 8. Çok katmanlı yapay sinir ağı yapısı (Murat, 2021).

1.6.2.4 İleri Yönde Yayılım

İleri beslemeli bir yapay sinir ağında nöronlar çoğunlukla katmanlar halinde gruplandırılır ve bilgiler, giriş katmanından çıkış katmanına tek yönlü bağlantılar yoluyla iletilmektedir. Yani, ağın geriye doğru döngüsü olmayan tek yönlü bağlantıları vardır. Bu yapıyla ileri beslemeli ağlar statik bir işlevi yerine getirir (Alaloul ve Qureshi, 2020; Yıldırım, 2022). Nöronlar bir katmandan bir sonraki katmana bağlantı kurarken, aynı katman içinde bağlantıları yoktur. Bu ağda, bir katmandan elde edilen çıktılar bir sonraki katmana girdi olarak verilir. Giriş katmanında herhangi bir bilgi işleme yoktur ve bilgi gizli katmana iletilir. Gizli katmandaki nöronlar, bağlantı ağırlıklarının etkisiyle giriş katmanındaki nöronlardan gelen bilgileri alır ve işlenmiş halde çıkış katmanına gönderir. Benzer şekilde çıktı katmanında da bilgiler işlenerek ağın çıktısı belirlenir (Şekil 10 (a)) (Pekel ve Soner, 2017; Yıldırım, 2022) (Yıldırım, 2022).


1.6.2.5 Maliyet Fonksiyonu

Eğitim sürecinin temel amacı, eğitim veri kümesindeki gerçek değer ile modelin öngördüğü değer arasındaki farkı en aza indiren bir dizi parametre bulmaktır. Kayıp fonksiyonları, belirli bir sinir ağının eğitimi sonucunda bulunan değerlerin gerçek

değere ne kadar yakın olduğunu ölçer. Çıktının gerçek verilerden sapmasını belirlemek için bir kayıp fonksiyonu kullanılır. Hataların daha sonra tüm veri kümesi boyunca ortalaması alınır, toplanır ve sinir ağının idealine ne kadar yakın olduğunu gösteren tek bir sayı elde edilir. Kayıp fonksiyonları, sinir ağlarının eğitimi bir optimizasyon problemi olarak yeniden şekillendirmesine yardımcı olur (Patterson ve Gibson, 2017; Erdem, 2023). Bu çalışmada L1 ve L2 kayıp fonksiyonu kullanılmıştır. Mutlak hata kaybı olarak bilinen L1, tahmin ile gerçek arasındaki mutlak farkı temsil eder. L2 ise tahmin ile gerçek arasındaki kare farkıdır ve kare hata kaybı olarak adlandırılır (URL-7).

1.6.2.6 Optimizasyon ve En İyileme

Eğitim sırasında olası hataları en aza indirmek için optimizasyon ve en iyileme yöntemi adı verilen bir gradyan iniş (gradient descent-Gİ) yöntemi kullanır. Optimizasyon süreci, öğrenme hızıyla birlikte adım adım ilerleyen bir süreçtir (Seyyarer ve ark., 2020; Murat, 2021). İleri yayılım aşaması sırasında ağırlık parametresi seçim yöntemlerinden biri rastgele ağırlık değeri seçme yöntemidir. Bu seçilen değerin kayıp fonksiyonunda oluşturulan sonuca göre zincirleme türev yolu ile güncellenmesi beklenmektedir. Ağırlık değerlerinin belirlenmesinin ilk adımı, Gİ algoritmasının ilk adımını temsil eder. Şekil 9'da rastgele belirlenmiş ilk ağırlık değerleri sonrası geri yayılım sonucunda maliyet fonksiyonuna göre belirlenen ağırlık değerinin güncellenmesini ve negatif yönde azalan bir Gİ'yi göstermektedir. Gİ'nin amacı en uygun ağırlık değerini bularak minimum eğim noktasına ulaşmaktır. Normal bir Gİ algoritmasında her adımda minimum noktasına biraz daha yaklaşılması beklenmektedir (URL-3; Murat, 2021). Gİ algoritması maliyet işlevini hesaplamak için eğitim veri kümesindeki tüm örnekleri kullanır. Eğitim seti ne kadar büyük olursa, algoritma ağırlıkları o kadar yavaş günceller ve eğitim o kadar uzun sürer. Bu maliyetten kaçınmak için, veri kümesindeki tüm örnekler yerine belirli sayıda örnek kullanan olasılıksal eğim inişi (stochastic gradient descent-SGD) algoritması önerilmiştir (Raschka, 2022; Murat, 2021).




Şekil 9. Gİ'nin gösterimi (Seyyarer ve ark., 2020; Murat, 2021).

SGD (America ve Nj, 2010; Özdemir ve ark., 2021) algoritması, Gİ algoritmasının bir çeşididir. Düşük öğrenme hızlarında, normal Gİ ile aynı gücü üretir. Hata tahminlerini azaltmak için sık sık parametre değerlerinde küçük ayarlamalar yapar. Bu yöntem, bütün veri yerine parçalı eğitim veri grupları üzerinde gradyanı hesaplayan ve parametre değerlerini güncelleyen Gİ'nin olasılıksal bir versiyonu olarak düşünülebilir. Gİ, büyük veri kümeleri için uygun değildir ve yavaştır. Çünkü tahminler her yinelemede tüm eğitim verileri için hesaplanır. SGD'nin başlıca avantajları verimlilik ve uygulama kolaylığıdır. Bir diğer yöntem ise olasılıksal hedef fonksiyonlarının optimize edilmesi sürecinde birinci dereceden gradyan kullanan Adam algoritması (Kingma ve Ba, 2015; Özdemir ve ark., 2021), düşük dereceli ve uyarlanabilir tahminlere dayalı olarak sunulmuştur. Bu yöntemin uygulanması kolaydır ve hesaplama açısından verimlidir. Bellek gereksinimleri çok düşüktür. Gradyanların diyagonal olarak yeniden ölçeklendirilmesiyle değişmez. Veri veya parametre içeren büyük ölçekli problemler için çok uygundur (Özdemir ve ark., 2021).

1.6.2.7 Geri Yönde Yayılım

İleri beslemeli ağların aksine, geri beslemeli ağlarda bilgi hem ileriye hem de geriye doğru iletilmektedir. Yani iki yönlü bir bilgi akışı söz konusudur. Bu özelliği ile bu ağlar ileri beslemeli ağlardan farklı olarak dinamik bir hafıza yapısına sahiptir. Geri yönde yayılımı, çıktı katmanındaki veya gizli katmanlardaki nöronların çıktıları, girdi katmanına, önceki gizli katmanlara, kendi katmanındaki herhangi bir nörona veya nöronun kendisine girdi olarak verilebilir (Şekil 10 (b)) (Pekel ve Soner, 2017;


Yıldırım, 2022). Yani, bu ağlarda belirli bir andaki çıktılar, mevcut girdi değerlerinin yanı sıra önceki girdi ve çıktı değerlerini de yansıtır (Pham ve ark., 2007; Yıldırım, 2022). Bu yapısından dolayı geri beslemeli ağlar doğrusal olmayan bir yapıya sahiptir. Bu ağlara geri besleme özelliği kazandıran bağlantıların türüne göre farklı davranış ve yapıda geri beslemeli ağlar elde edilebilmektedir. Geriye doğru hesaplama mantığında ağın ürettiği çıkış değeri, ağın beklenen çıkışları ile karşılaştırılır ve aradaki fark belirlenir. Bu fark bir hata olarak kabul edilmektedir. Hatanın ağın ağırlık değerlerine dağıtılması ile bir sonraki iterasyonda hatanın azaltılması hedeflenmektedir (Yıldırım, 2022).



Şekil 10. (a) İleri beslemeli ağ, (b) Geri beslemeli ağ (Pekel ve Soner, 2017; Yıldırım, 2022).

1.6.2.8 Dropout-DropConnect

Makine öğrenimi tabanlı uygulamalarda, en yaygın görevlerden biri eğitim verilerine bir model uydurmaktır. Bu görev önemlidir, çünkü tahmin mekanizmamızın başarı oranı büyük ölçüde bu süreçle ilgilidir. Ancak, model aşırı karmaşıksa veya probleme uygun değilse, aşırı uyum (overfitting) ortaya çıkabilir. Aşırı uyum sağlayan bir modelin tahmin performansı genellikle düşük olacaktır. Ayrıca, model eğitim verilerini öğrenmek yerine ezberlemeye başlarsa, aşırı uyum kaçınılmazdır (Ulu, 2016).



Şekil 11. Sol: Dropout, sağ: DropConnect (van Doorn, 2014; Ulu, 2016).

Dropout, aşırı uyumu önlemek için kullanılan yöntemlerden biridir. Her eğitim durumu için nöronların bir kısmının rastgele çıkarılmasıyla çalışır. Böylece, eğitim aşamasında bu işlemle ağ boyutu azaltılır. Bu, nöronları daha uyarlanabilir ve sinir ağının mevcut mimarisiyle daha az kısıtlı hale getirir. Ağlarda bu işlemi kullanmak bize daha genel sonuçlar verir. DropConnect de dropout'a benzer bir işlevsellik sağlar: özellik dedektörlerinin yarısını rastgele çıkarmak yerine ağırlıkları rastgele çıkarır. Ağırlıklar sıfıra ayarlanarak atlanır (Ulu, 2016).


Şekil 11'de, şeklin sol tarafı dropout prosedürünü temsil etmektedir. Kırmızı noktalı daire ile gösterilen rastgele seçilmiş nöron atlanır. Şeklin sağ tarafında ise dropconnect fonksiyonu görülmektedir. Bu kez, rastgele seçilen ağırlıklar işlenir. Bunlar aşırı uyumu önlemek için çok önemli işlevlerdir (Ulu, 2016).

1.6.2.9 Aktivasyon Fonksiyonları

Yapay sinir ağının gerçekleştirdiği işlemler sonucunda elde edilen değerlerin anlamlı bir aralıkta olması gerekmektedir. Literatürde, giriş değerleri ile çarpılan ağırlık değerleri genellikle başlangıçta rastgele değerler olarak belirlenir. İleri ve geri yayılım, sistem için hangi nöronların daha önemli olduğunu belirlemek için ağırlık değerlerini günceller. Ancak bu matematiksel işlemin anlamlı olabilmesi için belirli bir aralıkta olması gerekir. Yani çıktı olarak gereksiz yere büyük veya çok küçük değerler kullanmak hatalı sonuçlar doğuracaktır. Dolayısıyla aktivasyon fonksiyonu bu değerleri belirli bir aralıkta tutar. (Murat, 2021).

Bir yapay sinir ağının aktivasyon fonksiyonunun asıl görevi, elde edilen çıkış değerlerinin lineer olmasını engellemektir. Burada kullanılmış olan sinir ağı yapısına

göre oluşturulmuş çıktı değerleri sadece sınıflandırma yapmak için değil daha derin yapılar içeren doğrusal olmayan değerler üretecektir (Murat, 2021). Şekil 12’de koordinat sistemi üzerinde aktivasyon fonksiyonlarının aralıklarını göstermektedir (Murat, 2021).



Şekil 12. Aktivasyon fonksiyonları (Murat, 2021).

1.6.3 Derin Öğrenmede Kullanılan Kütüphaneler

Yazılımcılar tarafından üretilmiş içerisinde önceden hazırlanmış kütüphaneleri barındıran ve onları değiştirmeye veya geliştirmeye izin veren yapılara kütüphane (framework) denir. DÖ’de birçok kütüphane kullanılmaktadır. Böylece benzer işleri yapmak için oluşturulan yapılar bir kütüphane içine gömülü hale getirilir. Başka bir kullanıcı tarafından bu kütüphane kullanılarak yapı çekilir ve yapılacak çalışmalar için kullanılabilir. Kullanılan amaca ve yazılım diline göre kütüphaneler çeşitlendirilebilir. DÖ’de kullanılan kütüphaneler uygulama kalitesine veya destekledikleri algoritmaya göre farklılık gösterebilir. Literatürde birçok DÖ kütüphanesi bulunmaktadır. Bunlar CNTK, Caffe, TensorFlow, Theano ve PyTorch’dur ve bunların her biri farklı performans ve özelliklere sahiptir. Bu kütüphaneler, DÖ algoritmalarının uygulanmasını optimize etmek için çeşitli teknikler kullanır (Shatnawi ve ark., 2018; Yılmaz, 2020). DÖ kütüphaneleri, Google, Facebook ve Microsoft gibi dünya çapındaki şirketler tarafından

geliştirilmiştir (Nguyen ve ark., 2020; Yılmaz, 2020). Derin öğrenmede kullanılan kütüphaneler aşağıda sıralanmıştır.

1. TensorFlow, Google Brain Team tarafından oluşturulan tüm sayısal hesaplamalar için tek bir veri akışı kullanan açık kaynaklı bir kitaplıktır. TensorFlow, esnek mimarisi ile birçok sinir ağı modelinde kullanılmaktadır. Kütüphane Python, C++ ve Java gibi programlama dillerini kullanır (URL-4; Yılmaz, 2020).
2. PyTorch, GPU hızlandırmalı bir DÖ kitaplığıdır. Facebook AI tarafından 2016 yılında geliştirilmiştir. PyTorch, Python, C ve CUDA'da yazılmıştır. Bu kitaplık, karmaşık DÖ modelleri oluşturmayı kolaylaştırır. Bu kütüphane ücretsiz olarak sağlanmaktadır. Twitter, Facebook, NVIDIA ve bunun gibi çoğu kuruluş tarafından desteklenir (Nguyen ve ark., 2020; Yılmaz, 2020).
3. Keras, Python'da geliştirilmiş açık kaynak koddur. TensorFlow, CNTK veya Theano üzerinde çalışabilen üst düzey bir yapay sinir ağlarının programlama ara yüzüdür. Kısa bir sürede gecikme yaşamadan araştırma yapmak için kullanılır. Tekrarlayan ve evrimsel sinir ağları üzerinde çalışmaktadır (URL-5; Yılmaz, 2020).
4. Caffe, BAIR (Berkeley Artificial Intelligence Research) tarafından oluşturulmuş bir DÖ kitaplığıdır. DÖ modelleri Caffe'de katman katman tanımlanır. Her bir katman modelin özü ve temel hesaplama birimi olarak kabul edilir. Bu katmanlar verinin normalizasyonunu sağlar. Bu katmanların özelleştirilmesi Python'da az desteklense de C++ CUDA'da yeni katmanlar yazılabilir (Nguyen ve ark., 2020; Yılmaz, 2020).
5. CNTK (Microsoft Cognitive Toolkit) Microsoft Research tarafından geliştirilen açık kaynaklı bir DÖ kütüphanesidir. Evrimsel, tekrarlayan sinir ağı gibi birçok sinir ağının eğitiminde ve çoklu GPU ve sunucular içinde kullanılmaktadır. CNTK, gradyan iniş ve geriye hata yayma prensibi ile çalışmaktadır. Ayrıca bu kütüphane, Python, C# ve C++ programlama dilinde kullanılmaktadır (URL-6; Yılmaz, 2020).
6. Theano, Montreal Üniversitesi'nde geliştirilen bir kütüphanedir. Theano, çok boyutlu dizileri içeren matematiksel ifadeleri (Numpy kitaplığını kullanarak)

tanımlamak, optimize etmek ve değerlendirmek için kullanılabilen bir Python kitaplığıdır. Bu kitaplık, C++ makine öğrenimi dilini kullanır (Shatnawi ve ark., 2018; Yılmaz, 2020).


1.6.4 Pan-Keskinleştirmede Derin Öğrenme

Uydu görüntüleri çok sayıda karmaşık veri içerebilmektedir ve bu verileri uygulamalarda kullanmak için DÖ yöntemleri yaygın olarak kullanılmaktadır (Zhang ve ark., 2016; Yılmaz, 2020). Uydu görüntüleri için pan-keskinleştirme işlemi önemlidir ve bu da DÖ tabanlı pan-keskinleştirme yöntemlerini önemli kılmaktadır. Pan-keskinleştirme için kullanılan DÖ yöntemlerinde, derin sinir ağları aracılığıyla girdi görüntü parçalarının hiyerarşik özelliklerinden yararlanılarak pan-keskinleştirme gerçekleştirilmektedir (Xing ve ark., 2018). Bu amaç doğrultusunda, DÖ yöntemlerinden faydalanan ilk yaklaşım pan-keskinleştirme problemini bir Süper Çözünürlük (Super Resolution) problemi olarak ele almış ve pan-keskinleştirmeyi gerçekleştirmek için basit bir üç katmanlı CNN mimarisi kullanmıştır (Masi ve ark., 2016; Yılmaz ve ark., 2021). (Masi ve ark., 2016) tarafından geliştirilen DÖ tabanlı pan-keskinleştirme yöntemi ilk aşama olarak girdi ÇB görüntünün çözünürlüğünü girdi PAN görüntünün çözünürlüğüne çıkartır. Çözünürlüğü arttırılan bantlar girdi PAN görüntü ile birleştirilir. Bu birleştirilmiş görüntü evrimsel sinir ağının girdi katmanını oluşturmaktadır. Ağ önceden belirlenen iterasyon sayısındaki eğitim süreci boyunca evrişim süzgecinin (filtre) ve kurulan modelin parametrelerini öğrenmeye çalışmaktadır. Ağın eğitimi (Wald ve ark., 1997) tarafından önerilen protokole göre gerçekleştirilir. Bu protokole göre pan-keskinleştirilmiş görüntünün çözünürlüğü girdi ÇB görüntünün çözünürlüğüne kötüleştirildiğinde elde edilen görüntü, girdi ÇB görüntü ile aynı olmalıdır (Yılmaz ve ark., 2021).

1.6.5 Evrimsel Sinir Ağları

CNN, yapay sinir ağları içerisinde en yaygın kullanılan ve önemli yapılardan biridir. Bir CNN, temel olarak geleneksel bir sinir ağı gibi çalışır. CNN'deki yapay bir nöron, girdi verilerini alır, ağırlıklar ile vektörel çarpımları yapar ve bunu doğrusal olmayan bir aktivasyon fonksiyonu aracılığıyla bir sonraki katmana gönderir. Son katmanda da tıpkı klasik yapay sinir ağlarındaki gibi çıktı verisi için bir tahmin

yapılır. CNN'leri klasik modellerden ayıran en büyük fark ana katmanlarının tam bağı katman yerine evrişimsel katman olmasıdır. Evrişim işlemi doğası gereği verideki detayların ayırt edilmesini sağladığından CNN'lerdeki kullanımları ile önemli başarılar elde edilmiştir. CNN mimarilerinde genellikle ilk katmanlarda evrişim katmanları, son katmanlarda tam bağı katmanlar bulunur. Bunun sebebi, birinci katmanın evrişim işlemi ile öznitelik çıkarımı yapması, son katmanın ise verileri sınıflandırmaya uygun bir boyuta getirmesidir (Severoğlu, 2021). Şekil 13'te CNN'nin temel yapısı gösterilmektedir (CNN, 2019; Şimşek, 2019).




