



T.C.

**KIRIKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**DÜŞÜK UZAMSAL ÇÖZÜNÜRLÜĞE SAHİP
HİPERSPEKTRAL GÖRÜNTÜLERİ İÇİN
ÖĞRENME TABANLI SÜPER ÇÖZÜNÜRLÜK YÖNTEMİ**

HÜSEYİN AYDİLEK

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DOKTORA TEZİ

**DANIŞMAN
Prof. Dr. Nihat İNANÇ**

KIRIKKALE- 2022



T.C.

**KIRIKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**DÜŞÜK UZAMSAL ÇÖZÜNÜRLÜĞE SAHİP
HİPERSPEKTRAL GÖRÜNTÜLERİ İÇİN
ÖĞRENME TABANLI SÜPER ÇÖZÜNÜRLÜK YÖNTEMİ**

HÜSEYİN AYDİLEK

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DOKTORA TEZİ

**DANIŞMAN
Prof. Dr. Nihat İNANÇ**

KIRIKKALE- 2022

Hüseyin AYDİLEK tarafından hazırlanan “DÜŞÜK UZAMSAL ÇÖZÜNÜRLÜĞE SAHİP HİPERSPEKTRAL GÖRÜNTÜLERİ İÇİN ÖĞRENME TABANLI SÜPER ÇÖZÜNÜRLÜK YÖNTEMİ” adlı tez çalışması, aşağıdaki jüri tarafından OY BİRLİĞİ ile Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalında DOKTORA TEZİ olarak kabul edilmiştir

Danışman: Prof. Dr. Nihat İNANÇ

Elektrik-Elektronik Mühendisliği, Kırıkkale Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Başkan : Prof. Dr. Refik SAMET

Bilgisayar Mühendisliği, Ankara Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Üye : Prof. Dr. Tamer EREN

Endüstri Mühendisliği, Kırıkkale Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Üye : Prof. Dr. Necaattin BARIŞÇI

Bilgisayar Mühendisliği, Gazi Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Üye : Prof. Dr. Tolga EREN

Elektrik-Elektronik Mühendisliği, Kırıkkale Üniversitesi

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum.

Tez Savunma Tarihi: 15/02/2022

Jüri tarafından kabul edilen bu tezin Doktora Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Prof. Dr. Recep ÇALIN

Fen Bilimleri Enstitüsü Müdürü

ETİK İLKELERE UYGUNLUK BİLDİRİMİ

Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
 - Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
 - Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
 - Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
 - Bu tezde sunduğum çalışmanın özgün olduğunu,
- bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Hüseyin AYDİLEK
15/02/2022

ÖZET

DÜŞÜK UZAMSAL ÇÖZÜNÜRLÜĞE SAHİP HİPERSPEKTRAL GÖRÜNTÜLERİ İÇİN ÖĞRENME TABANLI SÜPER ÇÖZÜNÜRLÜK YÖNTEMİ

AYDİLEK, Hüseyin

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı, Doktora Tezi

Danışman: Prof. Dr. Nihat İNANÇ

Şubat 2022, 83 Sayfa

Hiperspektral görüntüleme, sahip olduğu spektral özelliklerinden dolayı nesnelerin niteliklerini belirleme, ayırt etme ve sınıflandırma uygulamalarında diğer görüntüleme araçlarına göre üstünlük göstermektedirler. Hiperspektral görüntüleme araçları; elektromanyetik tayf üzerinde insan gözünün ayırt edemediği dalga boyunun haricinde, kızılötesi ve ultraviyole arasında bulunan belirli dalga boylarından yansıyan ışığı algılayabilmektedir. Bu özelliği, incelenen nesnenin spektral özelliği hakkında detaylı bilgi sağlarken, sahip olduğu optik görüntüleme donanımının kısıtlarından dolayı uzamsal çözünürlüğünün düşük olmasına neden olmaktadır. Günümüzde hiperspektral görüntülerin; başta askeri amaçlar olmak üzere tarım, madencilik, tıp ve eczacılık gibi önemli alanlarda uygulamaları artmaktadır. Uygulamaların daha hassas sonuçlar üretebilmesi için ise yüksek spektral bilginin yanında, yüksek uzamsal çözünürlüğe ihtiyaç duyulmaktadır. Düşük uzamsal çözünürlük sorununun donanımsal olarak çözülmesi zor ve maliyetli bir yöntemdir. Bu nedenle yazılımsal olarak çözüm, görüntü işleme alanında ilgi çekici bir alan olmaktadır. Bu tez çalışmasında, hiperspektral görüntülerin düşük uzamsal çözünürlüklerinin artırılması için, derin öğrenme ve seyrek temsil tabanlı hibrit bir çözüm yöntemi önerilmiştir. Önerilen yöntem, seyrek temsilin spektral veriyi kaynaştırmadaki başarısından ve derin öğrenmenin düşük ve yüksek uzamsal bilgiler arasında güçlü bir bağ kurmasından yararlanmaktadır. Yöntemde, düşük uzamsal çözünürlüğe sahip hiperspektral görüntünün derin ağ modeli ile uzamsal çözünürlüğü artırılırken, seyrek temsil yöntemi ile spektral veri yeni oluşturulan süper çözünürlüklü görüntüye aktarılmaktadır. Uygulama sonuçları, yöntemimizin başarılı sonuçlar elde ettiğini göstermektedir.

Anahtar Kelimeler: Uzaktan Algılama, Hiperspektral Görüntüleme, Süper Çözünürlük, Derin Öğrenme, Evrişimli Sinir Ağları, Seyrek Temsil, Sözlük Öğrenme

ABSTRACT

LEARNING-BASED SUPER-RESOLUTION METHOD FOR HYPERSPECTRAL IMAGES WITH LOW SPATIAL RESOLUTION

AYDİLEK, Hüseyin

Kırıkkale University

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Engineering, Doctoral Thesis

Supervisor: Prof. Dr. Nihat İNANÇ

February 2022, 83 pages

Due to its spectral properties, hyperspectral imaging is superior to other imaging tools in determining, distinguishing, and classifying objects. Hyperspectral imaging tools; Apart from the wavelength the human eye can distinguish on the electromagnetic spectrum, it can detect light reflected from specific wavelengths between infrared and ultraviolet. While this feature provides detailed information about the spectral feature of the object under investigation, it causes its spatial resolution to be low due to the limitations of its optical imaging hardware. Today, hyperspectral images; Its applications are increasing in essential fields such as agriculture, mining, medicine, and pharmacy, especially for military purposes. In order for applications to produce more precise results, high spatial resolution is required and high spectral information. Hardware solving of low spatial resolution problems is a costly and challenging method. Therefore, software solution is an exciting area in image processing In this thesis, a hybrid solution method based on deep learning and sparse representation is proposed to increase the low spatial resolution of hyperspectral images. The proposed method uses the sparse representation's success in fusing spectral data and the strong linkage of deep learning between low and high spatial information. In the method, the spatial resolution of the low spatial resolution hyperspectral image is increased with the deep mesh model. At the same time, the spectral data is transferred to the newly created super-resolution image with the sparse representation method. The application results show that our method has achieved successful results.

Keywords: Remote Sensing, Hyperspectral Imaging, Super-Resolution, Deep Learning, Convolutional Neural Networks, Sparse Representation, Dictionary Learning

TEŞEKKÜR

Bu doktora çalışmasında, konunun seçiminden, uygulanmasına ve başarılı sonuçların elde edilmesine kadar tüm süreçte her türlü yardımını ve desteğini esirgemeyen; akademik bilgi ve tecrübelerini paylaşarak sadece bu tez için değil, tüm akademik hayatımı etkileyecek kıymetli tavsiyelerini benimle paylaşan danışmanım Prof. Dr. Sayın Nihat İNANÇ'a tüm kalbimle teşekkürlerimi sunarım.

Tez çalışmam süresince, tezin şekil alması için değerli fikirlerini ve tavsiyelerini paylaşan komite üyeleri Prof. Dr. Sayın Tamer EREN ve Prof. Dr. Sayın Ertuğrul ÇAM'a teşekkürü borç bilirim.

Tezime sundukları pozitif eleştiriler ile daha iyi bir hal almasını sağlayan değerli tez savunma jürisi üyesi hocalarım, Prof. Dr. Sayın Refik SAMET ve Prof. Dr. Sayın Necaattin BARIŞCI'ya teşekkür ederim.