Şekil 13. CNN'nin temel yapısı (CNN, 2019; Şimşek, 2019).

CNN'lerin özellikle iki boyutlu görüntü verileri üzerindeki başarısı birçok kez kanıtlanmıştır. İlk kez (LeCun ve ark., 1998)'de 5 katmanlı bir CNN kullanarak el yazısı ile yazılmış rakamları doğru sınıflandırmaya çalışmıştır. Daha sonra IMAGENET yarışmasında (Krizhevsky ve ark., 2017)'de ALEXNET adını verdikleri 8 katmanlı bir CNN modeli geliştirmiştir. ALEXNET, IMAGENET veri kümesi üzerindeki performansı ile en yakın rakibinden %10 daha az hatayla sınıflandırma tahminleri yapmıştır. ALEXNET'in bu başarısı dikkatleri CNN'ler üzerinde toplamıştır. Bir sonraki yıl yine IMAGENET yarışması için (Zeiler ve ark., 2014)'de ZFNET adını verdikleri modelde ALEXNET'in hiperparametrelerini değiştirip evrişimsel katmanları genişleterek sonuçları iyileştirmiştir (Severoğlu, 2021). ALEXNET'te her filtrenin ne tür öznitelikler öğrendiği, ZFNET'te ise her katmandan sonra oluşan öznitelik haritaları görselleştirilerek CNN'lerin öznitelikleri

bulmadaki başarısına vurgu yapılmıştır. Daha sonraki yıllarda GOOGLNET (Szegedy ve ark., 2015; Severoğlu, 2021), VGGNET (Simonyan ve ark., 2014; Severoğlu, 2021) ve RESNET (He ve ark., 2016; Severoğlu, 2021) mimarileri ile daha derin CNN mimarilerinin daha çok özneteliği öğrendiği ve daha başarılı olduğu gösterilmiştir (Severoğlu, 2021).

1.6.5.1 Evrişim Katmanı

Evrişim katmanı, CNN'in ana katmanıdır. Bu katman bir dizi öğrenilebilir filtreden (kernel) oluşur. Her filtre, ileri geçiş sırasında evrişim işleminden sorumludur. Bu işlemden sonra, evrişim katmanı boyutuna ve boyutlarına bağlı olarak çeşitli özellik haritaları üretir. Bu haritalar katmanda saklanır ve kendi filtresine aittir. Ağ, girdideki bazı konumsal konularda belirli bir tür özellik gördüğünde filtreleri otomatik olarak öğrenir. Giriş görüntüsünün sol üst köşesinden başlayarak filtreyi sırayla uygulamak, bir evrişim işlemi oluşturur. (Murat, 2021). Şekil 14'te, evrişim katmanının blokları sorumlu bölgeleri ile iç(skaler) çarpımı yapmaya hazırdır. Her filtre giriş verisi ile konvolüsyonlanır ve farklı özellik haritaları Şekil 14'te gösterildiği gibi üretilir (Ulu, 2016).




Şekil 14. Evrişim işlemi (Ulu, 2016).

1.6.5.2 Havuzlama Katmanı

Havuzlama, CNN'lerin bir diğer önemli kavramıdır. CNN'lerde bir tür boyut azaltma tekniğidir. Amacı, gereksiz bilgileri atmak ve yalnızca en kritik bilgileri korumaktır. Bu şekilde, aşırı öğrenmeyi de kontrol edebilir. Genel olarak, bu katman ardışık evrişimsel katmanlar arasına periyodik olarak yerleştirilir. Temel olarak, maksimum havuzlama ve ortalama havuzlama olarak adlandırılan iki tür havuzlama işlevi vardır

(Ulu, 2016).



Şekil 15. Maksimum havuzlama katmanı (Rana, 2020; Murat, 2021).

Maksimum havuzlama işlemi giriş verilerini alır ve şekil 15'te gösterildiği gibi maksimum değeri döndürür. Genel olarak, havuzlama katmanları 2x2 gibi küçük boyutlu filtrelerle sahiptir. Maksimum havuzlamadan farklı olarak, ortalama havuzlama giriş verilerinin ortalama değerini döndürür. Bu katmanları ağda kullanmanın bazı dezavantajları vardır. Ortalama havuzlama açısından, negatif ve düşük değerler nedeniyle aktivasyon değerini en aza indirebilir. Öte yandan, maksimum havuzlama kullanıldığında, bu katmandaki yararlı ve ayırt edici bilgiler kaybedilebilir. Çünkü düşük değerleri göz ardı eder ve bu da veri kümesine oldukça hızlı bir şekilde aşırı uyuma neden olabilir (Van Doorn, 2014; Ulu 2016).


1.6.5.3 Tam Bağlantılı Katman

Tam bağlantılı katman, evrişimli sinir ağındaki son katmandır. Tam bağlantılı katmanların işlevi CNN'yi ileri yönde beslemektir. Tam bağlantılı katman kendisinden önceki evrişim, aktivasyon ve havuzlama katmanlarının çıktısını alır ve bu çıktıyı bir vektör olacak şekilde düzleştirir. Bu düzleştirilmiş vektör, sinir ağı hesaplama mantığıyla aynı şekilde ağırlık ve yanlılık (bias) değerleri kullanılarak matematiksel olarak hesaplanır (Arunava, 2018; Murat, 2021).

2 METARYAL VE YÖNTEM

2.1 Kullanılan Görüntü Verileri

Çalışma, Trabzon iline ait iki farklı bölge üzerinde gerçekleştirilmiştir. Şehir merkezinde yer alan ilk bölge 2003 yılında IKONOS uydusu tarafından görüntülenmiştir. İlk bölgedeki görüntü 4 m çözünürlüklü ÇB görüntüsü ile 1 m çözünürlüklü PAN görüntüsüne sahiptir. IKONOS uydusunun ÇB görüntüsü dört banttan oluşmaktadır. Trabzon'un Sürmene ilçesinde yer alan ikinci bölge ise 2012 yılında WV2 uydusu tarafından görüntülenmiştir. İkinci bölgede 2 m çözünürlüklü ÇB görüntüsü ile 50 cm çözünürlüklü PAN görüntüsü elde edilmiştir. WV2 uydusunun ÇB görüntüsü sekiz banttan oluşmaktadır. Çalışmada kullanılan tüm görüntüler 11 bit radyometrik çözünürlüğe sahiptir. Şekil 16'da uygulamada kullanılan görüntüler gösterilmektedir. Kullanılan uydu görüntülerinin boyutları tablo 2'de verilmiştir.



Şekil 16. IKONOS uydu görüntüsü (sağda), WV2 uydu görüntüsü (solda).

Tablo 2. Görüntü verilerinin özellikleri.

Sensör	Giriş boyutu		Çıkış boyutu
	MS	PAN	HRMS
WV2	96×96×8	384×384	384×384×8
IKONOS	96×96×4	384×384	384×384×4

2.2 Pan-Keskinleştirme Yöntemleri

2.2.1 Bileşen Değişimi Tabanlı Yöntemler

BD tabanlı yöntemlerde uygulanan algoritma, düşük konumsal çözünürlüğe sahip ÇB görüntüsünü başka bir uzaya yansıtır, orada yüksek konumsal bilgiye sahip olan bileşen PAN görüntüsüyle yer değiştirir ve ardından ters dönüşüm ile gerçek uzaya geri dönülerek pan-keskinleştirilmiş görüntü oluşturulur. BD tabanlı pan-keskinleştirme yöntemlerinin hesaplanması hızlı, uygulaması kolay ve konumsal olarak iyi sonuçlar verir ancak bahsedilen yöntemlerin olumsuz yönü spektral bantlarda bozulmaya sebep olmasıdır (Kahraman, 2019). Bu bölümde uygulamada kullanılan ve standart bileşen değişim tabanlı yöntemlerden bahsedilmektedir.

2.2.1.1 Optimized Brovey Transform with Haze Correction

BT yöntemi görüntüye ait en düşük ve en yüksek kenar değerleri arasındaki farklılığı görsel olarak arttırmak/netleştirmek için kullanılan bir birleştirme yöntemidir. Bu nedenle bu yöntem en çok farklılıkların görsel olarak algılanmasının önemli olduğu uygulamalarda tercih edilmektedir. Temel olarak BT dönüşümü, ÇB görüntünün her bir bandının parlaklık değerlerini ayrı ayrı PAN görüntünün parlaklık değerleri ile çarparak ve elde edilen değeri diğer tüm bantların piksel değerlerinin toplamına bölerek çalışır (Bektaş Balçık ve Göksel, 2009; Abas, 2011). Ancak atmosferdeki gaz ve partiküllerden oluşan puslu etkiler bu yöntemin performansını sınırlandırabilmektedir. Bu yüzden BT-H yöntemi BT yönteminin bu eksikliğini ele almaktadır. Bu yöntemde BT dönüşümüne ek olarak yol parlaklığı (path radiance) etkisini düzeltmek için bir adım eklenir. Her bir ÇB görüntü bandının yol parlaklığı

dikkate alınır (Schowengerdt, 2007; Vivone ve ark.,2020). Yol parlaklığı, gerçek renkli bir görüntüde sis şeklinde görünebilen, atmosferden saçılan istenmeyen enerjiyi temsil eder. Yol parlaklığı, her bir banttaki modülasyon öncesi tahmin edilmeli ve her banttın çıkarılmalıdır, daha sonra pan-keskinleştirilmiş görüntüye geri yerleştirmek için yeniden eklenmelidir. Bu amaçla, yakın zamanda BT-H adı verilen BT'nin puslu düzeltilmiş (haze-corrected) bir versiyonu önerilmiştir (Lolli ve ark., 2017; Vivone ve ark.,2020).

2.2.1.2 Gram Schmidt Yöntemleri

GS yönteminde ÇB görüntünün boyutları PAN görüntünün boyutlarıyla eşitlenir. Bu eşitlemeden sonra ÇB görüntünün bantları, düşük çözünürlüklü bir PAN görüntü oluşturmak için kullanılır. Bu PAN görüntü ÇB görüntünün ilk bandı olarak kullanılır ve ÇB görüntünün diğer bantlarına bu görüntü ile birlikte GS dönüşümü uygulanır. Bunun sonucunda PAN görüntü ile dönüşüm sonucu oluşan görüntünün ilk bandı yer değiştirilir. Sonra oluşan görüntüye ters GS dönüşümü uygulanarak pan-keskinleştirilmiş görüntü üretilir (Laben ve Brower, 2000; Yilmaz, 2012). GSA yöntemi, GS yönteminin gelişmiş bir versiyonudur. Standart GS tekniği, kaynak ÇB görüntü bantlarının ortalamasını alarak düşük çözünürlüklü bir PAN verisi hesaplar, ancak GSA tekniği, bunu ÇB görüntü bantlarının ağırlıklı ortalamasını alarak hesaplar. Ağırlıkları tahmin etmek için kaynak görüntülerin çok değişkenli regresyonunu kullanılır (Aiazzi ve ark., 2007; Yilmaz ve ark., 2021). C-GSA yöntemi ise GSA'nın görüntü piksellerini her bir kümeye (cluster) ayrı ayrı uygulanmasıyla elde edilir. Bu yöntem görüntüyü farklı özelliklere göre ayrıştırarak her bir kümenin farklı özellikleri içermesini sağlamaktadır (Restaino ve ark., 2017; Deng ve ark., 2022).

2.2.1.3 Partial Replacement Adaptive Component Substitution

PRACS tekniği, ilk olarak yapay yüksek çözünürlüklü bileşen görüntüsü ve düşük çözünürlüklü bileşen görüntüsü oluşturur. Yapay yüksek çözünürlüklü bileşen ve düşük çözünürlüklü bileşen görüntülerini ÇB ve PAN görüntüler arasındaki doğrusal regresyon ve korelasyon katsayıları açısından sentezlemek için kısmi yer değiştirme kullanır. PAN görüntüsünün bazı piksellerini ÇB bileşen görüntüsü ile yer değiştirme

işlemi kısmi yer değiştirme olara adlandırılır ve bu işlemde yüksek çözünürlüklü detayların daha iyi ifade edilmesi sağlanır. Daha sonra PAN ve ÇB bantlar arasındaki farkı en aza indirmek için bazı katsayılar hesaplar (Choi ve ark., 2011; Kahraman, 2019).

2.2.1.4 Band-Dependent Spatial Detail Yöntemleri

BDSD yönteminde, en küçük ortalama karesel hata hesaplanarak ÇB-PAN görüntüleri arasında pan-keskinleştirme gerçekleştirmektedir. Bu yöntemde, düşük çözünürlüklü ÇB ile düşük çözünürlüklü PAN görüntünün karesel hatasını minimize ederek çözüm oluşturmaktadır. Bu iki görüntü arasındaki farkı en aza indirmeyi amaçlar (Garzelli ve ark., 2008; Kahraman, 2019). BSDS (Garzelli ve ark., 2008; Yılmaz ve ark., 2021) yöntemi baz alınarak C-BSDS (Garzelli, 2015; Yılmaz ve ark., 2021) ve BSDS-PC (Vivone, 2019; Yılmaz ve ark., 2021) pan-keskinleştirme yöntemleri uyarlanmıştır. BSDS-PC yöntemi, kaynak ÇB görüntü bantlarının ağırlıklı toplamını hesaplamak amacıyla kullanılan ağırlıkları tahmin etmek için bazı fiziksel kısıtlamaları (spektral indeksler gibi) kullanır. Detay görüntülerini hesaplarken de bu tahminleri kullanmaktadır (Vivone, 2019; Yılmaz ve ark., 2021). C-BSDS tekniği, görüntü piksellerini k-means algoritmasını kullanarak birkaç kümeye böler. Daha sonra, her bir piksel grubu için bant ağırlıklarını tahmin eder. Bu tahmin için minimum varyans yansız tahmincisi (variance unbiased estimator) (Garzelli, 2015; Wang ve ark., 2014; Yılmaz ve ark., 2021) kullanılır (Yılmaz ve ark., 2021).

2.2.2 Çoklu Çözünürlük Analizi Tabanlı Yöntemler

ÇÇA'ya dayalı yöntemler literatürde en sık kullanılan yöntemler arasındadır. Bu yöntemler genellikle üç aşamada uygulanmaktadır (Ghassemien, 2016; Yılmaz ve ark., 2021). İlk aşamada, girdi görüntüler dalgacık (wavelet) dönüşümü veya piramit dönüşümü gibi çoklu çözünürlük ayrıştırma (decomposition) algoritmaları ile belli sayıda ölçek seviyesinde ayrıştırılır. İkinci aşamada, spektral ve konumsal detaylar belli pan-keskinleştirme kurallarına göre birleştirilir. Son aşamada ise ters çoklu çözünürlük ayrıştırma dönüşümü ile pan-keskinleştirilmiş görüntü orijinal renk uzayında üretilir. BD tabanlı tekniklerin aksine, ÇÇA tabanlı yöntemler yüksek renk

kalitesi vaat eder ancak PAN giriş görüntüsünün konumsal ayrıntılarını koruyamaz (Yang ve ark., 2018; Serifoglu Yilmaz ve ark., 2019; Yılmaz ve ark., 2021). Bu bölümde standart ve uygulamada kullanılan ÇÇA tabanlı yöntemlerden bahsedilmektedir.

2.2.2.1 Additive Wavelet Luminance Proportional

AWLP yöntemi çoklu çözünürlüklü pan-keskinleştirme yöntemlerinden biridir. AWLP yöntemi AWL yöntemi geliştirilerek oluşturulmuştur. Bu yöntem ilk olarak üç bantlı (RGB) görüntüler için tanımlanmıştır (Nunez ve ark., 1999; Kahraman, 2019). AWL tekniğinde yüksek çözünürlük detayları ÇB görüntünün parlaklık bileşenine eklenmektedir. Bunu yapmak için, RGB uzayından IHS renk uzayına bir dönüşüm uygulanır. PAN ve görüntünün parlaklık, yoğunluk değerini temsil eden ışıklılık bileşeni arasında histogram eşitlemesi yapılır. Daha sonra, PAN ve ışıklılık bileşeni Wavelet düzlemlerine ayrılmaktadır. PAN görüntünün yüksek konumsal detayları ışıklılık bileşeninin Wavelet katsayılarına eklenir. Pan-keskinleştirilmiş görüntü, detay eklenmiş olan ışıklılık bileşenine ters Wavelet ve ters IHS dönüşümü uygulanarak elde edilir (Kahraman, 2019). AWL yöntemine ek olarak her bir ÇB görüntü bandın toplam ÇB görüntü bantlarının ortalamasına bölünerek kazanç faktörü elde edilmektedir. Bu değer konumsal detay bilgisi ile çarpılması görüntünün spektral özelliklerini değiştirmeden detayları korumaktadır. Bu yöntem AWLP (Otazu ve ark., 2005) yaklaşımı adı verilmektedir (Kahraman, 2019).

2.2.2.2 Generalized Laplacian Pyramid with Modulation Transfer Function Matched Filter Yöntemleri

MTF-GLP yöntemi, girdi ÇB görüntüsünü üreten sensöre ait olan MTF'yi kullanarak bir görüntünün spektral özelliklerinin korunmasına olanak sağlayan bir kısıtlama oluşturur ve konumsal detay bilgisini seçici olarak girdi ÇB görüntünün bantlarına enjekte eder. Burada MTF bir sensörün belirli frekanstaki detaylarını nasıl aktardığını ölçen bir fonksiyondur (Aiazzi ve ark., 2006; Yılmaz ve ark., 2021). MTF-GLP yöntemi, MTF filtresi aracılığıyla indirgenen PAN görüntüyü girdi PAN görüntüden çıkartarak konumsal bilgileri elde eder. Bu yaklaşım düşük renk frekansına sahip alanlarda renk özelliklerinin korunmasını sağlar (Yılmaz ve ark.,

2021). MTF-GLP-HPM yöntemi, aşağı yönlü ölçeklemeden önce MTF'den faydalanır ve bir yandan girdi ÇB görüntünün spektral özelliklerini korurken diğer yandan, konumsal ayrıntıları enjekte etmek için konumsal özelliklerin çarpımına dayanan bir high-pass modulation (HPM) enjeksiyon yaklaşımı kullanır (Vivone ve ark., 2014; Xing ve ark., 2018; Yilmaz ve ark., 2021). MTF-GLP-HPM-R yöntemi, kaynak ÇB görüntü bantları ile kaynak PAN verilerinin düşük geçişli filtrelenmiş bir versiyonu arasındaki çok değişkenli doğrusal regresyona dayanan bir renk eşleştirme stratejisi kullanır (Vivone ve ark., 2020; Yilmaz ve ark., 2021). MTF-GLP-HPM-H (Lolli ve ark., 2017) yöntemi ise BT-H'deki gibi pus düzeltmeli bir füzyon algoritmasına benzer bir yaklaşım uygulamıştır (Vivone ve ark., 2020). MTF-GLP-CBD tekniği, kaynak PAN verilerinin konumsal yapısını çıkarmak için Gauss şekilli bir alçak geçirgen filtre kullanır. Kaynak görüntüler arasındaki regresyon çizgisinin eğimi enjeksiyon katsayılarını hesaplamak için kullanılır. MTF-GLP-FS yöntemi enjeksiyon katsayılarını tam ölçekte hesaplar (Vivone ve ark., 2018; Yilmaz ve ark., 2021). (Restaino ve ark., 2017) tarafından ÇB görüntüsünü spektral olarak benzer parçalara bölmek için bir k-means kümeleme yönteminin kullanımına dayalı yerel bir versiyon önerilmiştir ve bu yöntem C-MTF-GLP-CBD olarak adlandırılmıştır (Vivone ve ark., 2020).

2.2.2.3 Nonlinear Decomposition Scheme Using Morphological Filtering Based on Half Gradient

Bu yöntemde pan-keskinleştirilmiş görüntü oluşturmak için morfolojik piramit ve morfolojik filtre kullanılmaktadır. İlk olarak morfolojik yarı gradyanlara dayalı bir morfolojik piramit kullanılarak görüntüyü farklı çözünürlük seviyelerine ayırıştırır. Görüntülerden ayrıntı elde etmek için de morfolojik filtreleme kullanır (Vivone ve ark., 2020).

2.2.3 Varyasyonel Yaklaşımlar

VY tabanlı yöntemler pan-keskinleştirmeyi bir optimizasyon problemi olarak ele alır. Yani, kaynak ÇB görüntüsünün PAN görüntüsüne nasıl en iyi şekilde birleştirileceğini belirlemek için matematiksel bir yaklaşım uygular. Bu teknikler, varyasyonel optimizasyon şeması içinde uygun bir çözüm bulmak için kullanılan bir

amaç fonksiyonu kullanır. VY tabanlı yöntemler genellikle kaynak görüntüler ve pan-keskinleştirilmiş görüntü arasında bir ilişki kurmak için kullanılan sensör modelleri aracılığıyla pan-keskinleştirilmiş görüntüler üretir (Vivone ve ark., 2020; Yilmaz ve ark., 2021). P+XS tekniği, ilk VY tabanlı pan-keskinleştirme tekniklerinden biridir (Ballester ve ark., 2007; Yilmaz ve ark., 2021). P+XS yaklaşımı, spektral kanallar ile PAN görüntü arasındaki ilişkiyi ve çözünürlük farkını da dikkate alarak oluşturulan enerji fonksiyonunu minimize etmeye dayalı bir pan-keskinleştirme yöntemidir (Ballester ve ark., 2007; Kahraman, 2019) .

2.2.3.1 Total Variation

VY tabanlı TV yönteminin test alanlarında çok iyi bir pan-keskinleştirme performansı sergilediği söylenebilmektedir. Bu yöntem, kaynak PAN görüntüsünün, pan-keskinleştirilmiş bantların doğrusal bir kombinasyonu olduğunu ve pan-keskinleştirilmiş görüntünün kaynak ÇB görüntüsünden bazı bilgiler çıkarılarak elde edildiğini varsayar. TV yönteminin bir diğer önemli avantajı da modeli görüntü yamalarına (patch) uygulamamasıdır. Bunun yerine, bu modeli tüm görüntülere uygular ve bu da TV yönteminin test alanlarında zaman açısından verimli olmasını sağlar (Yilmaz ve ark., 2021).

2.2.3.2 Sparse Representation of Injected Details

SR-D yöntemi görüntüdeki her yamayı (patch) belirli bir seyrek temsil ile temsil etmektedir. Burada seyrek temsil görüntüdeki ayrıntıların daha az sayıda bileşenle ifade etmeye çalışan matematiksel bir ifadedir. Bu yöntemde belirli ölçeklerdeki konumsal ayrıntıların görüntü yamaları toplanır. Bu görüntü yamalarını sözlüklerde depolar ve bu sözlükler yüksek çözünürlüklü temel bileşenleri ifade eder (Vicinanza ve ark., 2015; Yilmaz ve ark., 2021). Genel bir ifadeyle SR-D yöntemi, farklı ölçeklerdeki konumsal ayrıntıların, ham görüntü yamaları koleksiyonları olarak oluşturulan belirli sözlüklerde aynı seyrek katsayılara sahip olduğu kavramından yararlanarak eksik ayrıntıları çıkarır (Yilmaz ve ark., 2021).

2.2.3.3 Principal Component Analysis/Wavelet Model-based Fusion

PWMBF, dalgacık tabanlı bayes füzyon yönteminin (Zhang ve ark., 2009; Yilmaz ve

ark., 2021) bir uzantısıdır ve kaynak ÇB görüntüsü ile pan-keskinleştirilmiş görüntünün konumsal olarak bozulmuş (kaynak ÇB görüntü ölçeğinde) versiyonu arasında bir bağlantı kurmak için dalgacık alanında bir gözlem modeli kullanır. Konumsal bozulma oldukça sorunlu olabileceğinden kaynak ÇB görüntüsünü PAN boyutuna yükseltmek için modele bir önsel (önceden özelliklerin dâhil edilmesi) dâhil edilir. PWMBF tekniği, PCA dönüşümünü gözlem modeline dâhil eder. Bu yöntemde PCA dönüşümü ve dalgacık alanında gözlem modeli kullanılarak pan-keskinleştirilmiş görüntü elde edilir (Palsson ve ark., 2015; Yilmaz ve ark., 2021).

2.2.3.4 Filter Estimation Based on a Semiblind Deconvolution Framework and High-Pass Modulation Injection Model

Pan-keskinleştirme algoritmasının ilk adımı PAN görüntüsünden konumsal ayrıntıları çıkarmaktır. Yararlı konumsal ayrıntıların miktarını en üst düzeye çıkarma görevini genellikle ÇB görüntü sensörünün MTF'si ile eşleşen filtreler yapar. MTF sensörüyle eşleşen Gauss filtreleri, bu adım için en son teknolojiyi temsil eder. Bu durumda, filtreyi tanımlamak için sensör özelliklerine ilişkin ön bilgiden yararlanılır. Bu bilgilerin bulunmaması veya yanlışlığı bu yaklaşımın güçlü bir şekilde sınırlandırılmasına neden olur. Ya da çıkarılan ayrıntılar yanlış olabilir. Bu sorunun üstesinden gelmek için, ÇB ve PAN görüntüsü arasındaki bulanıklığı modelleyen filtreyi tahmin etmek için yalnızca mevcut görüntüleri kullanarak ve hiçbir ön/ekstra bilgi (MTF ön bilgisi gibi) içermeyen bir yaklaşım benimseyen FE-HPM yöntemi önerilmiştir (Vivone ve ark., 2014).


2.3 Derin Öğrenme Tabanlı Pan-Keskinleştirme Yöntemleri

2.3.1 Pansharpening Neural Network

Günümüzde, CNN tabanlı yöntemler makine öğrenimi yaklaşımları arasında en umut verici olanlardır. Bundan dolayı, burada pan-keskinleştirme yöntemi için CNN'leri ilk kullananlardan biri olan (Masi ve ark, 2016)'nın öncü çalışmalarına dayanan 4 farklı yaklaşımdan bahsedilmiştir. Bunlardan ikisi PNN ve PNN-IDX olarak ve diğer ikisi de A-PNN ve A-PNN-FT diye adlandırılan dört model incelenmiştir. Burada IDX, bazı indekslerin yardımcı girdi olarak kullanılması, FT ise ince ayar

(kullanılacak olan parametrelerin daha iyi sonuç vermesi için hassas/özenli bir şekilde ayarlanması) anlamına gelmektedir (Vivone ve ark, 2020).


(Masi ve ark, 2016) tarafından PNN olarak adlandırılan pan-keskinleştirme evrişimli sinir ağı modeli, CNN'lere dayalı ilk pan-keskinleştirme yöntemleri arasındadır. (Dong ve ark, 2016) tarafından önerilen doğal görüntüler için süper çözünürlüklü ağdan ilham alan PNN, çok basit ve üç katmanlı evrişimli bir modeldir. Burada, orijinal versiyondan farklı olarak, kullanılacak parametreler tüm sensörler için eşit olarak ayarlanmıştır. Ancak, bütün ağın giriş ve çıkış kanalları (channels), ÇB görüntülerinin spektral bant sayısı ile ilgilidir. Üç evrişimli katman, RELU aktivasyonlarıyla birbirine bağlıdır. Ağa ilerlemeden önce, giriş ÇB görüntü bileşeni enterpolasyon yöntemi ile PAN boyutuna ölçeklendirilir ve PAN ile birleştirilerek tek bir giriş veri küpü oluşturulur. Bu oluşturulan giriş veri küpü ağın girdi verisini oluşturur. Evrişim katmanları, giriş veri küpünden birçok özellik haritaları çıkarır. PNN, (Dong ve ark, 2016)'da tek görüntü süper çözünürlük için CNN mimarisinden yararlanırken, pan-keskinleştirme işlemini genişletmektedir. Bu sebeple DÖ tabanlı pan-keskinleştirme topluluğunda oldukça önemli bir role sahiptir. Ayrıca, tamamen evrişimsel sinir ağı kullanarak pan-keskinleştirme işlemini ele alan ilk girişimdir ve sonradan geliştirilen DÖ tabanlı pan-keskinleştirme yöntemleri için önemli bir referans noktası olmuştur (Deng ve ark, 2022). PNN'nin PNN-IDX versiyonu, ÇB görüntü bantlarından türetilen yardımcı girdilerin kullanımını içermektedir. Bunlar normalize edilmiş fark bitki örtüsü/su indeksleri/toprak türü gibi iyi bilinen radyometrik indekslerdir. Bu indeksler yüzey özelliklerini vurgulamak için kullanılır. Bu nedenle, PNN ve PNN-IDX arasındaki temel fark, şekil 17'de kesikli bir kutuyla vurgulanan CNN girdi oluşturma süreciyle ilgilidir. Burada radyometrik indeks haritalarında dâhil edilerek daha fazla özellik ve ayrıntı çıkarımı sağlanır. Bu da (Vivone ve ark., 2020)'de elde ettiği sonuçlara göre daha fazla sayıda girdi bantı anlamına gelmektedir. Bu ek giriş bantlarının kullanımı, bir PNN'nin ilk evrişimsel katmanı tarafından çıkarılan birçok özellik haritasının bu radyometrik indekslerle güçlü bir korelasyon gösterdiği deneysel gözlemlerle saptanmış olup bu sezgi daha sonra PNN-IDX'in PNN'ye göre üstün performansı ile deneysel olarak doğrulandığını göstermiştir (Vivone ve ark., 2020).



Şekil 17. PNN ve PNN-IDX (kesikli kutu dâhil) algoritmalarının üst düzey akış şeması. NI, ÇB'den çıkarılan normalleştirilmiş dizinlerin bir yığınıdır (Vivone ve ark., 2020).

(Scarpa ve ark. 2018) tarafından üç ana yenilik sunan gelişmiş bir PNN versiyonu önerilmiştir: artık öğrenme, ℓ_1 -kayıp ve hedef uyarlama için ince ayar. Artık öğrenme (He ve ark., 2016), derin öğrenmede önemli bir yeniliktir ve kaybolan gradyan sorunlarını önlemeye yardımcı olduğu için çok derin ağlarda eğitim sürecini hızlandırmak amacıyla tanıtılmıştır. Üstelik kısa süre içinde çözünürlük geliştirme için doğal bir seçim olduğu ortaya çıkmıştır (Kim ve ark, 2016). Aslında, istenen süper çözünürlüklü görüntü, düşük ve yüksek frekans bileşenlerinden oluşmuş bir şekilde düşünülebilir, ilk bileşen esas olarak giriş düşük çözünürlüklü görüntüyü temsil ederken, ikincisi gerçekten geri yüklenmesi gereken eksik (veya artık) bölümdür. Artık şemalar, doğal olarak süper çözünürlük veya pan-keskinleştirme problemlerini bu bölüm ışığında ele alarak, istenen tüm çıktının gereksiz bir şekilde yeniden oluşturulmasını önler ve görüntünün düşük frekanslı içeriğini değiştirme riskini (yani spektral bozulma) azaltır. A-PNN/-FT için, PNN modeline eklenen tek bir giriş-çıkış atlamalı bağlantısı, onu genel bir artıklı modüle dönüştürür. Kesikli çizgiler ile gösterilen bağlantılar, ince ayarlama aşamasına işaret eder. Genellikle eğitim verileri test görüntülerinden gelmezken, ince ayarlama aşamasında aynı test görüntüsü parametre güncellemesi için kullanılır. İnce ayarlama başladığında, model parametreleri Φ_0 , ön eğitimde hesaplananlara karşılık gelir ve A-PNN olarak adlandırılır. Hedef (ölçeklenmiş) test görüntüsünde belirli bir ayarlama iterasyonu sayısından sonra parametreler dondurulur (Φ_∞ olarak adlandırılır) ve sonunda tam çözünürlüklü test görüntüsü, ‘iyileştirilmiş’ A-PNN olan A-PNN-FT kullanılarak

pan-keskinleştirme işlemine tabi tutulur (Vivone ve ark., 2020). Şekil 18’de A-PNN-FT yönteminin şeması verilmiştir.



Şekil 18. A-PNN-FT üst düzey iş akışı (Vivone ve ark., 2020).

2.3.2 Deep Convolutional Neural Network Architecture for Pansharpening


(Yang ve ark, 2017) tarafından, düşük çözünürlüklü ÇB ve PAN görüntülerinden gelen yüksek frekanslı bilgi girdilerine dayanarak pan-keskinleştirme görevi için PANNET adı verilen derin bir CNN mimarisi tasarlanmıştır. Söz konusu PANNET mimarisi, alana özgü bilgileri dikkate almakta ve temel olarak uzaktan algılama görüntülerindeki spektral ve konumsal bilgilerin korunmasına odaklanmaktadır. Genel olarak, PANNET'in ağ mimarisi, spektral bilgiyi korumayı amaçlayarak önce yüksek çözünürlüklü ÇB görüntüsünü PAN ölçeğine yükseltir. Ayrıca, pan-keskinleştirme görüntüsü için konumsal ayrıntıları elde etmek amacıyla konumsal haritalamayı (spatial mapping) öğrenmek için derin bir artık ağ kullanılmaktadır. Burada konumsal haritalama görüntüdeki piksellerin konumunu belirler. Derin artık ağ kullanılarak pan-keskinleştirilmiş görüntü için konumsal detayları elde etmek amacıyla konumsal haritalama öğrenilir. Özellikle, derin artık ağı temel olarak özellik kanallarını artıran bir ön işleme evrişimsel katman ve kanalları spektral bantlara indirgeyen bir son işleme evrişimsel katman içerir. Ayrıca, daha iyi bir özellik çıkarımı için ağ derinliğini artırmak üzere atlama bağlantılı dört RESNET bloğu (He ve ark, 2016) kullanılmaktadır. Özellikle, basit yüksek geçişli filtreler kullanılarak elde edilen düşük çözünürlüklü ÇB ve PAN görüntülerinin yüksek frekanslı konumsal bilgileri birleştirilir ve eğitimi için derin artık ağında kullanılır.

2.3.2.1 RESNET Mimarisi

2015 yılında düzenlenen ILSVRC IMAGENET yarışmasını Microsoft RESNET kazanmıştır. Bu yarışmada Microsoft RESNET %3.6 gibi bir hata oranı elde etmiştir. Genelde insanlar ortalama %5-%10 hata oranı ile görüntü sınıflandırma işlemini gerçekleştirirken %3.6'lık bir hata oranı ile insandan daha iyi görsel tanıma yaparak bu alanda başarısını göstermiştir. Bu mimari daha önceki DÖ mimarilerin üzerinde bir derinliğe sahiptir. Ayrıca katman sayısında diğer DÖ mimarilerindeki katman sayısından daha fazladır (Russakovsky, 2015; Doğan ve Türkoğlu 2019).

İki RELU aktivasyon fonksiyonunun arasında bulunan doğrusal katman ve artık değer (Residual Value) ile beslenen artık bloktan (Residual Block) oluşturulan Microsoft RESNET mimarisi ile öğrenme daha hızlı şekilde gerçekleşeceği düşünülmüştür. Artık blokta, x değerinin girişinden sonra evrişim-RELU-evrişim serisi sonucu bir $F(x)$ değeri oluşmaktadır. Bu sonuç daha sonra orijinal x girişine eklenir ve (2.1)'deki formülle ifade edilir (Ülker ve ark., 2017). Bu artık modül şekil 20'de görülmektedir.

$$H(x) = F(x) + x \quad (2.1)$$



Şekil 20. RESNET artık modülü (He ve ark., 2016; Ülker ve ark., 2017).

Bir artık ağ, birkaç artık bloğun bir araya getirilmesiyle oluşturulur. Her bir artık blok; evrişim katmanları, toplu(batch) normalizasyon ve aktivasyon katmanlarından oluşmaktadır. Toplu normalizasyon veriyi işler ve verinin yapısını bozmadan bazı ölçekleme teknikleri kullanarak sayısal kararlılık sağlar. Aktivasyon katmanı, sinir ağının daha karmaşık verileri öğrenmesine yardımcı olmak için artık ağa eklenir.


CNN veya DÖ yöntemi, çıktıyı sağlarken görüntü verilerinin doğrusal olmayan doğasına uyum sağlamak için aktivasyon katmanında RELU işlevini kullanır. Artık bloklar, artık veya atlama bağlantı stratejisi ekleyerek ağın ilk katmanından son katmanlarına bilgi akışına izin verir. Bu nedenle RESNET, giriş verilerinin özelliklerini ağın çıkışında etkili bir şekilde kullanabilir ve böylece gradyan kaybolma sorunlarını hafifletebilir (Priya ve ark., 2022). RESNET 152 katmandan oluşan bir mimaridir (Doğan ve Türkoğlu 2019).

2.3.3 Multiscale and Multidepth Convolutional Neural Network

(Yuan ve ark., 2018) tarafından pan-keskinleştirme için MSDCNN adı verilen çok ölçekli ve çok derinlikli bir CNN tabanlı bir mimari önerilmiştir. Şekil 21’de gösterildiği gibi MSDCNN, birden çok ölçekli alıcı alanlara sahip farklı evrişimli filtreler kullanarak derin ve sıkı özellikleri çıkarır ve daha iyi bir tahmin elde etmek için son olarak bunları entegre eder. Pan-keskinleştirme işlemi, ideal restorasyon için hem kaba yapılar (coarse structures) hem de doku detayları (texture details) büyük önem taşır. Aynı zamanda, zemin nesnelerinin boyutları çok küçük komşuluklardan (neighborhoods) binlerce piksel içeren geniş bölgelere kadar değişir ve bir zemin sahnesi, çeşitli boyutlarda birçok nesneyi kapsayabilir.