Akademik hayata başladığım günden itibaren, her zaman yardımını ve sonsuz desteğini hissettiğim çok kıymetli büyüğüm, hocam Doç. Dr. Sayın Murat LÜY başta olmak üzere; çalışmalarım boyunca gerekli desteği gördüğüm değerli Bölüm Başkan Yardımcısı hocam Prof. Dr. Sayın Tolga EREN'e, birçok ortak çalışmada bulunduğum ve daha çok çalışmalar başaracağımıza inandığım değerli arkadaşım Mustafa Yasin ERTEN'e ve tüm mesai arkadaşlarıma teşekkür ederim.

Tüm çalışmalarım boyunca sonsuz bir inanç ve sabırla beni destekleyen değerli eşim, annem, babam ve kardeşime sonsuz teşekkürlerimi sunarım.

Hayatıma girmesiyle birlikte bambaşka bir dünya yaratan biricik kızıma sonsuz sevgi ve teşekkürlerimi sunarım.

İÇİNDEKİLER DİZİNİ

ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER DİZİNİ	vii
ÇİZELGELER DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
1. GİRİŞ	1
1.1 Uzaktan Algılama.....	2
1.2 Elektromanyetik Tayf.....	8
1.3 Hiperspektral Görüntüleme	9
1.4 Süper Çözünürlük.....	11
1.5 Literatür Taraması	13
1.5.1 Görüntü Kaynaştırma Tabanlı Yöntemler.....	13
1.5.2 Tekli Görüntü Üzerinden Yapılan Yöntemler.....	19
1.5.3 Literatürün Değerlendirilmesi.....	25
1.6 Tezin Literatüre Katkısı.....	26
2. METODOLOJİ	29
2.1 Denetimli ve Denetimsiz Öğrenme	29
2.2 Yapay Sinir Ağları.....	30
2.2.1 Derin Öğrenme	31
2.2.2 Aktivasyon Fonksiyonları	32
2.2.3 Kayıp Fonksiyonları	36
2.2.4 Gradyan Azalma	37
2.3 Derin Evrişimli Sinir Ağları	39
2.3.1 Tam Bağlantılı Katman.....	39
2.3.2 Evrişimsel Katman	40
2.3.3 Havuzlama Katmanı	41
2.4 Derin Kalıntı Ağlar.....	41
2.5 Yoğun Evrişimli Ağlar	42
2.6 Seyrek Temsil.....	43

2.6.1 Kodlama	44
2.6.2 Sözlük Öğrenme.....	44
2.7 Değerlendirme Metrikleri.....	45
3. ÖNERİLEN MODEL	47
3.1 Derin Öğrenme Modellerinin Geliştirilmesi	48
3.1.1 Derin Evrişim Ağı Modeli	49
3.1.2 Derin Kalıntı Ağı Modeli	51
3.2 Seyrek Temsil Tabanlı Kısım.....	54
4. UYGULAMA VE SONUÇLARI	57
4.1 Veri Setleri	57
4.2 Uygulama Detayları	57
4.3 Sonuçlar.....	58
4.4 Tartışma.....	68
KAYNAKLAR	71
ÖZGEÇMİŞ.....	81

ÇİZELGELER DİZİNİ

Çizelge 4.1 Derin evrişimli sinir ağında kullanılan parametreler	58
Çizelge 4.2 Derin evrişimli sinir ağı ve seyrek temsil tabanlı hibrit yöntemin, CAVE veri setine uygulanması sonucu elde edilen süper-çözünürlüklü görüntülerin OKH ve SAH sonuçları.....	59
Çizelge 4.3 Derin kalıntı ağı ve seyrek temsil tabanlı hibrit yöntemin, CAVE veri setine uygulanması sonucu elde edilen süper-çözünürlüklü görüntülerin OKH ve SAH sonuçları	60
Çizelge 4.4 Derin evrişimli sinir ağı ve seyrek temsil tabanlı hibrit yöntemin, Harvard veri setine uygulanması sonucu elde edilen süper-çözünürlüklü görüntülerin OKH ve SAH sonuçları.....	61
Çizelge 4.5 Derin kalıntı ağı ve seyrek temsil tabanlı hibrit yöntemin, Harvard veri setine uygulanması sonucu elde edilen süper-çözünürlüklü görüntülerin OKH ve SAH sonuçları	61
Çizelge 4.6 Önerilen yöntemlerin, CAVE veri setine göre literatürdeki diğer yöntemlere göre OKH ve SAH ortalama değerlerinin karşılaştırılması	67
Çizelge 4.7 Önerilen yöntemlerin, Harvard veri setine göre literatürdeki diğer yöntemlere göre OKH ve SAH ortalama değerlerinin karşılaştırılması	68

ŞEKİLLER DİZİNİ

Şekil 1.1 (a) Pasif sensörler çalışma şekli (b) aktif sensörlerin çalışma şekli	4
Şekil 1.2 (a) Düşük uzamsal çözünürlüklü görüntü, (b) Yüksek uzamsal çözünürlüklü görüntü	6
Şekil 1.3 (a) Düşük radyometrik çözünürlüklü görüntü (2 bit), (b) Yüksek radyometrik çözünürlüklü görüntü (8 bit).....	7
Şekil 1.4 Dalganın temel yapısı	8
Şekil 1.5 Elektromanyetik Tayf	9
Şekil 1.6 Hiperspektral görüntünün kavramsal diyagramı	10
Şekil 1.7 Süper-çözünürlük uygulaması, (a) Düşük uzamsal çözünürlüklü girdiler ve alt piksellerinin temsili, (b) alt piksellerin kaydırılarak, birleştirilmesi ile elde edilen süper çözünürlüklü görüntünün temsili.....	12
Şekil 2.1 Yapay Sinir Ağı Yapısı.....	30
Şekil 2.2 Çok katmanlı algılayıcı temel yapısı	32
Şekil 2.3 Sigmoid fonksiyonunun grafiksel gösterimi.....	33
Şekil 2.4 tanh fonksiyonunun grafiksel gösterimi	34
Şekil 2.5 ReLU fonksiyonunun grafiksel gösterimi	35
Şekil 2.6 Bir Derin Evrişimli Sinir Ağı'nın (DESA) yapısı.....	39
Şekil 2.7 Tam bağlantılı bir katmanın yapısı	40
Şekil 2.8 Evrişimsel bir katmanın gösterimi.....	41
Şekil 2.9 Derin kalıntı ağlarında temel bir evrişim işlemi	42
Şekil 2.10 Temel bir yoğun evrişimli ağ mimarisi	42
Şekil 2.11 Atomların seyrek gösterimi	45
Şekil 3.1 Önerilen yöntemin algoritmik gösterimi	48
Şekil 3.2 Derin evrişim ağı ile önerilen yöntemin gösterimi.	51
Şekil 3.3 Derin kalıntı ağı ile önerilen yöntemin gösterimi.....	53
Şekil 3.4 Bayes seyrek temsil ile süper çözünürlüğün algoritmik gösterimi.....	55
Şekil 4.1 Harvard veri setindeki “imga2”, “imgb5” ve “imgc7” isimli hiperspektral görüntülerin, derin kalıntı ağı ve seyrek kodlama tabanlı hibrit model ile süper çözünürlük uygulaması sonucunda girdi ve çıktıların görüntüsü	62
Şekil 4.2 Harvard veri setindeki “imgd3”, “imge7” ve “imgf8” isimli hiperspektral görüntülerin, derin kalıntı ağı ve seyrek kodlama tabanlı hibrit model ile süper çözünürlük uygulaması sonucunda girdi ve çıktıların görüntüsü	63

Şekil 4.3 CAVE veri setinde bulunan “Egyptian Statue”, “Tomatoes” ve “Flowers” isimli hiperspektral görüntülerin, derin kalıntı ağı ve seyrek kodlama tabanlı hibrit model ile süper çözünürlük uygulaması sonucunda girdi ve çıktıların görüntüsü.. 64

Şekil 4.4 CAVE veri setinde bulunan “Beads”, “CD” ve “Chart and Stuffed toys” isimli hiperspektral görüntülerin, derin kalıntı ağı ve seyrek kodlama tabanlı hibrit model ile süper çözünürlük uygulaması sonucunda girdi ve çıktıların görüntüsü.. 65

Şekil 4.5 CAVE veri setinde bulunan “Cloth”, “Faces” ve “Food” isimli hiperspektral görüntülerin, derin kalıntı ağı ve seyrek kodlama tabanlı hibrit model ile süper çözünürlük uygulaması sonucunda girdi ve çıktıların görüntüsü..... 66



1. GİRİŞ

İnsanođlu gemiřten beri varlıkları, olayları ve nesnelere inceleme; onlardan bilgi edinme isteđinde olmuřtur. Bu amala, eřitli yntemler geliřtirmiř ve geliřtirmeye devam etmektedir. Uzaktan algılama; anlamsal olarak bir varlık, nesne veya olayı temas olmaksızın eřitli ara ve gereler ile algılama ve analiz etme olarak dřnlebilir. Bir canlının ultrason, rntgen, Manyetik Rezonans Grntleme (MRG) gibi analizinden; kameralar ile bir olayın irdelenmesi veya eřitli sensrler ile nesnelere, canlıların incelenmesi gibi geniř bir tanım alanı, uzaktan algılamanın konusu olarak gsterilebilir.