Çok ölçekli özellikler, farklı boyutlara sahip evrişimli filtrelere farklı yanıt vermektedir. Buna bağlı olarak çekirdek boyutları 3x3, 5x5 ve 7x7 olan üç paralel evrişimli katman içeren çok ölçekli bir blok oluşturulmuştur. Ayrıca, her çok ölçekli blok için kısa bir atlama bağlantısı kullanılmıştır (çok ölçekli artık blok (Şekil 21’de MSResB)). Giriş görüntü küpünü derin çıkarma dalından geçirerek, ideal multispektral görüntülerle aynı spektral boyuta indirgenmiş olan CNN_d derin öznitelikleri çıkarabilir. Öte yandan, CNN’lerin sıkı özellikleri, çekirdek boyutlarının sırasıyla 9x9, 1x1 ve 5x5 olduğu üç evrişimli katmana sahip sıkı özellik çıkarma bloğu tarafından sağlanır (Deng ve ark, 2022). Ayrıca, derinlik arttıkça her iki koldaki evrişimli katmanların çıktı öznitelik sayıları da azalmaktadır. MSDCNN ayrıca SGD optimizasyon algoritmasıyla L2 kayıp fonksiyonu kullanılarak eğitilmiştir. Genel olarak, MSDCNN, bir özelliği farklı boyutlara sahip çekirdeklerle birleştirerek elde edilen çeşitli özelliklerden yararlanır (çok ölçekli işlem olarak adlandırılır). Bu strateji ile, özellik çıkarımını iyileştirmek için çeşitli alıcı alanlara

sahip farklı özellikler birleştirilir. Çok ölçekli özellik çıkarım bloğu, çoklu ölçekli özellikleri, diğer dal üç basit konvolüsyon gerçekleştirerek sözde sığ özellikleri elde etmektedir. Burada sığ özellik görüntüdeki geniş özellikleri, genel yapıları ifade ederken çok ölçekli özellik ise detay yapıları ifade etmektedir (Deng ve ark, 2022). Şekil 21’de MSDCNN’nin ağ mimarisi verilmiştir (Deng ve ark, 2022).




Şekil 21. MSResB'nin çok ölçekli artık blok olduğu L2 kayıp işlevini kullanan MSDCNN'nin akış şeması. Ayrıca, CNN_d ve CNN_s sırasıyla derin ve sığ özellikleri temsil eder (Deng ve ark, 2022).

2.3.4 Pansharpening by Combining Machine Learning and Traditional Fusion Schemes

(Deng ve ark, 2020)'da pan-keskinleştirme işlemini ele almak için MÖ teknikleri ile diğer yöntemleri, yani CS ve MRA'nın birleşiminden faydalanmaktadır. FUSIONNET adı verilen genel ağ mimarisi, iki ayrı tabanlı yöntemden yararlanarak yukarı örneklenmiş düşük çözünürlüklü ÇB görüntüsünün ve çıkarılan ayrıntıların birleştirilmesini yöneten doğrusal olmayan enjeksiyon modellerini tahmin eder. Özellikle çıkarılan ayrıntılar, PAN görüntüsü ile yukarı örneklenmiş düşük çözünürlüklü ÇB görüntüsü arasındaki farkın derin bir kalıntı ağına doğrudan girilmesiyle hesaplanabilir. PAN ve yukarı örneklenmiş düşük çözünürlüklü ÇB görüntülerini doğrudan farklılaştıran bu strateji basittir. Bununla birlikte, sırasıyla PAN ve düşük çözünürlüklü ÇB görüntülerinden konumsal ve spektral bilgileri koruyabilir (Deng ve ark, 2022). Ayrıca çıkarılan ayrıntılar, özellik kanallarını artırmak için bir ön işleme evrişim katmanındayken, ardından daha iyi bir özellik

çıkarmayı için ağın derinliğini arttırmak üzere dört RESNET bloğundan geçirilir. Oluşturulan özellikler, aynı düşük çözünürlüklü ÇB spektral bant numarasına sahip yüksek çözünürlüklü ÇB ayrıntılarını elde etmek için bir son işleme katmanı tarafından evrişim işlemine tabi tutulur. Ayrıca öğrenilen yüksek çözünürlüklü ÇB ayrıntıları, yüksek çözünürlüklü ÇB sonucunu elde etmek için doğrudan yukarı örneklenmiş düşük çözünürlüklü ÇB'ye eklenir. FUSIONNET, ağı eğitmek için Adam optimize ediciden ve sabit bir öğrenme oranından (learning rate) yararlanır. Yüksek çözünürlüklü ÇB sonucu ile GT görüntüsü arasındaki mesafeyi ölçmek için kayıp işlevi olarak geleneksel L2 işlevi kullanılır (Deng ve ark, 2022). FUSIONNET mimarisi şekil 22'de verilmiştir (Deng ve ark, 2022).




Şekil 22. L2 kayıp fonksiyonundan yararlanan FUSIONNET'in akış şeması. P_D , spektral boyut boyunca P 'nin kopyalanmış versiyonudur (Deng ve ark, 2022).

2.3.5 Deep Residual Pansharpening Neural Network

(Wei ve ark., 2017) tarafından pan-keskinleştirme işlemi ele almak için DRPN adlı derin bir artık sinir ağı önermiştir. Daha fazla filtreleme katmanına sahip daha derin bir CNN'nin daha soyut ve temsilci özellikler çıkarma eğiliminde olduğunu düşünerek daha yüksek bir tahmin doğruluğu beklemektedirler. Bununla birlikte, gradyan kaybolma sorunu sebebiyle, sık katmanlar ağı geriye yayarak optimize edemez, bu da derin ağı tam olarak öğrenilmemesini sağlar. Derin artık öğrenme (He ve ark., 2016; Deng ve ark., 2022), bu sorunu çözmek için geliştirilmiş bir yöntemdir. Bu yöntemde dönüşüm $F(X) \approx \text{CNN}(X)$ yerine $F(X) - X \approx \text{RES}(X)$ olarak değiştirilir ve ayrı katmanlar arasında atlamalı bağlantılar kurularak daha fazla katmanın ağına eklenmesi, performansının artırılması sağlanır (Deng ve ark., 2022).

DRPNN’de evrişim filtreleme çerçevesinin önünde ve arkasında on katman içeren derin bir artıklı atlamalı bağ oluşturulmuştur ve tüm filtre boyutları 7×7 olarak ayarlanmıştır. Birleştirilecek ÇB görüntü bantları PAN ölçeğine enterpolasyon yapılır ve ardından PAN görüntüsü ile birleştirilerek bir giriş küpü oluşturulur. Derin artıklı özellik çıkarımından sonra, pan-keskinleştirilmiş görüntüleri elde etmek için N gruplu evrişim filtreleri içeren bir restorasyon katmanı kullanılır. Sonuç, GT ile L2 kaybını hesaplamak için kullanılır. Ayrıca DRPNN'yi eğitmek için SGD optimizasyon algoritması kullanılmıştır (Deng ve ark., 2022). Derin artıklı atlama, modelin girdi ve çıktı arasındaki farkı öğrenmesini sağlayarak hızlı ve doğru eğitim sağlar. Atlama bağlantısı stratejisi DRPNN ile aynı dönemde yayınlanan PANNET'te de kullanılmaktadır. DRPNN, daha geniş bir alanı kapsayabilen 7×7 gibi daha büyük boyutlu evrişim filtreleri kullanması sayesinde rekabetçi sonuçlar alabilmektedir. Ancak, bu büyük filtreler nedeniyle DRPNN göreceli olarak yüksek parametre miktarına sahiptir (Deng ve ark., 2022). Şekil 23’te DRPNN’nin akış şeması verilmiştir.



Şekil 23. L2 kayıp işlevini kullanan DRPNN'nin akış şeması (Deng ve ark., 2022).

Tablo 3’te karşılaştırılan tüm DÖ tabanlı pan-keskinleştirme yöntemlerinin (Deng ve ark, 2022) tarafından eğitim sırasında kullanılan parametre ayarları (epoch sayısı, batch size, optimizasyon algoritması, kayıp fonksiyonu, aktivasyon fonksiyonu) gösterilmiştir. Ayrıca IKONOS uydu veri setleri için 10.000 örnek oluşturulmuştur. Bu örneklerin 9.000 eğitim örneği ve 1.000 doğrulama örneği şeklinde kullanılmaktadır. WV2 uydu veri setleri için 16.107 örnek oluşturulmuş olup

bunların 14.496 eğitim örneği ve 1.611 doğrulama örneği şeklinde kullanılmıştır.

Tablo 3. Karşılaştırılan DÖ tabanlı yöntemler için eğitim sırasında kullanılan parametreler.

Parametre	PNN/ PNN- IDX	A- PNN/A- PNN- FT	PANNET	MSDCNN	FUSIONNET	DRPNN
Epock	12,000	10,000	450	500	400	500
Batch Size	64	64	32	64	32	64
Kayıp Fonksiyonu	L2	L1	L2	L2	L2	L2
Optimizasyon Algoritması	SGD	SGD	Adam	Adam	Adam	Adam
Aktivasyon Fonksiyonu	RELU	RELU	RELU	RELU	RELU	RELU

2.4 Pan-Keskinleştirmede Kalite Metrikleri

Referans gerektirmeden kalite (QNR), tam çözünürlüklü pan-keskinleştirme görüntülerinin kalitesini ölçer. Bu metriğin diğer metriklerden farkı referans görüntü gerektirmemesidir (Maleki ve Ghassemian, 2019).

QNR metriği denklem (2.2)'deki gibi ifade edilir (İşler, 2018).

$$QNR = (1 - D_\lambda)^\alpha (1 - D_s)^\beta \quad (2.2)$$

QNR metriği, formülde görüldüğü üzere sırasıyla spektral ve konumsal bozulmayı hesaplayan, iki ayrı değerden oluşan α ve β katsayıları ile ağırlıklandırılan çarpımdan oluşur. $(1 - D_\lambda)$ ve $(1 - D_s)$ sırasıyla spektral ve konumsal kaliteyi temsil eder. QNR endeksi ne kadar yüksek olursa pan-keskinleştirilmiş görüntünün kalitesi o kadar yüksek olur (İşler, 2018).

Spektral bozulma olan D_λ , denklem (2.3) ile hesaplanır (İşler, 2018).

$$D_\lambda = \sqrt[p]{\frac{1}{N(N-1)} \sum_{i=1}^N \sum_{j=1, j \neq i}^N |d_{i,j}(\mathcal{C}\mathcal{B}, \widehat{\mathcal{C}\mathcal{B}})|^p} \quad (2.3)$$

$\mathcal{C}\mathcal{B}$ ve $\widehat{\mathcal{C}\mathcal{B}}$ sırasıyla düşük çözünürlüklü $\mathcal{C}\mathcal{B}$ ve pan-keskinleştirilmiş görüntüyü ifade eder. N değeri ise $\mathcal{C}\mathcal{B}$ görüntünün bant sayısıdır (İşler, 2018).

Konumsal bozulma olan D_s , denklem (2.4) yöntemi ile bulunur (İşler, 2018).

$$D_s = \sqrt[q]{\frac{1}{N} \sum_{i=1}^N |Q(\mathbb{C}B_i P_L) - Q(\mathbb{C}B_i P_H)|^q} \quad (2.4)$$


$\mathbb{C}B_i$, P_L ve P_H sırasıyla $\mathbb{C}B$ görüntüsünü, düşük çözünürlüklü PAN görüntüsünü ve yüksek çözünürlüklü PAN görüntüsünü ifade etmektedir. (İşler, 2018). Bu denklemlerde, p ve q , büyük fark değerlerini vurgulamak için seçilen pozitif tam sayılardır. Varsayılan olarak bire eşit olarak ayarlanırlar. D_λ , pan-keskinleştirilmiş bantlar arasındaki karşılıklı ilişkinin, $\mathbb{C}B$ görüntü bantları arasındaki ilişki kadar aynı olması gerektiğini belirtir ve D_s , her bir pan-keskinleştirilmiş bant ile PAN görüntüsü arasındaki ilişkinin, $\mathbb{C}B$ görüntü bandı ve düşük çözünürlüklü PAN arasındaki ilişkiyle aynı olması gerektiğini belirtir. D_s ve D_λ birleştirilerek QNR kalite indeksi elde edilir (Alparone ve ark. 2008; Maleki ve Ghassemian, 2019), (Carlà ve ark. 2015; Maleki ve Ghassemian, 2019).

2.5 Destek Vektör Makineleri ile Sınıflandırma Yöntemi

DVM, Vladimir N. Vapnik tarafından ortaya atılan istatistiksel öğrenme teorisine dayalı bir kontrollü öğrenme algoritmasıdır (Vapnik, 1995; Çölkesen ve Kavzoğlu, 2008). DVM'nin temel amacı, iki sınıfı en iyi ayırt edebilen bir hiperdüzlem tanımlamaktır (Vapnik, 2000; Çölkesen ve Kavzoğlu, 2008). DVM, öznetelik bilgilerini kullanarak bir test veri setinin sınıf etiketlerini öğrenebilen veya tahmin edebilen bir model oluşturmayı amaçlar. Böylece sınıflandırma işleminde eğitim setindeki veriler kullanılarak DVM tarafından bir hiper düzlem belirlenir ve oluşturulan bu düzlemin geçerliliği (genelleştirilebilirliği), test veri seti adı verilen bağımsız bir veri seti kullanılarak belirlenir. K boyutlu bir verinin sınıflandırılmasında DVM ile $(K-1)$ boyutlu bir hiperdüzlem geliştirilir. İkili sınıflandırma probleminin doğrusal olarak ayrılabilir bir veri kümesine sahip olduğu göz önüne alındığında, bu veri kümesini ayırabilecek sonsuz sayıda hiper düzlem vardır. Ancak, bu düzlemler arasında maksimum sınıra sahip sadece bir hiper-düzlem bulunmaktadır (Sherrod, 2003; Çölkesen ve Kavzoğlu, 2008). Bu hiper-düzleme en uygun hiper-düzlem ve sınır genişliğini sınırlandıran noktalara ise destek vektörleri

adı verilir (Çölkesen ve Kavzoğlu, 2008).

DVM temelde doğrusal olarak ayırt edilebilen iki sınıflı problemlerin çözümünden yola çıkarak doğrusal olarak ayırt edilemeyen veya çoklu sınıf problemlerinin çözümü için genelleştirilebilir (Cortes and Vapnik, 1995; Çölkesen ve Kavzoğlu, 2008). Doğrusal olarak ayrılabilen iki sınıflı bir sınıflandırma probleminde DVM'nin eğitimi ele alınarak k sayıda örnekten oluşan eğitim verisinin $\{x_i, y_i\}$, $i = 1, \dots, k$, gibi olduğu kabul edilmiştir. Burada $x \in \mathbb{R}^N$ olup N-boyutlu bir uzayı, $y \in \{-1, +1\}$ ise sınıf etiketlerini göstermektedir. Eğer eğilim değeri (b) ve hiper-düzlemin normali (w) belirlenebilirse şekil 24(a)'da görüleceği üzere eğitim örnekleri doğrusal olarak ayrılabilir (Çölkesen ve Kavzoğlu, 2008).



Şekil 24. (a) Doğrusal olarak ayrılabilen veri setleri için hiper-düzlemin belirlenmesi, (b) Doğrusal olarak ayrılamayan veri setleri için hiper-düzlemin belirlenmesi (Çölkesen ve Kavzoğlu, 2008).

Şekilde en uygun hiper-düzleme paralel olan iki hiper-düzlem görülmektedir. Bu hiper-düzlemler $w \cdot x_i + b = \pm 1$, şeklinde bir fonksiyon ile tanımlanır. Dolayısıyla bu düzlemler arasındaki sınır $2/\|w\|$ kadar olur (Foody ve Mathur, 2004; Çölkesen ve Kavzoğlu, 2008). Bu durumda en uygun hiper-düzlemin belirlenmesi aşağıdaki sınırlı optimizasyon probleminin çözümünü gerektirir (Çölkesen ve Kavzoğlu, 2008).


$$\min \left[\frac{1}{2} \|w\|^2 \right] \quad (2.5)$$

Buna bağlı sınırlamalar ise

$$y_i (w \cdot x_i + b) - 1 \geq 0 \text{ ve } y_i \in \{1, -1\} \quad (2.6)$$

şeklinde olur (Çölkesen ve Kavzoğlu, 2008).

Seçilen örnek piksellerle uydu görüntüsünün sınıflandırılması gibi birçok sınıflandırma probleminde, veriler doğrusal olarak ayrılamaz. Bu tür problemler için (Cortes ve Vapnik, 1995) sınıf etiketi ile verilen eğitim verilerin en uygun hiper-düzlem ile aynı tarafta bulunmasını sağlamak için “arttıran yapay değişken” (ϕ_i) kullanılmaktadır (Şekil 24(b)). Bu durum için şekil 25’de görüleceği üzere girdi uzayında doğrusal olarak ayrılamayan veri daha yüksek boyutlu bir uzayda görüntülenir. Bu uzaya özellik uzayı denir (Çölkesen ve Kavzoğlu, 2008).



Şekil 25. Kernel fonksiyonu ile verinin daha yüksek bir boyuta dönüşümü (Çölkesen ve Kavzoğlu, 2008).

DVM formül (2.7)’deki gibi bir kernel fonksiyonu yardımıyla doğrusal olmayan dönüşümler yapılabilmekte ve bu şekilde verilerin yüksek boyutta doğrusal olarak ayrılabilmesine imkân sağlamaktadır (Vapnik, 1995; Gunn, 1998; Cristianini ve ark., 2000; Çölkesen ve Kavzoğlu, 2008). Sonuç olarak; doğrusal olarak ayrılamayan iki sınıflı bir problemde iki sınıfın birbirinden ayrılması ile ilgili karar kuralı (2.8) eşitliği şeklinde yazılabilir (Osuna ve ark., 1997; Çölkesen ve Kavzoğlu, 2008).

$$K(x_i, x_j) = \phi(x) \cdot \phi(j) \quad (2.7)$$

$$f(x) = \text{sign}[\sum \lambda_i y_i \phi(x) \cdot \phi(x_i) + b] \quad (2.8)$$

DVM modelleri tablo 4’te gösterildiği gibi doğrusal, polinom, radyal tabanlı fonksiyonlar ve sigmoidal kerneller olmak üzere dört temel gruba ayrılabilir. Lineer kernel, radyal tabanlı kernelin özel bir hali gibi düşünülebilir. Ayrıca, (Keerthi ve

Lın, 2003) sigmoid kernellerinin belirli parametreler için radyal tabanlı kerneller gibi davrandığını tespit etmiştir. Bazı çalışmalar, uzaktan algılama uygulamaları için radyal tabanlı çekirdeklerin en iyi sonuçları verdiğini belirtmektedir (Keerthi ve Lın, 2003; Melgani ve Bruzzone, 2004; Foody ve Mathur, 2004; Pal ve Mather, 2005) (Çölkesen ve Kavzoğlu, 2008).

Tablo 4. DVM için kullanılan kernel fonksiyonları (Çölkesen ve Kavzoğlu, 2008).

Kernel Fonksiyonu	Formül	Açıklama
Lineer Kernel	$K(x, y) = x \cdot y$	-
Polinom Kernel	$K(x, y) = ((x \cdot y) + 1)^d$	d, Polinom derecesi
Radyal Tabanlı Kernel	$K(x, y) = e^{-\gamma \ x - x_i\ ^2}$	γ , Gauss Kernelinin boyutu
Sigmoid Kernel	$K(x, y) = \tanh(b(x \cdot y) + r)$	b, r Kernel parametreleri

2.6 Görüntü Sınıflandırma Doğruluk Analizi

Sınıflandırma sonrası doğruluk analizi görüntü sınıflandırma sürecindeki en önemli adımlardan biridir. Buradaki amaç kullanılan sınıflandırma algoritmasının görüntüleri ne kadar doğru sınıflandırabildiğini ölçmektir. Elde edilen sınıflandırılmış görüntü doğru kabul edilen referans verilerle karşılaştırılarak doğruluk analizi yapılır. Referans veriler, önceden üretilmiş tematik görüntülerden, hava fotoğraflarından ve planlardan üretilebilir. Referans bir görüntünün daha önceden mevcut olması ile piksel piksel doğruluk analizi gerçekleştirilebilir. Ancak, referans verilerinin bu şekilde elde edilmesi çoğu zaman mümkün olmamaktadır. Bu sebeple sınıflandırma işleminin performansı, belli sayıda bilinen referans kontrol noktaları kullanılarak değerlendirilebilir. Bu referans noktalarının rastgele seçilmesine dikkat edilmelidir (Congalton, 1991; Güngör, 2019). Çünkü kapladıkları alana, kullanılan uydu görüntülerine ve sahip oldukları konumsal çözünürlüğe göre kullanılan referans noktalarının sayısı değişmektedir. Örneğin 30 metre konumsal çözünürlüğe sahip bir LANDSAT görüntüsünde 250 nokta yeterli olurken 2 metre konumsal çözünürlüğe sahip bir WV2 görüntüsünde bu sayı 750 - 1000'e çıkmaktadır (Güngör, 2019).

Sınıflandırma doğruluğunu bulmak için en sık kullanılan yöntemlerden biri hata matrisi yöntemidir. Bu yöntemde referans kontrol noktalarının sınıflandırılmış

görüntüdeki ve gerçekteki değerlerinin birbirleriyle tutarlı olup olmadığı ölçülür. Hata matrisi iki kritere göre oluşturulur: kullanıcı doğruluğu ve üretici doğruluğu. Üretici doğruluğu bir sınıfı test etmek için toplanan piksel topluluğundan kaç tanesinin doğru olarak sınıflandırıldığını ölçer. Örneğin, yol sınıfını test etmek için n adet referans piksel toplanmış olsun. Üretici doğruluğu bu n adet pikselden kaç tanesinin yol olarak sınıflandırıldığını gösterir. Kullanıcı doğruluğu ise kullanıcı tarafından üretilen tematik görüntünün doğruluğunu/güvenilirliğini ölçer. Bir başka deyişle tematik görüntüdeki bir pikselin sınıfının o pikselin yeryüzündeki sınıf değerine uyup uymadığını ölçer. Genel doğruluk, doğru sınıflandırılmış piksellerin toplam sayısının (yani köşegen toplamın) toplam referans piksel sayısına oranı olarak hesaplanır (Congalton, 1991; Güngör, 2019). Sonuç performansını karşılaştırmak için çoğunlukla kullanılan metriklerden olan Recall (R), Precision (PR) ve F1 skoru metrikleri kullanılır (Foto, 2022).

- Karışım matrisi (Confusion matrix) : Karışım matrisi, modelin performansını/başarısını gösteren bir matristir. Matristeki her hücre bir değerlendirme faktörünü temsil eder. Bu değerlendirme faktörleri gerçek değerler ve tahminler hakkında bilgi içermektedir. Karışım matrisi, bir NxN matrisidir. N, tahmin edilen sınıfların sayısıdır. Sınıflandırma tahminleri yapılırken dört tür sonuç ortaya çıkar (Yeşildal, 2022);

1. True Positives (TP): Modelin sayı olarak doğru tahmin ettiği pozitif sınıfların sayısını temsil eder. Başka bir deyişle, "gerçek pozitif" bir sayıdır.
2. True Negatives (TN): Modelin sayı olarak kaç tane negatif sınıfı doğru tahmin ettiğini ifade etmektedir. Bir diğer deyişle "Gerçek Negatif" sayısıdır.
3. False Positives (FP): Modelin sayı olarak kaç tane negatif sınıfı yanlış tahmin ettiğini ifade etmektedir. Bir diğer deyişle "Yanlış Pozitif" sayısıdır.
4. False Negatives (FN): Modelin sayı olarak kaç tane pozitif sınıfı yanlış tahmin ettiğini ifade etmektedir. Bir diğer deyişle "Yanlış Negatif" sayısıdır.

Tablo 4. Karşıtlık matrisi (Yeşildal, 2022).

	Tahmin Edilen Pozitif	Tahmin Edilen Negatif
Gerçek Pozitif	Gerçek Pozitif (TP)	Yanlış Negatif (FN)
Gerçek Negatif	Yanlış Pozitif (FP)	Gerçek Negatif (TN)

Sınıflandırma performansını değerlendirmek için kullanılan metrikler (Goutte ve Gaussier, 2005; Foto, 2022):

- PR: Pozitif tahmin edici olarak bilinen PR, veri kümesindeki tüm sınıfları ne kadar doğru tahmin ettiğini gösterir. Bu değer ne kadar yüksek olursa, tahmin o kadar doğru olur. Doğru sınıflandırma için %100'e yakın olması çok önemlidir. Denklem (2.9)'da PR denklemi verilmiştir (Foto, 2022).

$$PR = \frac{TP}{TP+FP} \quad (2.9)$$

- R: Bu metrikte, veri kümesindeki ortaya çıkan tüm pozitif sınıfları ne kadar iyi tahmin ettiğini ölçer. Bu sınıflandırma yüksek oranları hedeflemektedir. Denklem (2.10)'da R denklemi verilmiştir (Foto, 2022).

$$R = \frac{TP}{TP+FN} \quad (2.10)$$

- F1 Skoru: Sınıflandırma sonrası elde edilen PR ve R değerlerinin harmonik ortalamasıdır. Bu nedenle F1 skoru, PR ile R arasında dengeyi oluşturmak için hesaplanmaktadır. Denklem (2.11)'de F1 skoru denklemi verilmiştir (Foto, 2022).

$$F1 = \frac{2*(PR*R)}{PR+R} \quad (2.11)$$

3 BULGULAR VE SONUÇLAR


Bölüm 2’de bahsedilen BD, ÇÇA, VY, DÖ olmak üzere dört ana kategoriye ait pan-keskinleştirme yöntemleri ve bu yöntemlerin görüntü sınıflandırma sonuçları bu bölümde niteliksel ve niceliksel olarak değerlendirilecektir.

3.1 Pan-Keskinleştirilmiş Görüntülerin Nitel Değerlendirmesi


Tüm yöntemlerin spektral kalitesini, radyometrik özelliklerini görsel olarak incelemek için IKONOS ve WV2 uydularına ait ÇB görüntüleri ile pan-keskinleştirilmiş görüntüleri şekil 26 ve 27’de gösterilmiştir. Pan-keskinleştirilmiş görüntülerin tarafsız bir şekilde değerlendirilmesi için görüntülerde herhangi bir kontrast iyileştirmesi yapılmamıştır. Şekil 26’da konumsal özellik açısından bulanık görüntü oluşturan BD tabanlı yöntemler PRACS, C-GSA ve BDSD-PC yöntemleridir. BDSD-PC ve GS yöntemlerinde spektral kalite bakımından başarılı bir görüntü oluşturmuştur. Diğer BD tabanlı yöntemler ise tutarlı renkler üreterek ortalama sonuç vermiştir. ÇÇA tabanlı yöntemlerde C-MTF-GLB-CBD yöntemi dışındaki tüm görüntülerin spektral bilgisini belli bir düzeyde koruduğu söylenebilir. C-MTF-GLP-CBD, MTF-GLP-FS ve AWLP yöntemlerin sonuçları bulanıklık etkisine maruz kalmıştır. VY tabanlı yöntemlere gelince, TV ve SR-D sonuçlarının kaynak ÇB görüntüsüyle çok benzer renk özelliklerine sahip olduğu söylenebilir; PWMBF yöntemi ise diğer VY tabanlı yöntemlere göre daha başarısız sonuç görüntü üretmiştir. Ayrıca VY tabanlı yöntemler radyometrik özellikleri korumada başarılı olmuştur. Ancak, VY tabanlı TV ve FE-HPM yöntemleri görüntülerdeki bazı kenar detaylarını absorbe etmiştir. DÖ tabanlı yöntemlerden bahsedecek olursak MSDCNN ve DRPNN hariç, diğer tüm yöntemlerin bölgedeki ÇB görüntülerinin spektral özelliklerini korumada etkili olduğu görülmüştür. MSDCNN ve DRPNN'nin IKONOS görüntüsünün bazı bölümlerinde radyometrik özellikleri bozduğu tespit edilmiştir. DÖ tabanlı algoritmalar genel olarak keskin kenar detayları üretmiştir.

Şekil 27’de WV2 uydusuna ait pan-keskinleştirilmiş görüntüleri inceleyecek olursak ilk olarak BD tabanlı yöntemlerde PRACS yöntemi sonucunda spektral yapı korunmuştur fakat bulanık görüntü oluşmuştur. C-BDSD yöntemi ise konumsal olarak da spektral açıdan da başarısız sonuç vermiş ve diğer BD tabanlı yöntemler

alanı belirli bir dereceye kadar korumayı başardığını göstermiştir. Genel olarak BD tabanlı algoritmaların bu alanda yüksek radyometrik kalitede görüntüler ürettiği söylenebilir. Şekil 27'de görüldüğü gibi MF, MTF-GLP-HPM ve MTF-GLP-HPM-R dışındaki ÇÇA tabanlı algoritmalar gölgeli alanlarda kırmızımsı pikseller üretmiştir. Spektral yapı olarak kaynak ÇB görüntüsüne en yakın ÇÇA yöntemi MTF-GLP-HPM-H yöntemi olup netlik konusunda renk yapısı kadar başarılı değildir. Benzer şekilde, VY tabanlı FE-HPM tekniği de gölgeli alanlarda kırmızımsı pikseller üretirken, VY tabanlı TV algoritması hem radyometrik hem de konumsal açıdan tutarlı bir görüntü üretmiştir. Diğer VY tabanlı algoritmalar SR-D ve PWMBF yüksek spektral doğruluğa sahip görüntüler üretmiş ancak şekil 27'de de görüldüğü gibi nispeten daha az konumsal doğruluğa sahip görüntüler üretmiştir. DÖ tabanlı yöntemlerden bazılarının bu bölgede daha düşük performansa sahip olduğu gözlemlenmektedir. PNN, PNN-IDX, MSDCNN ve FUSIONNET teknikleri bu alanda global renk bozulmasına neden olmuştur. Yüksek spektral koruma performanslarına rağmen A-PNN, A-PNN-FT, DRPNN ve PANNET yaklaşımları bu bölgede konumsal özelliklerde bozulmaya yol açmıştır.



Şekil 26. Yöntemlerin IKONOS uydusuna ait pan-keskinleştirilmiş görüntüleri.



Şekil 27. Yöntemlerin WV2 uydusuna ait pan-keskinleştirilmiş görüntüleri.

3.2 Pan-Keskinleştirilmiş Görüntülerin Nicel Değerlendirmesi

Üretilen pan-keskinleştirilmiş görüntülerin kalitelerinin değerlendirilmesini sağlamak amacıyla bölüm 2’de bahsedilen istatistiksel hesaplamalara yer verilmiştir. Hesaplanan metrik değerleri tablo 5’te gösterilmektedir. Tablo 5’te tüm metrikler için her kategoride en başarılı yöntemler koyu yazı fontunda belirtilmiş olup en başarısız yöntemlerde italik olarak gösterilmiştir. Bu değerlerin sonuçlarına bakılacak olursa öncelikle kategori olarak bahsedilebilir.

BD tabanlı yöntemler arasında IKONOS uydusuna ait pan-keskinleştirilmiş görüntülerde en iyi D_s ve QNR değerlerine sahip yöntem C-BDSD yöntemi olup en iyi spektral ve konumsal kaliteyi elde etmiştir. Ancak, nispeten yüksek D_λ değerinin de gösterdiği gibi, bu yöntemin spektral özelliklerini koruma açısından çok iyi bir performans göstermediğini belirtmek gerekmektedir. PRACS yöntemi bir diğer en iyi sonucu veren metrik olmuştur. Üç kalite metriğini birden düşünürsek GS ve GSA yöntemleri bu BD tabanlı yöntemler içinde en kötü sonuçları veren yöntemler olmuştur. WV2 uydusunda ise tüm BD tabanlı yöntemler arasında PRACS’ın en yüksek QNR değerine sahip olduğu görülmektedir. Bununla birlikte, en düşük D_λ değerine de sahiptir, bu da ÇB’nin radyometrik özelliklerini etkili bir şekilde koruduğu anlamına gelmektedir. Öte yandan, C-BDSD yöntemi en düşük D_s değerine sahiptir ve bu değer diğer BD yöntemlerine kıyasla en net görüntüyü ürettiğini anlamına gelmektedir.

ÇÇA tabanlı yöntemler arasında IKONOS uydusuna ait pan-keskinleştirilmiş görüntülerde en iyi sonucu veren yöntemler C-MTF-GLP-CBD VE MTF-GLP-HPM-H yöntemleri olup spektral ve konumsal olarak başarılı bir pan-keskinleştirme gerçekleştirmiştir. C-MTF-GLP-CBD yöntemi aynı zamanda iyi spektral korumaya işaret eden düşük bir D_λ değeri üretirken MTF-GLP-HPM-H de QNR değeri ve D_λ değeri açısından tatmin edici bir performans göstermiştir. ÇÇA teknikleri arasında en başarısız yöntemler ise hem IKONOS hem de WV2 uydularına ait pan-keskinleştirilmiş görüntüler için de D_s konumsal metriği yüksek olan MF ve MTF-GLP yöntemleridir. D_λ spektral metriği zayıf olan yöntemler IKONOS uydusu için MTF-GLP ve MTF-GLP-HPM yöntemi olup WV2 uydusu için MF ve MTF-GLP-HPM yöntemleridir. QNR metriği için ise IKONOS uydusunda MTF-GLP yöntemi, WV2 uydusunda MTF-GLP-HPM yöntemi en zayıf sonuçları elde etmiştir.

VY tabanlı yöntemler arasında her iki uydu için en iyi sonucu veren yöntem SR-D yöntemidir, bu da; bu çalışmada karşılaştırılan tüm VY tabanlı yöntemler arasında en düşük D_λ ve D_s değerlerini elde ederek radyometrik ve konumsal yapı kalitesini korumada oldukça etkili olduğunu göstermiştir. VY kategorisindeki tüm yöntemler arasında en zayıf yöntem ise IKONOS uydusunda PWMBF yöntemidir. WV2 uydusunda en zayıf yöntem ise FE-HPM yöntemidir. Bu iki en başarısız yöntem en yüksek D_s değerine sahiptir ve bu da sonuç görüntülerinin konumsal bozulmaya neden olduğunu gösterir.

DÖ tabanlı yöntemlerde ise IKONOS uydusuna ait pan-keskinleştirilmiş görüntülerde PANNET'in en yüksek QNR değerine sahip olduğunu ve onu A-PNN-FT yönteminin takip ettiği görülmektedir. PANNET yöntemi tüm DÖ yöntemleri arasında en düşük D_λ değerine sahiptir bu da ÇB'nin radyometrik özelliklerini diğer DÖ yöntemlerinden daha iyi koruduğunu göstermektedir. Ancak PANNET yönteminde D_s değeri bazı yöntemlere bakarak daha yüksek sonuç elde etmiştir. Bu durum PANNET'in yüksek konumsal detay içeriği gerektiren uygulamalar için en uygun yöntem olmayabileceğini göstermektedir. DRPNN ve MSDCNN'nin diğer DÖ yöntemlerine kıyasla nispeten daha düşük QNR değerlerine sahip olduğu görülmüş, bu da genel performans açısından en etkili yöntemler olmayabileceklerini göstermiştir. WV2 uydusuna ait pan-keskinleştirilmiş görüntülerde A-PNN-FT yönteminin en yüksek QNR değerine sahip olduğu görülmektedir. Ayrıca, A-PNN-FT yönteminin sonucu D_λ endeksi açısından en düşük değere ve D_s endeksi açısından ikinci en düşük değere sahiptir; bu da radyometrik özellikleri koruduğunu ve kaynak ÇB görüntü verilerinin konumsal doğruluğunu yüksek bir başarıyla artırdığını göstermektedir. A-PNN yöntemi de QNR değeri ile iyi bir performans sergilemiştir. PANNET ve FUSIONNET yöntemlerinin sonuçları ise QNR metriği ile yakın bir değer elde etmiştir. En başarısız sonuçlar ise PNN, PNN-IDX, MSDCNN ve DRPNN yöntemleri olup diğer dört yöntemle kıyasla daha düşük QNR değeri elde etmiştir. Ayrıca pan-keskinleştirme işlemi özellikle klasik yöntemler MATLAB yazılımında işlenmiş olup diğer yöntemler DÖ tabanlı PHYTON yazılımında uygulanmıştır. Pan-keskinleştirme sonucunda yöntemlerin birbirleriyle karşılaştırılması için hesaplanan metrikler ise MATLAB yazılımında hesaplanmış olup sınıflandırma işlemine geçilmiştir.

Tablo 5. Pan-keskinleştirme kalite metrik değerleri.