Yer bilimlerinde ise uzaktan algılama, uak ve uydulardan elde edilen veriler kullanılarak, dnya yzeyindeki nesne zelliklerinin lm olarak tanımlanabilir [1]. Birok kaynakta, yer bilimlerinde uzaktan algılama kavramının kameraların icadı ile bařladıđı kabul edilmektedir [2]. İlk havadan grntleme 1858 yılında, Gaspard-Felix Tournachon (Nadar) tarafından balon ile Paris'in fotođraflarının ekilmesi ile gerekleřtirilmiřtir [3]. Geliřen kamera ve hava araları teknolojileri ile 1. Dnya Savařı ve 2. Dnya Savařı esnasında havadan ekilen grntler askeri amalar iin kullanılmıřtır. 1980'li yıllarda hiperspektral sensrlerin kullanılmaya bařlanmasından gnmze kadar gsterdiđi geliřim, hiperspektral kameraların en nemli uzaktan algılama aracı haline gelmesini sađlamıřtır.

Klasik grntleme araları, elektromanyetik tayf zerinde sadece gzle grlebilir dalga boyu aralıđından yansıyan ıřıđı algılayabilirken; hiperspektral grntleme araları, kızıltesi ve ultraviyole arasında bulunan belirli dalga boylarından yansıyan ıřıđı da algılayabilmektedir [4]. Hiperspektral grntleme, klasik grntleme aralarından farklı olarak, sahip olduđu ok sayıdaki spektral bant sayesinde uzaktan algılama ile incelenen nesnelere yapıřı hakkında da bilgi sađlayabilmektedir. Askeri uygulamalar bařta olmak zere madencilik, tıp, ila bilimi, tarım ve ormancılık gibi alanlarda hiperspektral grntlerden yararlanılarak tespit, analiz ve sınıflandırma uygulamaları yapılmaktadır [5–9].

Son yıllarda hiperspektral kameralar, sensör teknolojisi ile doğru orantılı olarak gelişmiştir. Hiperspektral görüntüleme araçları yapısında, spektrometre adı verilen bir donanım bulundurmaktadır. Bu sayede, bir sahnenin hem uzamsal hem de spektral bilgilerini elde etmek için geleneksel görüntüleme ve spektroskopi yöntemleri bir arada kullanılmaktadır [10]. Spektroskopi özelliğine sahip hiperspektral görüntüleme araçları, gözlemlenen nesnenin belirli dalga boylarında yansıttığı enerjiyi ölçmektedir. Bu sensörler, elektromanyetik spektrum boyunca çok sayıda bitişik spektral dalga yakalayabilmektedir. Bir nesneden yansıyan enerjinin, hiperspektral görüntüleme aracının spektral sensörleri ile algılanmasıyla elde edilen yansıma eğrisine spektral imza adı verilmektedir [11]. Nesnelerin fiziksel ve kimyasal özelliklerinden dolayı ışığı emme, yansıtma ve geçirme oranının farklı olmasından ötürü, her nesnenin spektral imzası farklıdır. Hiperspektral görüntüler üzerinde yapılacak analizden en doğru çıkarımları elde edebilmek için, spektral çözünürlük ile uzamsal çözünürlüğün uyumlu olması gerekmektedir. Ancak, hiperspektral görüntüleme araçlarının donanımsal yapısı ve görüntüleme mesafesinin uzaktan olması nedeni ile uzamsal çözünürlüğü düşük olmaktadır. Düşük uzamsal çözünürlüklü görüntülerde spektral eğriler karışmakta, bu da analizin sonucunu etkilemektedir.

Düşük uzamsal çözünürlük problemini donanımsal olarak çözmek oldukça maliyetlidir ve uygulaması zor bir çözüm yöntemidir. Bu nedenle problemin yazılımsal olarak çözümü, görüntü işleme alanında ilgi çekici bir problem olarak çalışılmaktadır.

1.1 Uzaktan Algılama

Uzaktan algılama, fiziksel bir temas olmaksızın bir hedef veya olgu üzerinden veri toplama sürecidir. Fiziksel temasın olmaması, erişimi imkânsız ve güvenli olmayan bölgelerden veri toplamada avantaj sağlamaktadır.


Bir uzaktan algılama uygulamasında, gerekli veri, uzaktan algılama platformları aracılığıyla toplanmaktadır. Uzaktan algılama platformu, uygulama için gerekli sensörlerin yerleştirildiği araçlardır. Yapılacak uygulamada, kullanılacak platform ve sensörlerin yerleştirilmesi uygulamanın başarıya ulaşması için oldukça önem arz etmektedir. Uzaktan algılama platformları, kullanım amaçları doğrultusunda beş gruba ayrılabilir [12]. En çok kullanılan uydu platformları, 40 yılı aşkın süredir

kullanılmaktadır [13]. Uzaktan algılama amacıyla, 1972 yılında uzaya gönderilen Landsat-1 uydusu, 0.5 – 1.1 μm spektral aralığında, 68 m x 83 m uzamsal çözünürlüğe sahip 4 banttan oluşan çoklu spektral tarayıcı sensörüne sahipti [14]. Günümüzde kullanılan Landsat-9 uydusu ise 11 spektral bantta 433 – 12500 nm aralığında spektral bilgi toplamaktadır [15]. Hava platformları ise, belirli uzaktan algılama görevleri için uçak veya helikopter üzerine uzaktan algılama sensörlerinin yerleştirilmesi ile oluşturulan platformlardır. Bu platformların kullanımında, ülkelerin uyguladığı kısıtların yanında, platformun hızlı hareket etmesi ve uydu platformlarına göre daha alçaktan görüntüleme yapması nedeni ile incelenen bölge hakkında veri toplamak daha zordur. İnsansız hava sistemleri platformları ise, hava platformlarına benzer şekilde uzaktan algılama sensörlerinin insansız hava araçlarına yerleştirilmesi ile elde edilmektedir. Hava platformları ile benzer kısıtlara sahiptirlerdir. Bazı kaynaklar, benzer özelliklerinden dolayı insansız hava sistemleri platformlarını, hava platformları başlığının altında incelemektedirler [16-18]. Mobil platformlar, hareketli bir kara vasıtasına uzaktan algılama sensörlerinin yerleştirilmesi ile elde edilmektedir. Otonom araçlar, mayın algılama robotları, haritalama araçları gibi platformlar bu kategori içerisinde sayılabilmektedir. Mobil platformların en bilindik örneği Google Haritalar tarafından kullanılan araçlardır. Sabit platformlar ise, belirli bir bölgenin zamansal, mevsimsel değişiminin izlenmesi gibi amaçlar için kullanılmaktadır. Diğer platformlardan farklı olarak sabit olması, zamansal çözünürlük açısından avantaj sağlamaktadır. Ancak, görüntü alanının kısıtlı olması, sınırlı bilgi sağlamaktadır. Bazı kaynaklar, mobil platformları ve sabit platformları, kara platformu adı altında tek bir başlıkta incelemektedir [18].