KATEGORİ	YÖNTEM	IKONOS			WV2		
		D _s	D _λ	QNR	D _s	D _λ	QNR
BD	PRACS	0.0981	0.0569	0.8506	0.0528	0.0405	0.9089
	GS	0.1977	0.1819	0.6564	0.0904	0.2002	0.7276
	GSA	0.1989	0.1207	0.7044	0.1598	0.1418	0.7211
	C-GSA	0.1452	0.0910	0.7770	0.1366	0.0942	0.7821
	BDS	0.1338	0.1174	0.7645	0.0726	0.2066	0.7358
	C-BDS	0.0331	0.0973	0.8728	0.0287	0.1675	0.8086
	BDS-PC	0.1354	0.1157	0.7646	0.1052	0.1391	0.7703
	BT-H	0.1408	0.0730	0.7965	0.0880	0.0535	0.8632
ÇÇA	AWLP	0.1644	0.0325	0.8085	0.1134	0.0382	0.8527
	MF	0.1736	0.0509	0.7843	0.1542	0.1194	0.7448
	MTF-GLP	0.1911	0.0575	0.7624	0.1606	0.0755	0.7760
	MTF-GLP-FS	0.1714	0.0459	0.7906	0.1249	0.0537	0.8281
	C-MTF-GLP-CBD	0.1059	0.0319	0.8656	0.0911	0.0298	0.8818
	MTF-GLP-CBD	0.1701	0.0453	0.7923	0.1261	0.0556	0.8254
	MTF-GLP-HPM	0.1696	0.0571	0.7829	0.1255	0.1584	0.7360
	MTF-GLP-HPM-H	0.1227	0.0295	0.8515	0.0728	0.0231	0.9058
	MTF-GLP-HPM-R	0.1579	0.0367	0.8112	0.1140	0.1113	0.7874
VY	TV	0.0811	0.0284	0.8928	0.0563	0.0651	0.8823
	SR-D	0.0554	0.0159	0.9295	0.0267	0.0111	0.9625
	PWMBF	0.2213	0.1078	0.6947	0.1406	0.0825	0.7885
	FE-HPM	0.1652	0.0453	0.7970	0.1568	0.1156	0.7457
DÖ	PNN	0.0373	0.0358	0.9283	0.1016	0.2635	0.6617
	PNN-IDX	0.0287	0.0367	0.9357	0.1055	0.2250	0.6933
	A-PNN	0.0387	0.0250	0.9372	0.0262	0.0698	0.9058
	A-PNN-FT	0.0207	0.0235	0.9563	0.0322	0.0424	0.9267
	PANNET	0.0225	0.0186	0.9593	0.0501	0.0889	0.8655
	MSDCNN	0.0266	0.0802	0.8954	0.0999	0.3227	0.6096
	DRPNN	0.0269	0.1050	0.8709	0.1254	0.1295	0.7613
	FUSIONNET	0.0198	0.0350	0.9459	0.0576	0.1354	0.8148

3.3 Pan-Keskinleştirme Yöntemlerinin İşlem Süreleri

Kullanılacak en uygun pan-keskinleştirme yönteminin belirlenmesinde zaman verimliliği önemli bir kriter olarak ele alınabilir. Bu sebeple, bu çalışmada kullanılan her pan-keskinleştirme yönteminin ortalama işlem süresi tablo 6'da verilmiştir. İşlem süresinin yalnızca kullanılan pan-keskinleştirme yönteminin karmaşıklığına değil, aynı zamanda sistem konfigürasyonuna da bağlı olduğuna dikkat edilmesi gerekir. Bu da, işlem sürelerinin sistemden sisteme değiştiğini gösterir. Öte yandan, DÖ tabanlı yöntemlerin pan-keskinleştirilmiş görüntüleri üretmesi çok fazla zaman almamıştır. Çünkü DÖ tabanlı yöntemlerin eğitim sürecinden dolayı çok daha uzun sürmesi beklenirken, bu çalışmada tüm DÖ tabanlı yöntemlerde önceden eğitilmiş modeller kullanıldığı için eğitim gerçekleştirilmemiştir. Eğitimin yapılmaması, DÖ tabanlı yöntemler için işlem süresinde önemli bir azalmaya yol açmıştır (Yılmaz ve ark., 2022).

Tablo 6'da görüldüğü üzere en yüksek işlem süresi IKONOS uydu görüntüsünde PNN yöntemi, WV2 uydu görüntüsünde ise TV yöntemidir. En kısa işlem süresi iki uydu görüntüsü içinde BD tabanlı yöntemlerden olan GS yöntemidir. Her iki uydu görüntüsünde de DÖ tabanlı yöntemlerin işlem süreleri, diğer yöntemlere oldukça yakın sonuçlar vermiştir.

Tablo 6. Kullanılan pan-keskinleştirme yöntemlerinin ortalama işlem süreleri.

KATEGORİ	YÖNTEM	IKONOS	WV2
		Ortalama işlem süresi (sn)	Ortalama işlem süresi (sn)
BD	PRACS	0.35	0.44
	GS	0.11	0.08
	GSA	0.30	0.16
	C-GSA	0.90	1.09
	BDS	0.50	0.15
	C-BDS	3.21	1.69
	BDS-PC	2.04	0.25
	BT-H	0.79	0.09
ÇÇA	AWLP	0.30	0.43
	MF	0.52	0.37
	MTF-GLP	0.25	0.42
	MTF-GLP-FS	0.17	0.27
	C-MTF-GLP-CBD	0.56	2.13
	MTF-GLP-CBD	0.15	0.27
	MTF-GLP-HPM	0.27	0.43
	MTF-GLP-HPM-H	0.23	0.30
	MTF-GLP-HPM-R	0.15	0.28
VY	TV	1.53	16.0
	SR-D	2.60	5.72
	PWMBF	1.28	0.63
	FE-HPM	0.92	1.07
DÖ	PNN	20.2	14.4
	PNN-IDX	1.32	2.35
	A-PNN	1.34	1.50
	A-PNN-FT	15.9	8.38
	PANNET	6.11	1.60
	MSDCNN	1.57	1.66
	DRPNN	1.62	1.91
	FUSIONNET	1.97	1.76


3.4 Sınıflandırılmış Görüntülerin Değerlendirilmesi

Şekil 28’de iki uydu görüntülerine ait özellik sınıflarını gösterirken şekil 29 ve 30’da elde edilen sınıflandırılmış görüntüleri göstermektedir. Burada tek tek her yöntemin sınıflandırma performansını değerlendirmek için görüntüler sıralanmıştır. Sınıflandırılmış görüntüler sonucunda hesaplanan PR, R ve F1 değerleri tablo 7’de verilmiştir. Ayrıca tablo 7’de tüm metrikler için her kategoride en başarılı yöntemler koyu yazı fontunda belirtilmiş olup en başarısız yöntemlerde italik olarak

gösterilmiştir. IKONOS uydu görüntüsü için sadece iki BD tabanlı algoritma PRACS ve C-BDSD her üç ölçüt içinde iyi performans sergilerken diğer BD tabanlı algoritmalar tüm ölçütler için ÇB'ye kıyasla daha düşük değerlerle sonuçlanmıştır. Genel olarak IKONOS uydu görüntüsündeki yöntemlerde bina ve yol sınıflarının birbirlerine karıştığı, yol sınıfı ile gösterilmesi gereken çoğu yerde bina sınıfı olarak gösterildiği ve bunun sonucunda görsel olarak başarısız sonuç elde edildiği saptanmaktadır. PR, R ve F1 skoru için en düşük değerleri veren yöntem de GS yöntemi olmuştur. ÇÇA kategorisinde, en başarılı yöntem C-MTF-GLP-CBD yöntemi olup her üç ölçütte de yüksek performans sergilemiştir. MTF-GLP-FS, MTF-GLP-CBD ve MTF-GLP-HPM-R yalnızca PR ve F1 değerlerini iyileştirmiştir. Diğer yöntemler başarı ölçütlerinin altında kalmıştır, bunlardan biri ise MTF-GLP yöntemidir. VY tabanlı yöntemler de genel olarak başarılı ölçütler vermektedir. İstisna olarak PWMBF yöntemi gösterilebilir. Ayrıca bu kategorideki FE-HPM algoritması yalnızca PR ve F1 değerlerini iyileştirmiştir. DÖ tabanlı yöntemlerde VY tabanlı yöntemler gibi diğer yöntemlere kıyasla tüm sınıfların birbirlerinden ayrılabilmesinde daha başarılı olmuşlardır. DÖ tabanlı yöntemlerin istisnası olarak DRPNN yöntemi gösterilebilir. PR ve F1 değeri için DRPNN yöntemi DÖ tabanlı yöntemler arasında en düşük sonucu üretmiştir. DÖ kategorisindeki pan-keskinleştirme yöntemleri IKONOS uydu görüntüsünde diğer kategorilerdeki yöntemlerden daha iyi performans göstermiştir.


Tablo 7'de, BD tabanlı algoritmaların WV2 uydu görüntüsünde PR, R ve F1 değerlerini iyileştirmede başarılı olamadığını göstermektedir. Ancak, BD tabanlı GSA, PRACS ve BDSD-PC algoritmaları bu bölgedeki PR değerlerini iyileştirebilmiştir. En başarısız sonucu ise IKONOS uydusunda olduğu gibi GS yöntemi vermiştir. Burada da genel olarak tüm görüntülerde toprak zemin ve asfalt yol sınıfları birbirleriyle karışmaktadır. MTF-GLP-HPM-H hariç ÇÇA tabanlı algoritmaların çoğu, kaynak ÇB görüntü verilerine kıyasla daha düşük PR, R ve F1 değerleriyle sonuçlanmıştır. MTF-GLP-HPM-H yöntemi de ÇÇA'nın en başarılı yöntemi olsa da ÇB görüntüsünden düşük değerler elde etmiştir. MTF-GLP-FS ve MTF-GLP-HPM-R bu bölgede R değerini iyileştirebilmiştir. VY kategorisinde yalnızca SR-D algoritması her üç ölçütü de iyileştirmiştir. Diğer VY tabanlı algoritmalar PR, R ve F1 için daha düşük değerler vermiştir. DÖ tabanlı yöntemlerde

ise A-PNN, A-PNN-FT ve PANNET hariç tüm DÖ tabanlı algoritmalar, WV2'de kaynak ÇB görüntü verilerinden daha düşük PR, R ve F1 değerleri üretmiştir. En başarısız sonucu ise MSDCNN yöntemi vermektedir. Tüm yöntemler arasında MSDCNN yöntemi PR ve F1 için en düşük değeri üretmiştir. IKONOS uydusuna ait sınıflandırılmış görüntülerin WV2 uydusuna ait sınıflandırılmış görüntülere göre daha çok birbirleriyle karıştırıldığı saptanmıştır.




Şekil 28. IKONOS uydusuna ait görüntünün sınıfları (solda), WV2 uydusuna ait görüntünün sınıfları (sağda).

Ayrıca sınıflandırma işleminin genel doğruluğu, pan-keskinleştirilmiş her görüntü için 600 referans noktası kullanılarak belirlenmiştir. Öncelikle DVM sınıflandırma yöntemi ENVI programında gerçekleştirilmiş olup doğruluk analizi ERDAS IMAGINE programında uygulanmıştır. PR, R ve F1 değeri yapay zekâ yardımıyla PHYTON yazılımı kullanılarak hesaplanmıştır.



Şekil 29. Yöntemlerin IKONOS uydusuna ait sınıflandırma görüntüleri.



Şekil 30. Yöntemlerin WV2 uydusuna ait sınıflandırma görüntüleri.

Tablo 7. Görüntü sınıflandırma kalite metrik değerleri.

KATEGORİ	YÖNTEM	IKONOS			WV2		
		PR	R	F1	PR	R	F1
	Kaynak ÇB	0.898	0.908	0.902	0.933	0.930	0.933
BD	PRACS	0.906	0.914	0.906	0.938	0.927	0.933
	GS	0.868	0.880	0.870	0.907	0.888	0.897
	GSA	0.874	0.890	0.880	0.937	0.903	0.920
	C-GSA	0.878	0.890	0.880	0.932	0.922	0.925
	BDS	0.888	0.892	0.890	0.927	0.913	0.913
	C-BDS	0.906	0.916	0.908	0.933	0.928	0.930
	BDS-PC	0.890	0.908	0.896	0.940	0.926	0.931
	BT-H	0.882	0.890	0.886	0.925	0.918	0.920
ÇÇA	AWLP	0.894	0.900	0.896	0.927	0.909	0.917
	MF	0.898	0.898	0.898	0.919	0.916	0.916
	MTF-GLP	0.886	0.890	0.888	0.925	0.913	0.918
	MTF-GLP-FS	0.900	0.908	0.906	0.920	0.937	0.922
	C-MTF-GLP-CBD	0.906	0.912	0.910	0.937	0.925	0.930
	MTF-GLP-CBD	0.912	0.898	0.904	0.907	0.925	0.913
	MTF-GLP-HPM	0.882	0.896	0.890	0.905	0.907	0.903
	MTF-GLP-HPM-H	0.896	0.896	0.896	0.937	0.945	0.942
	MTF-GLP-HPM-R	0.906	0.908	0.906	0.918	0.940	0.928
VY	TV	0.912	0.918	0.914	0.918	0.938	0.923
	SR-D	0.920	0.942	0.930	0.962	0.962	0.960
	PWMBF	0.882	0.894	0.884	0.915	0.922	0.917
	FE-HPM	0.908	0.906	0.910	0.927	0.898	0.912
DÖ	PNN	0.904	0.912	0.908	0.904	0.917	0.910
	PNN-IDX	0.906	0.918	0.912	0.892	0.913	0.898
	A-PNN	0.914	0.932	0.920	0.957	0.941	0.951
	A-PNN-FT	0.934	0.930	0.930	0.957	0.953	0.957
	PANNET	0.918	0.934	0.920	0.946	0.947	0.944
	MSDCNN	0.912	0.920	0.918	0.875	0.918	0.895
	DRPNN	0.884	0.922	0.898	0.912	0.928	0.918
	FUSIONNET	0.916	0.932	0.922	0.913	0.932	0.920

4 TARTIŞMA VE SONUÇ

Bu tez çalışmasında, birçok klasik ve güncel pan-keskinleştirme yöntemlerinin performansları IKONOS ve WV2 uydu görüntüleri üzerinde incelenmiştir. Ayrıca tüm yöntemler DVM sınıflandırma yöntemiyle sınıflandırılmıştır. Sınıflandırma uygulamalarında pan-keskinleştirilmiş görüntüler kullanılmaktadır. Buna bağlı olarak, görüntü sınıflandırmasının doğruluğu büyük ölçüde kullanılan pan-keskinleştirme yönteminin performansına bağlıdır. Çalışmada 29 farklı pan-keskinleştirme yönteminden faydalanılmıştır. Pan-keskinleştirme ve sınıflandırma işlemlerinin performansı niteliksel ve niceliksel olarak değerlendirilmiştir. Bu değerlendirmeler iki uydu görüntüsünde de tam ölçekte gerçekleştirilmiştir. Metrikler sonucunda bazı yöntemlerin nitel ve nicel sonuçları arasında tutarsızlıklar meydana gelmiştir. Bu tutarsızlıklar birçok farklı nedenlerden meydana geldiği gibi her yöntemde kendine göre avantajları ve dezavantajları vardır.

BD tabanlı pan-keskinleştirme yöntemleri renk bozulması pahasına daha keskin görüntüler üretmiştir. Uygulamasının kolay ve hızlı olması avantajları arasında yer almaktadır. ÇÇA tabanlı yöntemler, BD tabanlı yöntemlere kıyasla daha iyi bir spektral koruma performansı sunmuştur. Bunun başlıca nedeni (Yılmaz ve ark., 2022)'da belirttiği üzere ÇÇA tabanlı yöntemlerin kaynak PAN verilerinin yalnızca yüksek frekans bileşenlerini enjekte etmesidir; BD tabanlı teknikler ise tüm frekans bileşenlerini kullanır. Ayrıca VY tabanlı yöntemler yüksek spektral ve konumsal kalitede görüntüler üretirken bazı VY tabanlı yöntemler, ince ayarı zor olan parametreler kullanır ve nispeten yavaştır. Üstelik (Vivone ve ark, 2020)'da VY yöntemlerinin hem hesaplama süresi hem de performans açısından hiperparametrelerin seçimine çok duyarlı olduğu belirtilmektedir. Buna göre, genellikle gerçek potansiyellerini gizleyebilecek doğru bir optimizasyon aşaması gerektirmektedirler. Bu nedenle, iyi hiperparametrelerin seçilmesi sorunu hızlı bir şekilde çözülsün VY yöntemleri pratik hale gelebilmektedir (Vivone ve ark, 2020). DÖ tabanlı yöntemlerin avantajlarına bakacak olursak; önceden eğitilmiş modeller kullanılıyorsa hızlı olması, yüksek spektral ve konumsal kalitede görüntüler üretmesi denebilir. Donanım talep etmesi ve eğitim için çok miktarda örnek görüntü gerektirmesi başlıca dezavantajlarıdır. Üstelik pan-keskinleştirme performansı büyük

ölçüde eğitimin başarısına ve kullanılan hiperparametrelere bağlıdır (Yılmaz ve ark., 2022).

Değerlendirme yapacak olursak BD tabanlı yöntemlerin test alanlarında sınıflandırma performansı açısından ortalamanın altında kaldığı pan-keskinleştirme sonuçlarından elde edilen metrik değerleri ile ortaya koyulmaktadır. Bu yöntemler arasında istisna olan yöntemler de bulunmaktadır; PRACS, BT-H, C-BDSD. PRACS yönteminin PAN görüntüsünün bazı piksellerini ÇB bileşen görüntüsü ile değiştirerek kısmi yer değiştirme işlemi uygulaması bu yöntemin performansını olumlu yönde etkilediğini göstermektedir. Ayrıca C-BDSD yöntemi IKONOS uydu görüntüsünde PR, R ve F1 metrik değerleri açısından en yüksek değeri üretmiştir. BDSD ve BDSD-PC yöntemi C-BDSD yönteminden daha düşük performans göstermiştir. Üstelik BDSD yöntemi WV2 uydu görüntüsünde daha düşük metrik değerleri üretmiştir. (Yılmaz ve ark., 2022) bahsettiği gibi BDSD tekniği dört ÇB görüntü bandına sahip kaynak görüntülerle iyi bir çözüm sunmaktadır. Fakat daha fazla ÇB görüntü bandı olduğunda, çözülmesi gereken parametreler artar ve bazı pan-keskinleştirme sorunlarına yol açabilmektedir. En düşük performansı da GS yöntemi vermiştir. GS yönteminin kaynak görüntülerin istatistiksel özelliklerini yeterince koruyamaması düşük sonuçlar vermesine sebep olmuştur. Ayrıca, GS yöntemi aynı zamanda kaynak görüntüler arasındaki ölçek oranına da bağlı olduğu tespit edilmiştir. Ölçek farkları, pan-keskinleştirme işleminin doğruluğunu ve keskinliğini olumsuz etkileyebilmektedir (Yılmaz ve ark., 2022). BT-H yönteminin pan-keskinleştirme algoritmasında her bir renkli bantta bulunan yol parlaklığını tahmin ederek görüntüden çıkarması görüntünün kalitesini artırarak başarılı sınıflandırma sonuçları oluşturmuştur.

ÇÇA tabanlı yöntemlerinde C-MTF-GLP-CBD ve MTF-GLP-HPM-H yöntemleri başarılı PR, R ve F1 metrik değeri üretmiştir. MTF-GLP-HPM-H yönteminin BT-H yöntemi gibi pus düzeltme ve C-MTF-GLP-CBD yönteminin k-means kümeleme yaklaşımı bu yöntemlerin performansına önemli bir katkı sağlamıştır. Niteliksel ve niceliksel değerlendirme sonucunda, MTF-GLP tabanlı yöntemlerin test bölgelerinde genellikle iyi bir spektral doğruluk ve zayıf konumsal ayrıntı kalitesi elde etmiştir. Bu yöntemlerin renk koruma performansında (Vivone ve ark., 2022) bahsettiği gibi sensörlerin MTF'sini kullanmasının önemli bir avantaj olduğunu belirtmiştir. Ayrıca

AWLP yönteminin neden olduğu önemli miktarda spektral ve konumsal yapı bozulması, bu yöntemin kaynak PAN verileri ile IHS dönüşümü yoluyla hesaplanan yoğunluk verileri arasında bir histogram eşleştirmesi gerçekleştirmesinden kaynaklandığı tespit edilmiştir (Vivone ve ark., 2022).

Geleneksel yöntemler arasında ise en yüksek performansı VY tabanlı yöntemlerden olan SR-D yöntemi elde etmiştir. WV2 uydu görüntüsünde SR-D yöntemi sınıflandırma performansı olarak en yüksek değeri üretmiştir. Bu da görüntü özelliklerini korumadaki başarısını gösterir. SR-D yöntemi (Vivone ve ark., 2020) bahsettiği gibi seyrek temsilde kullanılan görüntü benzerliği sayesinde genel olarak çok iyi bir performans göstermektedir. Bu da VY sınıfındaki bazı yöntemlerin BD ve ÇÇA yöntemlerine göre daha yüksek doğrulukla hesaplama gücü elde ederek en son teknolojiye eşdeğer performans elde ettiğini göstermektedir. TV yöntemi SR-D yönteminden sonra pan-keskinleştirme ve sınıflandırma performansı açısından başarılı sonuçlar üretmiştir. TV yöntemi görüntü yamalarına ihtiyaç duymadan tüm görüntüler üzerinde işlem yapmaktadır. Bu da hesaplama yoğunluğunu ortadan kaldırarak test alanlarında verimli bir şekilde kullanılmasını sağlar. FE-HPM yöntemi, spektral açıdan daha başarılı bir yöntemdir. (Vivone ve ark., 2020) bahsettiği gibi MTF tabanlı MRA teknikleriyle karşılaştırılabilmektedir ancak sistematik olarak daha iyi olmayan sonuçlar gösterir, bu da sensör modelinin veya sistem parametrelerinin tam olarak uyuşmadığı durumlardan kaynaklanabilmektedir. PWMBF yöntemi diğer VY tabanlı yöntemler arasında en başarısız sonuç üreten yöntemlerden biridir. Bu, diğer VY yöntemlerine göre biraz daha fazla spektral ve konumsal bozulmayla ilişkilendirilebilir. Yöntem PCA dönüşümünü gözlem modeline dâhil eder. Yöntemin başarısız sonuçlar vermesi PCA'nın veriyi yeterince iyi temsil edemediğini veya dönüşümün yetersiz olduğunu göstermektedir.

DÖ tabanlı yöntemlerde ise IKONOS uydu görüntüsünde A-PNN-FT ve PANNET yöntemleri en iyi genel performansı vermektedir. Ayrıca A-PNN-FT yöntemi sınıflandırma performansı açısından da en başarılı olanıdır. Bu da demek oluyor ki ince ayar algoritması sayesinde, A-PNN-FT diğer DÖ yöntemlerinden daha iyi bir ağ performansına sahiptir. Üstelik sonuçlara bakılırsa kullanılan DÖ tabanlı yöntemlerde L1 kayıp fonksiyonunun L2 kayıp fonksiyonundan daha etkili olduğu görülmektedir. DÖ tabanlı yöntemler arasında hem pan-keskinleştirme hem de

sınıflandırma açısından en başarısız yöntem DRPNN yöntemidir. DRPNN'nin mimarisi bir atlama bağlantısı içerir ve 11 katmana sahiptir, bu nedenle daha iyi bir özellik çıkarma yeteneğine sahiptir. Fakat sonuçlara bakılırsa DRPNN yönteminin karmaşık ağ yapısına sahip olması nedeniyle hiperparametre ayarlaması ve optimize edilmesi karmaşık olabilmektedir, bu da DRPNN yönteminin başarılı sonuçlar vermesini zorlaştırabilmektedir (Deng ve ark., 2020). Genel olarak 4 bantlı IKONOS uydu görüntüsünde daha yüksek performans sergilenmiştir. Ayrıca A-PNN, A-PNN-FT ve PANNET algoritmaları, her iki uydu görüntüsünde de PR, R ve F1 değerlerini iyileştirmiştir. WV2 uydu görüntüsünde de paralel olarak A-PNN-FT, PANNET ve SR-D yöntemleri en başarılı yöntemlerdir. DÖ tabanlı yöntemler için de hem pan-keskinleştirme hem de sınıflandırma açısından en başarısız yöntem MSDCNN yöntemidir. (Deng ve ark., 2022)'nin de bahsettiği gibi MSDCNN yönteminde diğer bir adıyla "derin dal" olan çok ölçekli işlem dışında, diğer dalda üç basit konvolüsyon katmanı kullanılarak "sığ" özellikler elde edilir ve bundan yola çıkarak sığ dalda bulunan basit konvolüsyon katmanlarının gerekli olmayacağını, bu katmanların ağ çıkışlarını fazlasıyla esnek hale getirerek, derin ve sığ özelliklerin öğrenilmesinde belirsizliğe neden olacağı düşünülmektedir. Bu da MSDCNN yönteminin çok bantlı görüntülerde performansının düşmesine sebep olabilmektedir. Ayrıca, (Xu ve ark., 2020) tarafından da belirtildiği gibi MSDCNN yöntemi girdi verilerini oluşturmak için kaynak PAN görüntüsünü kaynak ÇB görüntü bantlarıyla birleştirir; bu da kaynak ÇB ve PAN görüntülerinin ayırt edici özelliklerini göz ardı etmektedir. Bu, kaynak ÇB ve PAN görüntülerinin farklı sensörler tarafından elde edildiği durumlar için büyük bir dezavantaj olabilmektedir (Yılmaz ve ark., 2022). PANNET en iyi DÖ tabanlı yaklaşımlarından biridir bu da iyi bir ağ performansı gösterdiği anlamına gelir. (Deng ve ark., 2022)'da bahsettiği gibi bunun nedeni, yalnızca yüksek frekanslı bilgiler üzerinde gerçekleştirilen ağ eğitimi ile ilgili olabilmektedir. Ayrıca bazı DÖ tabanlı yaklaşımlar geleneksel yöntemlerden daha düşük sonuçlar vermektedir çünkü DÖ tabanlı yöntemler pratikte farklı eğitim örnekleri üzerinde eğitilmektedir. WV2 uydu görüntüsünde tüm teknikler arasında en kötü sonucu elde eden PNN yöntemidir; bunun nedeni sadece nispeten küçük boyutu değil, büyük olasılıkla ağı yeni veri setlerinde spektral bozulmaya eğilimli hale getiren artık modüllerin (atlama bağlantıları) eksikliğidir. Ayrıca (Deng ve ark., 2020) bahsettiği gibi PNN mimarisi, herhangi bir atlama bağlantısı olmayan basit bir

3 katmanlı ağ yapısına sahiptir, bu nedenle basit ağdan yeterli görüntü özellikleri çıkarmak da kolay olmamaktadır. Bir atlama bağlantısının (A-PNN) eklenmesinden ve bir ince ayar stratejisinin uygulanmasından sonra, ağ (yani A-PNN-FT) daha iyi sonuçlar elde edebilmektedir. FUSIONNET yöntemi ise IKONOS uydusunda daha başarılı olup WV2 uydusunda ortalamanın üstünde kalarak başarılı sonuç vermiştir. Bu yöntem (Deng ve ark., 2022) bahsettiği gibi PNN gibi düz konvolüsyon katmanlarından oluştuğu için (hatta atlamalı bağlantı ile) yüksek geçerlilik özelliği açısından PANNET ve A-PNN-FT'ye göre daha zayıftır.

Sonuç olarak bu tez çalışmasında elde edilen sonuçlar DÖ yöntemlerinin pan-keskinleştirme ve sınıflandırma performansında önemli bir başarı elde ettiği ve bundan sonraki çalışmalarda önemli bir araç olabileceğini göstermektedir. Ayrıca DÖ yöntemlerinde kullanılan modellerin daha uygun eğitim verileri ile eğitilerek daha başarılı sonuçlar verebileceğininde altını çizmek gerekir.

Teşekkür

Bu çalışmada kullanılan çoğu pan-keskinleştirme yönteminin Matlab kodlarını sağladığı için (Vivone ve ark., 2020)'ye (<https://openremotesensing.net/>) ve tüm DÖ tabanlı yöntemlerin phyton versiyonunu paylaştığı için (Deng ve ark, 2022)'ye (<https://github.com/liangjiandeng/DLPan-Toolbox>) teşekkür ederim. Bu çalışmada kullanılan görüntüleri sağlayan Karadeniz Teknik Üniversitesi, Harita Mühendisliği Bölümü'ne ve araştırmalarım çerçevesinde makale erişimi sunduğu için Artvin Çoruh Üniversitesi Lisansüstü Eğitim Enstitüsü'ne en içten teşekkürlerimi sunarım.

KAYNAKÇA

- Abas, İ.A., 2011. Çok spektrallı görüntü füzyonu, Yüksek Lisans Tezi, Konya Selçuk Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı, Konya.
- Aggarwal, C. C., 2018. Neural networks and deep learning, 1st Edition, Springer Nature.
- Aiazzi, B., Alparone, L., Baronti, S. and Garzelli, A., 2002. Context driven fusion of high spatial and spectral resolution images based on oversampled multiresolution analysis, *IEEE Trans. Geosci. Remote Sens.*, vol. 40, no. 10, pp. 2300±2312.
- Aiazzi, B., Alparone, L., Baronti, S., Garzelli, A. ve Selva, M., 2006. MTF-tailored multiscale fusion of high resolution MS and Pan imagery, *Photogrammetric Engineering Remote Sensing*, 72(5) 591–596.
- Aiazzi, B., Baronti, S. ve Selva, M., 2007. Improving component substitution pansharpening through multivariate regression of MS+PAN data, *IEEE Transactions on Geoscience and Remote Sensing*, 45 (10) (2007) 3230-3239.
- Akoğuz, A., 2013. Uzaktan algılamada görüntü birleştirme algoritmalarının Karşılaştırılması, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen bilimleri Enstitüsü, İstanbul.
- Alaloul, W. S. ve Qureshi, A. H., 2020. Data processing using artificial neural networks. In: D. G. Harkut, Editor, “Dynamic data assimilation-beating the uncertainties”, London, UK: IntechOpen.
- Alparone, L., Aiazzi, B., Baronti, S., Garzelli, A., Nencini, F. ve Selva, M., 2008. Multispectral and panchromatic data fusion assessment without reference. *Photogrammetric Engineering & Remote Sensing*, 74(2), pp.193-200.
- Alparone, L., Wald, L., Chanussot, J., Thomas, C., Gamba, P. ve Bruce, L.M., 2007. Comparison of pansharpening algorithms: Outcome of the 2006 GRS-S datafusion contest, *IEEE Transactions on Geoscience and Remote Sensing*, 45 (10) (2007) 3012–3021.
- America, N. E. C. L. ve Nj, P., 2010. Large-scale machine learning with stochastic gradient descent (SGD), *Proceedings of COMPSTAT'2010*, pp. 3–4., 10.1007/978-3-7908-2604-3.
- Arunava, 2018. «Convolutional Neural Network», Available: <https://towardsdatascience.com/convolutional-neural-network-17fb77e76c05> (18 Şubat 2023, 11:30).
- Ayhan, E., Karşlı, F. ve Tunç E., 2003. Uzaktan Algılanmış Görüntülerde Sınıflandırma ve Analiz, *Harita Dergisi*, 130, 32-46.

- Ballester, C., Caselles, V., Igual, L., Verdera, J. ve Roug'e, B., 2007. A variational model for P+ XS image fusion, *International Journal of Computer Vision*, 69 (1) (2006) 43–58.
- Bektaş Balçık, F. ve Göksel, Ç., 2009. SPOT 5 ve farklı görüntü birleştirme algoritmaları, İstanbul Teknik Üniversitesi Uzaktan Algılama Anabilim Dalı, İstanbul.
- Buduma, N., 2016. Fundamentals of deep learning. Designing next-generation machine intelligence algorithms, 1st Edition, O'Reilly.
- Carlà, R., Santurri, L., Aiazzi, B. ve Baronti, S., 2015. Fullscale assessment of pansharpening through polynomial fitting of multiscale measurements. *IEEE Transactions on Geoscience and Remote Sensing*, 53(12), pp.6344-6355.
- Cheriyadat, A. M., 2014. Unsupervised feature learning for aerial scene classification, *IEEE Transactions on Geoscience and Remote Sensing* vol. 52, no. 1, pp. 439–451.
- Choi, J., Yu, K., ve Kim, Y., 2011. A new adaptive component-substitution-based satellite image fusion by using partial replacement, *IEEE Transactions on Geoscience and Remote Sensing*, 49(1), 295–309.
- CNN, 2019 Retrived from <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53> (10 Mart 2023, 18:20).
- Collet, C., Chanussot, J., ve Chehdi, K., 2009. Multivariate image processing. hoboken, New Jersey, Wiley.
- Congalton, R., 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, Vol. 37: 35-46.
- Cortes, C. ve Vapnik, V., 1995. Support-vector networks, *Machine Learning*, 20, 273- 297.
- Cristianini, N. ve Shawe-Taylor, J., 2000. An introduction to support vector machines and other kernel based learning methods, Cambridge University Press, England.
- Çölkesen, İ. ve Kavzoğlu, T., 2008. Destek vektör makineleri kullanarak arazi örtüsünün sınıflandırılması: Gebze örneği, Gebze Yüksek Teknoloji Enstitüsü, Jeodezi ve Fotogrametri Mühendisliği Bölümü, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu UZAL-CBS 2008, Kayseri, <http://www.uzalcbs2008.org>.
- Çölkesen, İ., 2009. Uzaktan algılamada ileri sınıflandırma tekniklerinin karşılaştırılması ve analizi, Yüksek Lisans Tezi, Gebze Yüksek Teknoloji Enstitüsü Mühendislik ve Fen Bilimleri Enstitüsü, Gebze.

- Çölkesen, İ., 2015. Yüksek çözünürlüklü uydu görüntüleri kullanarak benzer spektral özelliklere sahip doğal nesnelerin ayırt edilmesine yönelik bir metodoloji geliştirme, Doktora Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Deng, L., ve Dong, Y., 2014. Deep Learning Methods and Applications, 198-349.
- Deng, L. J., Vivone, F., Jin, C., ve Chanussot, J., 2020. Detail injection-based deep convolutional neural networks for pansharpening, *IEEE Transactions on Geoscience and Remote Sensing*, 10.1109/TGRS.2020.3031366.
- Deng, L. J., Vivone, G., Paoletti, M. E., Scarpa, G., He, J., Zhang, Y., Chanussot, J. ve Plaza, A., 2022. Machine learning in pansharpening: A benchmark, from shallow to deep networks, *IEEE Geoscience and Remote Sensing Magazine*, 2-38, 10.1109/MGRS.2020.3019315.
- Dixit, A., Hedge, N. ve Reddy, B. E., 2017. Texture feature based satellite image classification scheme using SVM, *International Journal of Applied Engineering Research*; ISSN 0973-4562 Volume 12, Number 13, pp. 3996-4003.
- Doğan, F. ve Türkoğlu İ., 2019. Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme, *DÜMF Mühendislik Dergisi* 10:2 (2019) : 409-445, 10.24012/dumf.411130.
- Doğan, F. ve Türkoğlu İ., 2019. Derin öğrenme ile uydu görüntülerinin sınıflandırılması, *8th International Advanced Technologies Symposium (IATS'17)*.
- Dong, C., Loy, C. C., He, K. ve Tang, X., 2016. Image super-resolution using deep convolutional networks, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 38(2):295–307.
- Erdem, F., 2023. Konum-zamansal görüntü kaynaştırma için derin öğrenme tabanlı yeni bir yaklaşım, Eskişehir Teknik Üniversitesi Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı, Eskişehir.
- Foody, G.M. ve Mathur A., 2004. A relative evaluation of multiclass image classification by support vector machines, *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 42, (1335–1343).
- Foto, Ö., 2022. Transfer öğrenme modelleri ile akciğer X-Ray görüntülerinden Covid-19 tespiti, Yüksek Lisans Tezi, Aksaray Üniversitesi Sosyal Bilimler Enstitüsü Yönetim Bilişim Sistemleri Anabilim Dalı, Aksaray.
- Garzelli, A., Nencini, F. ve Capobianco, L., 2008. Optimal MMSE Pan Sharpening of Very High Resolution Multispectral Images, *IEEE Transactions on Geoscience and Remote Sensing*, 46(1), 228-236.

- Garzelli, A., 2015. Pansharpening of multispectral images based on nonlocal parameter optimization, *IEEE Transactions on Geoscience Remote Sensing*, 53 (4) (2015) 2096–2107.
- Ghassemian, H., 2016. A review of remote sensing image fusion methods, *Information Fusion*, 32, 75-89. <https://doi.org/10.1016/j.inffus.2016.03.003>.
- Goutte, C. ve Gaussier, E. 2005. A probabilistic interpretation of precision, recall and F-score, with implication for evaluation. In European Conference On Information Retrieval Kongresi'nde sunulmuş bildiri, Santiago de Compostela, Spain.
- Gunn, SR., 1998. Support vector machines for classification and regression, technical report, Southampton Üniversitesi.
- Güngör O., 2019. Coğrafi bilgi sistemleri ve uzaktan algılama uygulamaları, İstanbul Üniversitesi Açık ve Uzaktan Eğitim Fakültesi.
- He, K., Zhang, X., Ren, S., ve Sun, J., 2016. Deep residual learning for image recognition, *In Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 770–778.
- İşler, İ., 2018. Çoklu spektral ve pankromatik uydu görüntülerinin füzyonu için negatif olmayan matris ayrıştırma (noma) tabanlı yeni bir yöntem, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Bilişim Enstitüsü, İstanbul.
- Kahraman, S., 2019. Hiperspektral veriler için kaynaştırma ile uzamsal çözünürlük artırımı, Doktora Tezi, Kocaeli Üniversitesi.
- Kansu, O., 2006. Uzaktan algılamada görüntü sınıflandırma yöntemleri analizi, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, Trabzon.
- Kaplan, H., 2008. Kafes süzgeç yapıları ile görüntü füzyonu, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Kaur, A. ve Sachdeva, K., 2017. Satellite image classification using firefly algorithm, *International Journal of Advanced Computronics and Management Studies (IJACMS)*, Volume 2, Issue 5, pp. 1-9.
- Keerthi, S. ve Lin, C. J., 2003. Asymptotic behaviors of support vector machines with gaussian kernel, *Neural Computation*, Vol.. 15, (1667–1689).
- Kim, J., Lee, J. K. ve Lee, K. M., 2016. Accurate image super-resolution using very deep convolutional networks, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, pp. 1646–1654.
- Kingma, D. P. ve Ba, J. L., 2015. Adam: A method for stochastic optimization, *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, pp. 1–15.

- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2017. ImageNet classification with deep convolutional neural networks, *Communications of the ACM*, 60 (6), 84-90.
- Kussul, N., Lavreniuk, M., Skakun S. ve Shelestov, A., 2017. Deep learning classification of land cover and crop types using remote sensing data, *IEEE Geoscience and Remote Sensing Letters*, 14 (5), 778-782.
- Laben, C.A. ve Brower, B.V., 2000. Process for enhancing the spatial resolution of multispectral imagery using pan-sharpening, U.S. Patent 6 011 875.
- LeCun, Y., Bottou, L. ve Haffner, P., 1998. Gradient-based learning applied to document recognition, *IEEE*, 86 (11), 2278-2324.
- Liu, J. G., ve Mason, P. J., 2009. Essential image processing and GIS for remote sensing, John Wiley & Sons.
- Lolli, S., Alparone, L., Garzelli, A., ve Vivone, G., 2017. Haze correction for contrast-based multispectral pansharpening, *IEEE Geoscience and Remote Sensing Letters*, vol. 14, no. 12, pp. 2255–2259, 10.1109/LGRS.2017.2761021.
- Lupia, F., Baiocchi, V., Lelo, K. ve Pulighe, G., 2017. Exploring rooftop rainwater harvesting potential for food production in urban areas, *Agriculture 2017*, 7(6), 46.
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G. ve Johnson, B. A., 2019. Deep learning in remote sensing applications: a meta-analysis and review, *ISPRS Journal of Photogrammetry and Remote Sensing*, 152 (2019), 166-177.
- Maleki, A. S. ve Ghassemian, H., 2019. A critical review of quality assesment protocols in pansharpening, Tarbiat Modares University, Tehran, Iran, <https://doi.org/10.5194/isprs-archives-XLII-4-W18-13-2019>.
- Masi, G., Cozzolino, D., Verdoliva, L. ve Scarpa, G., 2016. Pansharpening by convolutional neural networks, *Remote Sensing*, 8(7), 594. <https://doi.org/10.3390/rs8070594>.
- Mather, P. M., 1987. Computer processing of remote-sensed images, John Wiley ve Sons Ltd.
- Melgani, F. ve Bruzzone, L., 2004. Classification of hyperspectral remote sensing images with support vector machines, *IEEE Transactions on Geoscience and Remote Sensing*, 42, 8 (2004) 1778-1790.
- Mijwel, M. M., 2018. Artificial neural networks advantages and disadvantages, computer science, college of science, Baghdad University, Baghdad, Iraq.
- Mukhopadhyay, S. Ve Mukhopadhyay, S., 2018. Advanced data analytics using python, 1st Edition, Apress.

- Murat, S., 2021. İnsansız hava aracı görüntülerinden derin öğrenme yöntemleriyle nesne tanıma, Yüksek Lisans Tezi, İstanbul Maltepe Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı, İstanbul.
- Mutlu, U., 2022. Derin öğrenme kullanarak hava aracı tespiti, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi İletişim Sistemleri Anabilim Dalı, İstanbul.
- Nguyen G., Dlugolinsky S., Bobák M., Tran V., López Á., Ignacio G., Peter H. ve Ladislav M., 2020. Machine learning and deep learning frameworks and libraries for large-scale data mining: a survey, *Artificial Intelligence Review*, 52 (1), 77-124.
- Nunez, J., Otazu X., Octavi, Fors Oc., Prades, A., Pala, V., ve R Arbiol, R., 1999. Multiresolution - based image fusion with additive wavelet decomposition, *IEEE Transactions on Geoscience and Remote Sensing*, 37(3), 1204- 1211.
- Osuna, E. E., Freund, R. ve Girosi, F., 1997. Support vector machines: Training and applications, <http://cbcl.mit.edu/cbcl/publications/ai-publications/1500-1999/AIM-1602.ps> (20 Mart 2023, 15:00).
- Otazu, X., Gonz´alez-Aud´ıcana, M., Fors, O.ve N´uñez, J., 2005. Introduction of sensor spectral response into image fusion methods, Application to wavelet-based methods, *IEEE Transactions on Geoscience and Remote Sensing*, 43 (10) (2005) 2376–2385.
- Özçelik F., 2020. Self-supervised pansharpening: guided colorization of pancromatic images using generative adversarial networks, İstanbul Teknik Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı, İstanbul.
- Özdemir, M.F., Arı, A. ve Hanbay, D., 2021. Çoklu nesne takibi fairMOT algoritması için optimizasyon algoritmalarının karşılaştırılması, İnönü Üniversitesi, Bilgisayar Mühendisliği Bölümü, Malatya, *Journal of Computer Science*, ISSN: 2548-1304.
- Öztürk, K. ve Şahin, M. E., 2018. Yapay sinir ağları ve yapay zekâya genel bir bakış, *Takvim-i Vekayi*, 6 (2), 25-36.
- Pal, M. ve Mather, P. M., 2005. Support vector machines for classification in remote sensing, *International Journal of Remote Sensing*, Vol. 26, (1007–1011).
- Palsson, J., Sveinsson, R. ve Ulfarsson, M.O., 2014. A new pansharpening algorithm based on total variation, *IEEE Geoscience and Remote Sensing Letters*, 11 (1) 318–322.
- Palsson, F., Sveinsson, J.R., Ulfarsson, M.O. ve Benediktsson, J.A., 2015. Model-based fusion of multi-and hyperspectral images using PCA and wavelets, *IEEE Transactions on Geoscience and Remote Sensing*, 53 (5) 2652–2663.
- Patterson, J. ve Gibson, A., 2017. Deep learning: A practitioner’s approach. O’Reilly Media, Inc., Sebastopol.

- Pekel, E. ve Soner Kara, S., 2017. A comprehensive review for artificial neural network application to public transportation, *Sigma Journal of Engineering and Natural Sciences*, 35(1), 157-179.
- Pham, D. T., Packianather, M. S. ve Afify, A. A., 2007. Artificial neural networks. In: D. Andina, D. T. Pham, Editors, *Computational Intelligence*, 67-92, Springer, Boston, MA.
- Pohl, C. ve van Genderen, J. L., 1998. Review article multisensor image fusion in remote sensing: concepts, methods and applications, *International Journal of Remote Sensing*, 19(5), 823-854, <https://doi.org/10.1080/014311698215748>.
- Pradhan, P., 2005. Multiresolution based, multisensor, multispektral image fusion, PhD Thesis, Mississippi State University, Mississippi.
- Priya, K., Rajkumar, K.K., 2022. Hyperspectral and multispectral image fusion using deep convolutional neural network ResNet fusion, Department of Information Technologies, Kannur University, Kerala. DOI: <http://dx.doi.org/10.5772/intechopen.105455>
- Rana, K., 2020. Pooling layer — short and simple, Available: <https://medium.com/ai-in-plain-english/pooling-layer-beginner-to-intermediate-fa0dbdce80eb> (20 Ocak 2023, 10:40).
- Raschka S., 2022. Gradient descent and stochastic gradient descent, Available: http://rasbt.github.io/mlxtend/user_guide/general_concepts/gradient-optimization/ (25 Ocak 2023, 12:00).
- Restaino, R., Vivone, G., Dalla Mura, M., ve Chanussot, J., 2016. Fusion of multispectral and panchromatic images based on morphological operators, *IEEE Trans. Image Process.*, vol. 25, no. 6, pp. 2882–2895, doi: 10.1109/TIP.2016.2556944.
- Restaino, R., Dalla Mura, M., Vivone, G. ve Chanussot, J., 2017. Context adaptive pansharpening based on image segmentation, *IEEE Transactions on Geoscience and Remote Sensing*, vol. 55, no. 2, pp. 753±766.
- Romero, A., Gatta, C. ve Camps-Valls, G., 2016. Unsupervised deep feature extraction for remote sensing image classification, *IEEE Transactions on Geoscience and Remote Sensing*, 54(3), 1349-1362.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S. ve Berg, A. C., 2015. Imagenet large scale visual recognition challenge, *International Journal of Computer Vision*, 115(3), 211-252.
- Serifoglu Yilmaz, C., Yilmaz, V. ve Güngör, O., 2020. On the use of the SOS metaheuristic algorithm in hybrid image fusion methods to achieve optimum spectral fidelity, *International Journal of Remote Sensing*, 41(10), 3993-4021. <https://doi.org/10.1080/01431161.2019.1711244>.

- Sertel, E., Wang, P. ve Algancı, U., 2021. Comparative analysis on deep learning based pan-sharpening of very high-resolution satellite images, *International Journal of Environment and Geoinformatics (IJEgeo)*, 8(2):150-165, 10.30897/ijegeo.834760.
- Severoğlu, B. M., 2021. Hiperspektral görüntülerde derin öğrenme ile hedef tespiti, Yüksek Lisans Tezi, Hacettepe Üniversitesi Elektrik ve Elektronik Mühendisliği Anabilim Dalı, Ankara.
- Seyyarer, E., Ayata, F., Uçkan, T. ve Karıcı, A., 2020. Derin öğrenmede kullanılan optimizasyon algoritmalarının uygulanması ve kıyaslanması, *Anatolian Journal of Computer Sciences*, cilt 5, no. 2, pp. 90-98.
- Scarpa, G., Vitale, S. ve Cozzolino, D., 2018. Target-adaptive CNN-based pansharpening, *IEEE Transactions on Geoscience and Remote Sensing*, 56(9), 5443–5457.
- Schowengerdt, R. A., 2007. *Remote Sensing: Models and Methods for Image Processing*, 3rd ed. Orlando, FL: Elsevier.
- Shatnawi, A., Al-bdour, G., Al-qurran, R. ve Al-ayyoub, M., 2018. A comparative study of open source deep learning frameworks, *Proceedings of the 9th International Conference on Information and Communication Systems*, 72-77, Irbid, Jordan.
- Sherrod, P., H., 2003. Classification and regression trees and support vector machines for predictive modeling and forecasting, DTREG program manual.
- Simonyan, K. ve Zisserman, A., 2014. Very deep convolutional networks for large-scale image recognition, arXiv preprint arXiv:1409.1556.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, R., Anguelov, D., Erhan, D., Vanhoucke, V. ve Rabinovich, A., 2015. Going deeper with convolutions, *In Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 1–9.
- Şimşek, N., 2019. A comparative study of deep learning methods for classification of rna-seq cancer data, Yüksek Lisans, Hasan Kalyoncu University.
- Ulu, A., 2016. Deep convolutional neural network based representations for person re-Identification, İstanbul Teknik Üniversitesi, Bilgisayar Mühendisliği Bölümü, İstanbul.
- URL-1. <http://www.yildiz.edu.tr/~bayram/sgi/saygi.htm> (08 Ocak 2023, 13:20).
- URL-2. <https://towardsdatascience.com/the-perceptron-3af34c84838c> (15 Ocak 2023, 14:15).
- URL-3. Reducing Loss: Gradient Descent,. Available:<https://developers.google.com/machine-learning/crash-course/reducing-loss/gradient-descent> (10 Şubat 2023, 17:25).

URL-4. <https://www.tensorflow.org/learn> (20 Şubat 2023, 21:10).

URL-5. <https://keras.io/> (22 Şubat 2023, 21:50).

URL-6. <https://docs.microsoft.com/en-us/cognitive-toolkit/> (10 Mart 2023, 18:20).

URL-7. <https://stephenallwright.com/l1-vs-l2-loss/> (22 Mart 2023, 10:10).

Ülker, E. ve İnik, Ö., 2017. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri, *Gaziosmanpasa Journal of Scientific Research* ISSN: 2146-8168.

Ünlü, E. I., 2019. Derin öğrenme ile görüntü bölütleme, Yüksek Lisans Tezi, Fırat Üniversitesi Bilgisayar Mühendisliği Yazılım Anabilim Dalı, Elazığ.

Vapnik, V. N., 1995. The nature of statistical learning theory.

Vapnik, V.N., 2000. The nature of statistical learning theory, *Second Edition*, Springer-Verlag, New York.

Van Doorn, J., 2014. Analysis of deep convolutional neural network architectures.

Vicinanza, M.R., Restaino, R., Vivone, G., Dalla Mura, M. ve Chanussot, J., 2015. A pansharpening method based on the sparse representation of injected details, *IEEE Geoscience and Remote Sensing Letters*, 12 (1) 180–184.

Vivone, G., Restaino, R., Dalla Mura, M., Licciardi, G. ve Chanussot, J., 2014. Contrast and error-based fusion schemes for multispectral image pansharpening, *IEEE Geoscience and Remote Sensing Letters*, 11 (5) 930–934.

Vivone, G., Simões, M., Mura Dalla, M., Restaino, R., Bioucas-Dias, J.M., Licciardi, G.A. ve Chanussot, J., 2014. Pansharpening based on semiblind deconvolution, *IEEE Transactions on Geoscience and Remote Sensing*, 10.1109/TGRS.2014.2351754.

Vivone, G., Restaino, R. ve Chanussot, J., 2018. Full scale regression-based injection coefficients for panchromatic sharpening, *IEEE Transactions on Image Processing*, 27 (7) (2018) 3418–3431.

Vivone, G., Restaino, R. ve Chanussot, J., 2018. A regression-based high-pass modulation pansharpening approach, *IEEE Transactions on Geoscience and Remote Sensing*, 56 (2) 984–996.

Vivone, G., 2019. Robust band-Dependent spatial-detail approaches for panchromatic sharpening, *IEEE Transactions on Geoscience and Remote Sensing*, 57 (9) 6421–6433.

- Vivone, G., Mura Dalla, M., Garzelli, A., Restaino, R., Scarpa, G., Ulfarsson, M.O., Alparone, L. ve Chanussot, J., 2020. A new benchmark based on recent advances in multispectral pansharpening: Revisiting pansharpening with classical and emerging pansharpening methods, *IEEE Transactions on Geoscience and Remote Sensing, Mag.* 9 (1) (2021) 53–81.
- Yang, J., Fu, X., Hu, Y., Huang, Y., Ding, X. ve Paisley, J., 2017. PanNet: A deep network architecture for pan-sharpening, *IEEE International Conference on Computer Vision (ICCV)*, pp.1753–1761.
- Yang, C., Zhan, Q., Liu, H. ve Ma, R., 2018. An IHS-based pan-sharpening method for spectral fidelity improvement using ripplet transform and compressed sensing, *Sensors*, 18(11), 3624, <https://doi.org/10.3390/s18113624>.
- Yazıcı, A. C., Ögüş, E., Ankaralı, S., Canan, S., Ankaralı, H. ve Akkuş, Z., 2007. Yapay sinir ağlarına genel bakış, *Türkiye Klinikleri Tıp Bilimleri Dergisi*, 27 (1), 65-71.
- Yeşildal G., 2022. Tıbbi görüntüler üzerinden Covid-19 hastalık teşhisi, Yüksek Lisans Tezi, Ankara Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Yıldırım, E., 2022. Object detection from optical satellite images using deep learning techniques, Yüksek Lisans Tezi, Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü, Gebze.
- Yılmaz, E. Ö., 2020. Uzaktan algılanmış verilerin derin öğrenme yöntemiyle sınıflandırılması, Yüksek Lisans Tezi, Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü, Gebze.
- Yılmaz, V., 2012. Görüntü kaynaştırma yöntemlerinde performans analizi, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon.
- Yılmaz, V. ve Gungor, O., 2016. Fusion of very high-resolution UAV images with criteria-based image fusion algorithm, *Arabian Journal of Geosciences*, 9(1), 1-16, <https://doi.org/10.1007/s12517-015-2109-8>.
- Yılmaz, V., 2021. A non-dominated sorting genetic algorithm-II-based approach to optimize the spectral and spatial quality of component substitution-based pansharpened images, *Concurrency and Computation: Practice and Experience*, 33(5), e6030, <https://doi.org/10.1002/cpe.6030>.
- Yılmaz, V., Serifoglu Yılmaz, C. ve Gungor, O. 2021. Genetic algorithm-based synthetic variable ratio image fusion, *Geocarto International*, 36(9), 989-1006, <https://doi.org/10.1080/10106049.2019.1629649>.
- Yılmaz, V., Serifoglu Yılmaz, C. ve Gungor, O. 2021. Çok bantlı görüntülerde pan-keskinleştirme üzerine bir inceleme, ISSN: 2146-538X <http://dergipark.gov.tr/gumusfenbil>, 10.17714/gumusfenbil.972014.

- Yilmaz, V., Serifoglu Yilmaz, Ç. ve Gungor, O., 2021. A theoretical and practical survey of image fusion methods for multispectral pansharpening, *Information Fusion*, 79 (2022) 1-43, <https://doi.org/10.1016/j.inffus.2021.10.001>.
- Yuan, Q., Wei, Y., Meng, X., Shen, H. ve Zhang, L., 2018. A multiscale and multidepth convolutional neural network for remote sensing imagery pansharpening, *IEEE Journal of Selected Topics in Applied Earth Observations*, vol. 11, pp. 978±989.
- Zeiler, D. M., ve Fergus, R., 2014. Visualizing and understanding convolutional networks, *In European conference on computer vision*, pages 818–833. Springer.
- Zhang, Y., Backer, S. ve Scheunders, P., 2009. Noise-resistant wavelet-based Bayesian fusion of multispectral and hyperspectral images, *IEEE Transactions on Geoscience and Remote Sensing*, 47 (11) (2009) 3834–3843.
- Zhang, L., Zhang, L. ve Du, B. O., 2016. Deep learning for remote sensing data: a technical tutorial on the state of the art, *IEEE Geoscience and Remote Sensing Magazine*, 4 (2), 22-40.
- Zhang, L., Xia, G. S., Wu, T., Lin, L. ve Tai, X. C., 2016. Deep learning for remote sensing image understanding, *Journal of Sensors*, 2016, 1-3.
- Wald, L., Ranchin, T. ve Mangolini, M., 1997. Fusion of satellite images of different spatial resolutions: Assessing the quality of resulting images, *Photogrammetric Engineering and Remote Sensing*, 63(6), 691-699.
- Wang, W., Jiao, L. ve Yang, S., 2014. Fusion of multispectral and panchromatic images via sparse representation and local autoregressive model, *Information Fusion* 20 (2014) 73–87.
- Wei, Y., Yuan, Q., Shen, H. ve Zhang, L., 2017. Boosting the accuracy of multispectral image pansharpening by Learning a deep residual network, *IEEE Geoscience and Remote Sensing Letters*, 14(10), 1795–1799.
- Xing, Y., Wang, M., Yang, S. ve Zhang, K., 2018. Pansharpening with multiscale geometric support tensor machine, *IEEE Transactions on Geoscience and Remote Sensing*, 56 (5) (2018) 2503–2517.
- Xu, S., Amira, O, Liu, J., Zhang, C. X., Zhang, J., Li, G., 2020. HAM-MFN: Hyperspectral and multispectral image multiscale fusion network with RAP loss, *IEEE Trans. Geosci. Remote Sens.* 58 (7) (2020) 4618–4628.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : Aşıkoğlu Deryanur

Uyruğu :

Doğum tarihi ve yeri :

Medeni hali :

Telefon :

e-posta :

Eğitim

<u>Derece</u>	<u>Eğitim Birimi</u>	<u>Mezuniyet Tarihi</u>
Lise	Samsun Karşıyaka Anadolu Lisesi	2015
Lisans	Tokat Gaziosmanpaşa Üniv. Harita Mühendisliği	2019
Yüksek Lisans	A.Ç.Ü. L.E.E Harita Mühendisliği	2023