Uzaktan algılamada kullanılan sensörler; nesnelere yansıyan enerjileri algılayan, ölçen ve elde ettiği değerlerin analog veya dijital olarak kaydedilmesini sağlayan araçlardır. Bu sensörler, pasif sensörler ve aktif sensörler olarak iki kategoride sınıflandırılmaktadır [19]. Pasif sensörler, doğal ışık kaynaklarından yansıyan enerjiyi ölçmektedir. Uzaktan algılamada doğal enerji kaynağı güneştir. Pasif sensörler, nesnelere güneşten yansıyan ışığın emilmesinden ve geçirilmesinden sonra yaydığı enerjiyi ölçmektedir. Ancak, güneş ışığı her zaman yeterli bir enerji kaynağı olmayabilmektedir. Güneş ışığının yeterli seviyede ulaşmadığı bölgelerde bulutluluk, yağış gibi atmosferik olaylarda nesnelere algılanabilmesi için ek enerji kaynağına ihtiyaç duyulabilmektedir. Aktif sensörler, ilgilenilen nesne üzerinden yansıyan

enerjiyi algılayabilmek için kendi enerji kaynaklarını kullanırlar. Bu durumda, uzaktan algılama platformuna yerleştirilen bir enerji kaynağı aracılığıyla elektromanyetik enerji yayılır ve yansıyan enerji aktif sensör tarafından ölçülür. Şekil 1.1’de pasif ve aktif sensörlerin çalışma şekli verilmiştir. Şekil 1.1 (a)’da uydu platformu, güneşin yeryüzünden yansıyan enerjisini ölçerken; Şekil 1.1 (b)’de uydu platformu yeryüzünden, kendi enerji kaynağı vasıtasıyla yaydığı enerjinin yansımını ölçmektedir [20].

Yer gözlem alanında, veri toplamak için en yaygın olarak kullanılan aktif sensörler arasında radar, lazer floresensör ve Sentetik Açıklıklı Radar (SAR) bulunur [21].



Şekil 1.1 (a) Pasif sensörler çalışma şekli (b) aktif sensörlerin çalışma şekli [20]

Dijital görüntüler, piksel adı verilen dizilerden oluşur [22]. Her bir piksel, temsil ettiği dizi elemanı hakkında bulunduğu değer uzayına göre bilgi vermektedir. Bir uzaktan algılama görüntüsünde, pikseller içerdiği bölge hakkında diğer görüntülerden farklı olarak birden fazla veri içerebilmektedir.

Çözünürlük, görüntüde ayırt edilebilen iki nesne arasındaki minimum mesafedir. Çözünürlüğün yüksek olması, görüntü üzerindeki anlamlı bir nesnenin mümkün olan yüksek sayıda piksel ile temsil edilmesini ifade etmektedir ve daha yüksek kaliteli net bir görüntünün oluşması için oldukça önemlidir. Bununla birlikte, uzaktan algılamada çözünürlük terimi, yalnızca iki nesnenin varlığını tanımlama yeteneğini değil, aynı zamanda özelliklerini de içeren çözme gücünü temsil etmek için kullanılır. Niteliksel

olarak çözünürlük, bir görüntüde gözlemlenebilen detayların miktarıdır. Bu nedenle, daha ince ayrıntıları gösteren bir görüntünün, daha kaba ayrıntıları gösteren görüntüye kıyasla daha iyi çözünürlüğe sahip olduğu söylenebilir. Uzaktan algılama araçları ile elde edilen görüntülerin çözünürlüklerinin ifade edilmesinde dört tip çözünürlük kavramı vardır [23]:

Spektral çözünürlük; bir sensörün, ince dalga boyu aralıklarını tanımlama yeteneği veya bir sensörün, dünya yüzeyinin farklı bileşenlerini karakterize etmek için bir spektral bant genişliğinde alınan enerjiyi çözme yeteneği olarak tanımlanabilir. Spektral çözünürlük, filtrenin spektral bant genişliğini ve dedektörün hassasiyetini temsil eder. Spektral çözünürlük ne kadar dar olursa, belirli bir kanal veya bant için dalga boyu aralığı o kadar dar olur [24].

Uzamsal çözünürlük; uzaktan algılama araçları ile elde edilen görüntüden, taranan bölge üzerindeki nesnelere temsil ettiği minimum piksel sayısını ifade etmektedir. Uzamsal çözünürlük, görüntünün elde edildiği donanımın sensör kalitesine bağlı olduğu kadar, görüntüleme aracı ile görüntülenen alan arasındaki mesafe ve yansıma açısına da bağlıdır [25]. Şekil 1.2’de yüksek ve düşük uzamsal çözünürlüğe sahip iki görüntü verilmiştir. Şekil 1.2 (a)’da verilen düşük uzamsal çözünürlüklü görüntü, 30 m uzamsal çözünürlüğe sahipken, Şekil 1.2 (b)’de verilen yüksek uzamsal çözünürlüklü görüntü 10 m uzamsal çözünürlüğe sahiptir. Uzamsal çözünürlük küçüldükçe nesnelere şekilleri belirginleşmektedir. Bu da görüntü işleme uygulamalarında başarıyı arttırmaktadır [26].

Radyometrik çözünürlük; cihazın ışık yoğunluğu veya ışığın yansımasındaki farklılıkları ayırt etme kapasitesidir. Radyometrik çözünürlük ne kadar büyük olursa, algılanan görüntü o kadar hassas olur. Radyometrik çözünürlüğün değeri bit ile ifade edilir. 8 bitlik veride bir pikselin radyometrik değeri 0 ile 256 (2^8) aralığında olur. En düşük sinyal verisi 0 ile ifade edilirken, en yüksek değer 256 olur. Radyometrik çözünürlük, Sinyal Gürültü Oranına (SGO) da bağlıdır [24]. Şekil 1.3’te yüksek ve düşük radyolojik çözünürlüğe sahip iki görüntü verilmiştir. Şekil 1.3 (a)’da verilen görüntü 2 bit radyolojik çözünürlüğe sahipken, Şekil 1.3 (b)’de verilen görüntü 8 bit radyolojik çözünürlüğe sahiptir. Radyolojik çözünürlük büyüdükçe nesnelere şekilleri belirginleşmektedir. Bu da görüntü işleme uygulamalarında başarıyı arttırmaktadır [26].




(a)



(b)

Şekil 1.2 (a) Düşük uzamsal çözünürlüklü görüntü, (b) Yüksek uzamsal çözünürlüklü görüntü [26]



(a)




(b)

Şekil 1.3 (a) Düşük radyometrik çözünürlüklü görüntü (2 bit), (b) Yüksek radyometrik çözünürlüklü görüntü (8 bit) [26]

Zamansal çözünürlük; tam olarak aynı konumu tekrar ziyaret etmek ve veri almak için gereken süre olarak tanımlanır. Uzaktan algılamaya uygulandığında, bu süre, sensör özelliklerinin yanı sıra sensör platformunun yörünge özelliklerine de bağlıdır. Tekrar ziyaret gecikmesi düşük olduğunda, zamansal çözünürlük yüksektir ve bunun tersi de geçerlidir. Zamansal çözünürlük, genellikle gün olarak ifade edilir [27].

1.2 Elektromanyetik Tayf

Elektromanyetik (EM) tayf; insan gözünün algılayamadığı elektromanyetik dalgalar da dahil olmak üzere, tüm EM dalga türlerinin sınıflandırıldığı bir gösterim biçimidir. Dalga, kelime anlamı olarak enerjiyi bir yerden başka bir yere taşıyan düzensizlik olarak tanımlanabilir [28]. Dalgaları tanımlamak ve bilimsel olarak ölçümlendirebilmek için dalganın boyu, genliği ve frekans bilgileri kullanılmaktadır. Şekil 1.4'te bir dalganın temel yapısı verilmiştir.




Şekil 1.4 Dalganın temel yapısı [28]

Şekil 1.4'te görüleceği üzere bir dalganın iki tepe noktası arasındaki mesafeye dalga boyu; bir dalganın tepe noktası ile sıfır noktasına olan düşey uzaklığına genlik; belirli bir noktadan birim saniyede geçen dalga miktarına frekans adı verilir.

Elektromanyetik dalgalar; dalga boyu ve frekans özelliklerine göre sınıflandırılırlar. İnsan gözü yaklaşık 400 nm ile 700 nm arasındaki elektromanyetik dalgaları algılayabilir. İnsan gözünün algılayabildiği bu dalga boyu aralığındaki elektromanyetik dalgalar ışık olarak da isimlendirilebilir. Uzun radyo dalgaları, FM,

AM, mikrodalgalar, kızılötesi, ultraviyole, X ve gama ışınları diğer elektromanyetik dalga türleridir. Şekil 1.5'te elektromanyetik dalgalar, tayf üzerinde, dalga boyu ve frekans değerlerine göre sınıflandırılarak verilmiştir.

Elektromanyetik radyasyon enerji, dalga boyu veya frekans cinsinden ifade edilebilir. Frekans, saniyedeki devir sayısı cinsinden ölçülür ve birim olarak Hertz ile gösterilir. Dalga boyu metre cinsinden ölçülür. Enerji elektron volt ile gösterilir. Dalga boyu ile frekans arasında ters orantı vardır. Frekans arttıkça, dalga boyu azalır. Frekans ile enerji arasında doğru orantı vardır. Frekans arttıkça, taşınan enerji miktarı da artmaktadır. Şekil 1.5'ten de görülebileceği üzere; uzak radyo frekansları düşük enerjiye, gama ışınları yüksek enerjiye sahiptir. Gama ışınları ve X-ışınları yüksek enerjiye sahip olmalarından dolayı atom yapısından elektron koparma özelliğine sahiptir. Bu nedenle bu ışınlar iyonlaştırıcı elektromanyetik radyasyon olarak ta adlandırılırlar.

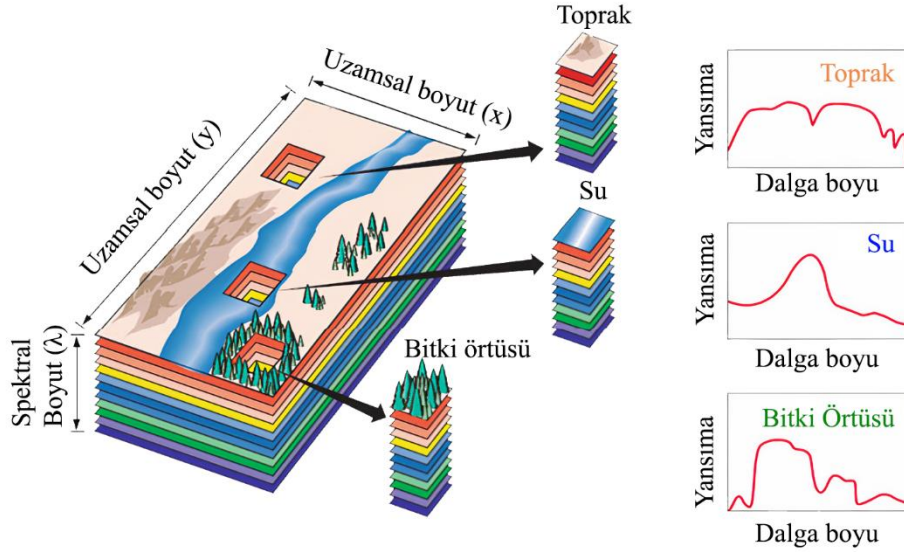


Şekil 1.5 Elektromanyetik Tayf [23]

1.3 Hiperspektral Görüntüleme

Hiperspektral görüntüleme sensörleri, bir sahnenin hem uzamsal hem de spektral özelliklerini algırlar. Bir hiperspektral sensör, yüzlerce bitişik dalga boyunda yansıma verilerini toplar. Bir sensör bir bölge üzerinden veri toplarken, elde edilen veriden üç boyutlu bir veri küpü oluşturulur. Veri küpü; bir dizi dalga boyunda yakalanan, iki boyutlu görüntülerin bir yığını olarak yorumlanabilir. Üç boyutlu veri küpünün her bir ögesi, bir yer konumunda belirli bir dalga boyunda ölçülen ışımaya

karşılık gelir [29]. Şekil 1.6’da bir hiperspektral görüntünün kavramsal diyagramı verilmiştir. Üç boyutlu veri küpü x ve y uzamsal boyutlarından ve λ spektral boyutundan oluşmaktadır [30]. Uzamsal çözünürlükte her bir piksel temsil ettiği malzemeye dair spektral veriye sahip olmaktadır. Kavramsal diyagramda spektral bilgi; su, toprak ve bitki örtüsü için yansımının dalga boyuna göre grafiği olarak temsil edilmiştir.



Şekil 1.6 Hiperspektral görüntünün kavramsal diyagramı [30]


Hiperspektral bir sensör tarafından ölçülen ışımaya, zemindeki malzemeler tarafından yansıtılan ve/veya yayılan radyasyonun bir kombinasyonudur [31]. Pasif sistemlerde, sinyalin yansıyan kısmı, zemin malzemelerine parlayan güneş ışığından yansıyan radyasyon miktarıdır [32]. Sensör ile zemindeki malzemeler arasındaki atmosfer, parlaklık ölçümlerini etkiler. Atmosferdeki su buharı ve oksijen en büyük kayba neden olur. Belirli dalga boylarında, absorpsiyon bantları, su buharı ve oksijen olarak bilinen bantlar, sinyalin büyük bir bölümünü emerek zayıf sinyal gürültü oranına neden olur. Işığı emme özelliklerine ek olarak, ışımanın ölçülebildiği farklı dalga boyları değişen özelliklere sahiptir. Örneğin; 0,4 μm ile 2,5 μm aralığında, güneş ışığı veya başka bir aktif aydınlatma kaynağı gereklidir, çünkü yansıyan parlaklık spektrumun bu kısmına hakimdir. Bunun aksine, 8 μm ile 14 μm arasındaki termal kızılötesi bölgeye yayılan parlaklık baskındır ve bu nedenle aktif bir aydınlatma kaynağı olmadan ölçülebilir.

Hiperspektral görüntülemenin en büyük faydası; farklı malzemelerin EM tayf boyunca değişen miktarlarda yansıttığı ışımaya miktarını ölçebilmesidir. Başka bir deyişle, farklı malzemeler genellikle benzersiz spektral imzalara sahiptir.


Hiperspektral bir sensörün en önemli iki özelliği, spektral ve uzamsal çözünürlüğüdür. Bir sensörün spektral çözünürlüğü; üzerinde parlaklık değerlerinin ölçüldüğü ve hiperspektral bir görüntüde tek bir bant oluşturmak üzere birleştirildiği dalga boyları aralığına karşılık gelir. Uzamsal çözünürlük; tek bir görüntü pikseli için parlaklık ölçümlerinin alındığı zemindeki fiziksel alanın boyutuna karşılık gelir. Bir piksele karşılık gelen alan arttıkça, görüntünün uzamsal çözünürlüğü azalır. Havadaki sistemler için uzamsal çözünürlük genellikle bir görüntü boyunca sabittir. Bununla birlikte, ileriye dönük birçok yer tabanlı sistem için, uzamsal çözünürlük bir görüntü içinde değişebilir. Değişen uzamsal çözünürlük, hiperspektral bir sensörün bir bölgeyi görüntülediği açının bir sonucudur. Sensöre daha yakın olan pikseller, uzaktaki piksellerden daha yüksek uzamsal çözünürlüğe sahiptir. Uzamsal çözünürlük, hiperspektral bir veri setindeki karışık piksellerin nedenlerinden biridir. Karışık piksel, birden çok malzemenin parlaklık değerlerini birleştiren bir pikseldir. Saf piksel, tek bir malzemenin parlaklık değerlerine karşılık gelir. Karışık pikseller, düşük uzamsal çözünürlükten oluşabilir, çünkü bir pikselin zemindeki karşılık gelen alanı arttıkça, komşu malzemelerin görüntü pikselinde birleştirilmesi muhtemeldir. Karışık pikseller, farklı malzemeler zeminde karıştırıldığında da meydana gelir.

1.4 Süper Çözünürlük

Donanımsal kısıtlamalar ve doğal faktörler, görüntünün her zaman istenilen çözünürlükte elde edilmesine imkân vermemektedir. Ancak, uygulamalarda yüksek çözünürlüklü görüntü kullanımı, analiz kalitesini doğrudan etkilemektedir. Süper çözünürlük; bir sahne veya nesneye ait birden fazla düşük çözünürlüklü görüntüden, yüksek frekans bilgi içeren bölümlerin çeşitli yöntemler ile birleştirilerek, yüksek çözünürlüklü görüntü elde edilmesidir. Şekil 1.7'de bir süper çözünürlük uygulaması şematize edilmiştir. Şekil 1.7 (a); aynı sahneye ait üç farklı görüntünün, yüksek geçiren filtre uygulandıktan sonra elde edilen yüksek frekanslı bilgileri temsil etmektedir. Şekil 1.7 (b) ise üç farklı görüntüye ait yüksek frekanslı bilgilerin kaynaştırılmasıyla elde edilmiş süper çözünürlüklü görüntüyü temsil etmektedir [33].



(a)



(b)

Şekil 1.7 Süper-çözünürlük uygulaması, (a) Düşük uzamsal çözünürlüklü girdiler ve alt piksellerinin temsili, (b) alt piksellerin kaydırılarak, birleştirilmesi ile elde edilen süper çözünürlüklü görüntünün temsili [33]

Hiperspektral görüntülerde süper-çözünürlük elde edilmesi ise iki farklı yöntemle yapılmaktadır. Bunlar; tek görüntüden süper-çözünürlüklü görüntü elde etme ve görüntü kaynaştırma yöntemleri ile süper-çözünürlüklü görüntü elde etme olarak sınıflandırılabilir.

Tek görüntüden süper çözünürlüklü görüntü elde etme; çeşitli istatistiksel yöntemler ile komşu piksellerdeki spektral ve uzamsal değerler analiz edilerek çözünürlüğün artırılması yoluyla yapılmaktadır.

Görüntü kaynaştırma yöntemlerinde; uzaktan algılama platformunda yer alan hiperspektral görüntüleme aracının yanına yüksek uzamsal çözünürlüğe sahip multispektral kameralar yerleştirilmekte ve her iki kameradan elde edilen görüntüler, çeşitli yöntemler ile kaynaştırılmaktadır.

1.5 Literatür Taraması

Hiperspektral görüntülerin uzamsal çözünürlüklerinin artırılmasının donanımsal çözümünün maliyetli ve zor bir uygulama olmasından dolayı, görüntü işleme metodları ile çözünürlük artırma uygulamaları literatürde sıkça çalışılmıştır. Çalışmalar, görüntü kaynaştırma tabanlı yöntemler ve tekli görüntü üzerinden süper çözünürlük artırma yöntemleri olarak iki ana başlık altında incelenebilir.

1.5.1 Görüntü Kaynaştırma Tabanlı Yöntemler

Hiperspektral görüntüler için yapılan süper çözünürlük çalışmalarının başında görüntü kaynaştırma tabanlı yöntemler gelmektedir. Alanda öncü sayılabilecek çalışmalardan Zhukov, Oertel, Lanzl ve Reinhackel (1999) çalışmalarında; çoklu sensör çoklu çözünürlük tekniğinin kısıtlı ve kısıtsız algoritmalarını kullanmışlardır. Çoklu sensör çoklu çözünürlük tekniği ile spektral bilgisi katılmış düşük çözünürlüklü görüntülerin spektral bilgisini ayırtmış ve elde edilen spektral bilgi ile yüksek uzamsal çözünürlüklü görüntünün uzamsal bilgisini bağdaştırarak kaynaştıran yeni bir yöntem önermişlerdir. Önerdikleri yöntemi, tematik haritalama özelliği olan LANDSAT uydusundan elde edilen görüntü üzerinde ve EOS-AM1 projesindeki ASTER sensörlerinden elde edilen simülatif görüntünün termal bantları ile çok çözünürlüklü yansıtıcısı üzerinde deneyerek, başarılı sonuçlar elde etmişlerdir [34]. Gomez, Jazaeri ve Kafatos (2001) yaptıkları çalışmada; temel dalgacık dönüşümü kullanarak hiperspektral ve multispektral görüntülerinin piksel düzeyinde görüntü kaynaştırması yapan bir yöntem geliştirmişlerdir. Yöntem, kaynaştırma için yalnızca iki girdi görüntüsü kullanmaktadır. Yöntem sonucunda elde edilen süper çözünürlüklü hiperspektral görüntü, piksel başına 2,8'lik bir ortalama kare hatası (OKH) ve 36 dB'lik sinyal gürültü oranı (SGO) değerlerine sahiptir [35]. Eismann ve Hardie (2004) çalışmalarında; hiperspektral görüntünün uzamsal çözünürlüğünü iyileştirmek için hiperspektral görüntüyü, benzer uzamsal bilgi içeren pankromatik bir görüntü ile maksimum artçıl kestirimi yöntemini kullanarak kaynaştırmışlardır. Önerdikleri

yöntem; kaynaştırılacak hiperspektral ve pankromatik görüntülere göre tahmini hiperspektral sahneyi ve ayrıca spektral karıştırma modelinin yerel istatistiklerini eşzamanlı olarak optimize eden bir maliyet fonksiyonu geliştirmek için, temeldeki spektral sahne içeriğinin stokastik bir karıştırma modelini kullanmaktadır. Stokastik karıştırma modelinin dahil edilmesinin, süper çözünürlüklü bir hiperspektral görüntü oluşturmak için iyi koşullandırılmış doğrusal bir denklem sistemine yol açan gerekli kısıtlamaları sağlaması bakımından, piksel altı spektral bilgilerinin yeniden yapılandırılması için anahtar bileşen olduğunu bulmuşlardır. Yöntemlerini AVIRIS ve DIRSIG görüntülerinde, temel bileşen analizi ve en küçük kareler yöntemleri ile karşılaştırmış ve başarılı sonuçlar elde etmişlerdir [36]. Hardie, Eismann ve Wilson (2004) çalışmalarında; süper çözünürlüklü hiperspektral görüntü oluşturmak için, uzamsal çözünürlüğü yüksek bir pankromatik görüntü ile maksimum artçıl kestirim yöntemini kullanarak kaynaştırma yapmışlardır. Yöntemlerini AVIRIS görüntülerinde; spline enterpolasyonu, koşullu ortalama, doğrusal regresyon yöntemleri ile karşılaştırarak uygulamış ve başarılı sonuçlar elde etmişlerdir [37]. Winter, Winter, Beaven ve Ratkowski (2006) tarafından yapılan çalışmada; hiperspektral görüntünün zengin spektral içeriği ile multispektral görüntünün zengin uzamsal içeriğinin birleştirilmesi için bir yöntem önerilmiştir. Yöntem; iki görüntüdeki bilgiler arasında ilişki kurabilmek için istatistiksel bir model sağlamaktadır. Model çıktısı olan son keskinleştirilmiş görüntünün, keskinleştirilmesi için ayrık kosinüs dönüşümü ve Butterworth filtresi kullanılmıştır [38]. Liao, Huang, Coillie, Gautama, Pižurica, Philips, Liu, Zhu, Shimoni, Moser ve Tuia (2007) çalışmalarında; temel parçacık yöntemi ile düşük uzamsal çözünürlüklü hiperspektral görüntünün özelliklerini çıkarmışlar ve biküçük enterpolasyonu tabanlı bir kılavuzlu filtre ile hiperspektral görüntüyü pankromatik veya RGB görüntü ile kaynaştırmışlardır [39]. Moeller, Wittman ve Bertozzi (2009) çalışmalarında; dalgacık tabanlı bir varyasyon yöntemi ile, kaynaşmış görüntü ve orijinal görüntü arasındaki spektral tutarlılığı sağlayabilen bir hiperspektral süper çözünürlük yöntemi önermişlerdir. Keskinleştirme işlemi uygulamasında seçilen parametre değerleri, AVIRIS ve HYDICE sensörlerinden iki farklı veri kümesi için alternatif yönlü örtük yöntemine ve Split Bregman yöntemine dayanmaktadır. Ancak yöntem sürecinde, netleştirme işleminde bulanıklık giderme teknikleri dikkate alınmadığı için, renklerin karmaşasına neden olmuştur [40]. Chen, Shi ve An (2014); hiperspektral görüntüdeki spektral bant gruplarına ve multispektral görüntüdeki bir banta, birden çok kez pan

keskinleştirme algoritmaları uygulayarak, hiperspektral ve multispektral görüntülerinin kaynaştırılması için pan keskinleştirme yaklaşımını önermişlerdir. Çalışmalarında hiperspektral görüntüdeki gruplandırılmış bantlar arasında, multispektral görüntüsünün herhangi bir bandının kapsamadığı bant grubu için, eksik verileri doldurabilen bir yöntem önererek spektral yeniden örnekleme yöntemi kullanılmıştır [41]. Zhang, De Backer ve Scheunders (2008) çalışmalarında; ondalıksız bir iki boyutlu dalgacık dönüşüm domeninde, hiperspektral ve multispektral görüntülerin kaynaştırılması sonucu elde edilen süper çözünürlüklü hiperspektral görüntüyü, Bayes tahmini kullanarak gerçekleştirmişlerdir. Görüntülerin ortak normal dağılım modeline uyduğu varsayıldığında, model parametrelerinin tahmini için, görüntüler arasındaki çözünürlük farkı bilgisi gerektirmektedir [42]. Zhang, De Backer ve Scheunders (2009) diğer bir çalışmalarında; eksik veri, spektral yeniden örnekleme ve ters evrişimin interpolasyon problemlerini ele almak için öncü Gauss kullanmıştır. Çalışmalarında, atraous algoritması ile uygulanan ondalık olmayan bir dalgacık dönüşümünü kullanmışlardır. Ancak yöntemleri, giriş görüntüleri arasındaki çözünürlük farkı bilgisine ihtiyaç duymaktadır [43]. Wei, Dobigeon ve Tournet (2014) tarafından yapılan çalışmada; sensörün spektral tepki fonksiyonu bilinmeyen durumlarda, hiperspektral ve multispektral görüntülerin kaynaştırılmasını yüksek uzamsal çözünürlükte bilinen öncelikler tanıtılarak bir Bayes tahmin çerçevesi kullanılarak formüle edilmiştir [44]. Palsson, Sveinsson, Ulfarsson ve Benediktsson (2015); hiperspektral görüntü için, dalgacık model tabanlı füzyon olarak adlandırılan, temel bileşen analizi ile daha düşük boyutlu bir alt uzayda ele alınan bir füzyon yöntemi önermişlerdir. Yöntemleri, teknik boyutsallık azaltmayı ve dolayısıyla hesaplama kolaylığı sağlamaktadır [45]. Bendoumi, Mingyi ve Shaohui (2014); Vertex Bileşen Analizi algoritmasıyla çıkarılan son üyeler ve kısıtsız en küçük kareler karıştırma algoritmasıyla çıkarılan bolluk haritalarını kullanarak hiperspektral ve multispektral görüntülerin spektral karıştırmama tabanlı görüntü füzyonunu önermiştir [46]. Yokoya, Yairi ve Iwasaki (2012) tarafından geliştirilen Birleştirilmiş Negatif Olmayan Matris Çarpanlara ayırma yönteminde; tam kısıtlı en küçük kareler doğrusal spektral karışım analizi yöntemi kullanılarak çıkarılan bolluk haritalarının, hesaplama zorluğunu düşürmede etkili olduğu kanıtlanmaktadır. Ancak, yeniden oluşturma hatası tahmini tamamen son eleman spektrumlarının doğruluğuna ve fark görüntülerinde bulunan görüntü dokusuna bağlıdır [47]. Bendoumi, He, Mei ve Zhang (2012); multispektral bantlara eşit veya daha az sayıda son elemana sahip bir spektral

kariştirmama yaklaşımları kullanarak, yüksek hesaplama maliyetinin üstesinden gelmektedirler [48]. Borsoi, Imbiriba ve Bermudez (2019) tarafından önerilen yöntemde; farklı zaman aralıklarında elde edilen görüntülerde var olan spektral değişkenlik, etkin bir şekilde füzyon problemine dahil edilmiştir. Spektral değişkenliği hesaba katan farklı zaman aralıklarında elde edilen görüntüler için test edilen deneysel sonuçlar, yöntemin üstün performans sağladığını göstermektedir [49]. Li, Dan, Fang ve Bioucas (2018) önerdikleri yöntemlerinde; birleştirilmiş görüntüyü oluşturan genişlik, yükseklik, spektral ayrıntılar için bir çekirdek tensörü ve seyrek sözlüğü tahmin etmişlerdir. Tucker ayrıştırmasını kullanan yöntem, düşük uzamsal çözünürlüklü hiperspektral ve yüksek uzamsal çözünürlüklü multispektral görüntünün kaynaştırılmasını, seyrek tensör çarpanlarına ayırması olarak formüle etmektedir [50]. Zhang, Wang, Yang ve Jiao (2018), kaynaştırma problemini; multispektral görüntüden uzamsal tutarlılık ve hiperspektral görüntüden spektral pürüzsüzlük ile ilgili iki grafik oluşturarak, düşük dereceli bir tensör ayrıştırma modeli olarak formüle etmişlerdir. Düşük dereceli özelliği kodlamak için Tucker ayrıştırma modelini kullanmışlardır. Uzamsal spektral grafik düzenlenmiş düşük sıralı tensör ayrıştırma adını verdikleri yöntemlerinde, tüm düzenleyicilerin kombinasyonu kaynaşmış görüntüyü oluşturmuştur [51]. Wei, Bioucas-Dias, Dobigeon ve Tourneret (2014); Online Sözlük Öğrenme algoritmasından görüntü sözlüklerini ve Ortogonal Eşleştirme Takibi'nden seyrek kodları kullanan, seyrek temsile dayalı bir algoritma önermişlerdir. Yöntem, farklı kalite ölçütlerinde test edilmiş olsa da benzersiz bir tahmin prosedürü olmadığından, düzenleme parametresi değerleri manuel olarak ayarlanmıştır [52]. Huang, Song, Cui, Peng ve Xu (2013); seyrek matris çarpanlarına ayırma kullanan bir uzamsal ve spektral kaynaştırma modeli önermişlerdir. K-SVD algoritması kullanılarak elde edilen hiperspektral görüntülerinden öğrenilen spektral imzaların sözlükleri, istenen yüksek uzamsal ve yüksek spektral çözünürlüklü çıktı görüntüsünün tahmin edilmesi için kullanılmıştır. Yöntem, tüm bantlarda uzamsal ayrıntıları koruma konusunda diğer algoritmalarından daha iyi performans gösterdiğini, ancak ön işleme operasyonlarından kaynaklanan birkaç spektral bozulma olduğunu göstermektedir. Yaklaşımda optimize edilmiş bir ön işleme prosedürü analiz edilmemiştir ve karmaşıklık yüksektir [53]. Akhtar, Shafait ve Mian (2015) çalışmalarında; seyrek temsili kullanarak görüntü kaynaştırma temelli yeni bir süper çözünürlük yöntemi önermişlerdir. Yöntemlerinde, düşük uzamsal çözünürlüklü görüntü ile yüksek uzamsal çözünürlüklü görüntü, seyrek gösterimini kullanarak ortak

bir sözlük ve seyreklik kat sayısı üretmektedir. Girdi olarak verilen düşük uzamsal çözünürlüklü görüntüsünün; oluşturulan sözlük ve seyreklik katsayısı kullanılarak yüksek uzamsal çözünürlüklü görüntü eldesini sağlamaktadır. Yöntemlerini CAVE ve Harvard veri setlerinde denemişler; diğer görüntü kaynaştırma temelli çalışmalara göre başarılı sonuçlar elde etmişlerdir [54]. Palssoni, Sveinsson ve Ulfarsson (2017); hiperspektral ve multispektral görüntü kaynaştırması için 3 boyutlu evrişimsel sinir ağı kullanan yöntem önermişlerdir. Eğitimi sırasında ağ, kaynaşmış görüntü ile hedef görüntü arasındaki ortalama kare hatasını en aza indirmeye ve uyarlanabilir moment tahmini kullanarak optimize etmeye odaklanmaktadır [55]. Han, Shi ve Zheng (2018) çalışmalarında; süper çözünürlüklü hiperspektral görüntü eldesini, düşük çözünürlüklü bir hiperspektral görüntü ile yüksek çözünürlüklü RGB görüntüsünün kaynaştırılmasının, sınırlı uygulanabilirliği, kısıtlılık gösterimi ve spektral özellikler gibi ön bilgilerle bir optimizasyon problemi olarak ele almışlardır. Yöntemlerinde, hiperspektral görüntü süper çözünürlüğü uygulamasında uzamsal ve spektral füzyonun avantajlarından yararlanmak için iki farklı derin erişimli ağ mimarisi önermişlerdir. Yöntemleriyle, CAVE ve Harvard veri setlerinde yapmış oldukları denemelerde başarılı sonuçlar elde etmişlerdir [56]. Zhou, Hang, Liu ve Yuan (2019); evrişimli sinir ağı kullanarak, hiperspektral ve multispektral görüntü füzyonu yöntemi önermişlerdir. Süper çözünürlüklü hiperspektral görüntü, füzyon alt ağındaki hiperspektral ve multispektral görüntü piramitleri kullanılmak suretiyle kademeli olarak yükseltilecek yeniden oluşturulmuştur. Gradyan farkı kaybının dikkate alınması, oluşturulan süper çözünürlüklü görüntüyü daha da iyileştirmiştir [57]. Han ve Chen (2019); süper çözünürlüklü görüntü elde etmek için hiperspektral ve multispektral görüntülerini birleştirmede derin kalıntı ağı tasarlamıştır. Kalıntı ağ bloğu, uzamsal yeniden yapılandırmaya tabi tutulmak üzere, hiperspektral ve multispektral görüntülerin spektral yeniden yapılandırmasını ve kalıntı bloğun girdi özellik haritalarını gerçekleştirerek, çıktı özellik haritalarını üretmek üzere tasarlanmıştır. Uygulama sonuçları, yöntemin verimliliğini kanıtlamıştır [58]. Han, Yu, Luo ve Sun (2019) yöntemlerinde; çok dallı bir geri beslemeli sinir ağı kullanan küme tabanlı bir füzyon yöntemi önermişlerdir. Yöntemlerinde kullandıkları geri beslemeli sinir ağı dizisi; süper çözünürlüklü hiperpsektral görüntünün spektrumunu üretmek için, düşük uzamsal çözünürlüğe sahip multispektral görüntünün denetlenmeyen kümelerinin spektrumları kullanılarak eğitilmiştir. Bu eğitilmiş ağ, denetimli hiperspektral ve multispektral görüntü kümelerini kabul ederek, hedef süper çözünürlüklü görüntüyü

yeniden yapılandırmak için doğrusal olmayan spektral haritalama gerçekleştirmiştir [59]. Xu, Wu, Chanussot, Comon ve Wei (2019); çalışmalarında matris çarpanlarına ayırma tabanlı yöntemlerin yüksek uzamsal çözünürlüklü hiperspektral görüntü ve multispektral görüntü arasındaki ilişkiyi iyi kuramaması problemi üzerine çalışmışlardır. Geliştirdikleri yöntemlerinde, hiperspektral ve multispektral görüntü füzyonu için yerel olmayan bir tensör ayrıştırma modeli önermişlerdir. Bu yöntem sayesinde, multispektral görüntünün uzamsal bilgisi hiperspektral görüntüye başarıyla aktarılabilmiştir. Yöntemlerini, sentetik veri seti ve Pavia veri seti üzerinde denemişler ve başarılı sonuçlar elde etmişlerdir [60]. Wan, Guo, Huang ve Liu (2020); çalışmalarında tekli görüntü üzerine geliştirilen süper çözünürlük yöntemlerinin, füzyon tabanlı yöntemlere göre yeterli sonuçlar üretememesi problemi üzerine çalışmışlardır. Çalışmalarında, benzer 3 boyutlu görüntü küplerini kümeler halinde gruplayarak ve daha sonra 4 boyutlu tensör yapısını kullanarak kümeler halinde süper çözünürlük uygulaması gerçekleştirmişlerdir. Önerdikleri yöntem ile yalnızca yapıyı korumakla kalmamış, aynı zamanda benzer küplerin toplanması nedeniyle küme içinde seyreklik elde etmişlerdir. Yöntemlerinde, 4 boyutlu tensör için Tucker ayrıştırmasını kullanmışlardır ve sözlükler ile grup bloğu seyrekliğine negatif olmayan kısıtlamalar getirmişlerdir. Çalışmalarını Indian Pines veri setinde denemişler ve başarılı sonuçlar elde etmişlerdir [61]. Wei, Nie, Zhang ve Zhang (2020) çalışmalarında, derin sinir ağı kullanarak düşük ve yüksek uzamsal çözünürlüklü görüntülerden istatistiksel bilgiler elde etmişler ve bu bilgiler doğrultusunda düşük ve uzamsal çözünürlüklü görüntüleri kaynaştırmışlardır. Denetimsiz yineleme tabanlı bir süper çözünürlük yöntemi olarak isimlendirdikleri yöntemlerinde; denetimsiz öğrenmeyi kendi kendine denetlemek için yeniden yapılandırma ara sonuçlarını kullanan, piksel duyarlı iyileştirme uygulamışlardır. Önerilen yöntem, görüntüye özgü karakteristik bilgilerini içermesi nedeniyle, mevcut yöntemlere kıyasla hem doğruluk hem de gürültüye karşı dayanıklılık açısından başarılı sonuçlar üretmektedir [62]. Şimşek ve Polat (2021) çalışmalarında, füzyon tabanlı pan-keskinleştirme yöntemleri olan IHS ve PCA ile sözlük öğrenmeye dayalı seyrek temsil yöntemleri olan K-SVD, ODL ve Bayes yöntemlerinin kapsamlı bir karşılaştırmasını yaparak performanslarını değerlendirmişlerdir. CAVE veri seti üzerinde yaptıkları deneylerinde, ODL yönteminin diğer yöntemlerden daha iyi sonuç verdiğini göstermişlerdir [63]. Vella, Zhang, Chen, ve Mota, (2021), çalışmalarında hiperspektral görüntülerin süper çözünürlük uygulaması için, RGB görüntüler ile füzyon edildiği bir yöntem

önermişlerdir. Çalışmalarında, derin öğrenme tabanlı füzyon yöntemlerinin diğer yöntemlere göre daha başarılı olduğunu ancak model ağ tarafından öğrenilen parametrelerin test görüntüleri üzerinde garantili sonuç vermemesi probleminden dolayı, öğrenme ve model tabanlı yöntemleri birleştiren bir yöntem önermişlerdir. Yöntemlerini CAVE ve Harvard veri setlerinde denemiş ve başarılı sonuçlar elde etmişlerdir [64]. Li, Zhang, Ge, Cao, Shi, ve Fu (2021) çalışmalarında, hiperspektral görüntü ve multispektral görüntüyü birleştirmek için yeni bir uyarlanabilir, negatif olmayan seyrek temsil tabanlı model önermişlerdir. Yöntemleri, doğrusal spektral karıştırmayı temel alarak, negatif olmayan yapılandırılmış seyrek temsil modeli ile süper çözünürlüklü hiperspektral görüntünün seyrek kodlarını tahmin etmektedir. Ardından, uyarlanabilir seyrek gösterim, uygun bir katsayı üreterek seyreklik ve görüntüler arasındaki ilişkiyi dengelemektedir. Son olarak, spektral temeli ve katsayıları dönüşümlü olarak; yön değiştiren çarpanlar yöntemi ile optimize etmişlerdir. Yöntemlerini CAVE ve Pavia veri setlerinde denemişler ve başarılı sonuçlar elde etmişlerdir [65]. Wang, Chen, Wei ve Richard (2021) çalışmalarında füzyon problemini; Sylvester denklemi çözülerek elde edilebilecek bir optimizasyon problemi olarak formüle etmişlerdir. Fiziksel bir model ile derin ön bilgileri birleştiren iki aşamalı füzyon ağı modelleri; füzyon problemi için bir düzenleyici olarak etkili sonuçlar vermektedir [66]. Mianji, Gu, Zhang ve Zhang (2011) çalışmalarında; hiperspektral görüntülerin, uzamsal ve spektral verilerini kullanarak kaynaştırma temelli bir süper çözünürlük tekniği önermişlerdir. Çalışmalarında, bir hiperspektral görüntünün uzamsal ve spektral bilgilerini, doğrusal bir karışım modeli ve tamamen kısıtlı en küçük kareler karıştırmama tekniği ile çıkarmışlardır. Çıkardıkları verileri, öğrenme tabanlı bir süper çözünürlüklü haritalama algoritması aracılığıyla bir uzamsal korelasyon modeli kullanarak birleştirmişlerdir. Önerdikleri uzamsal korelasyon modeli; düşük çözünürlüklü hiperspektral görüntüsü ile alt örneklenmiş versiyonu arasında, bir haritalama modelini gerçekçi bir şekilde simüle etmiştir. Yöntemlerini Indian Pines ve San Diego veri setlerinde denemiş ve başarılı sonuçlar elde etmişlerdir [67].

1.5.2 Tekli Görüntü Üzerinden Yapılan Yöntemler

He, Zhou, Wang, Cao ve Han (2016) çalışmalarında; hiperspektral görüntülerde süper çözünürlük için, uzamsal ve spektral korelasyon ve yerel pürüzsüzlük özelliklerini modelleyerek yeni bir yöntem önermişlerdir. Çalışmalarında, hiperspektral

görüntülerde gizlenmiş uzamsal ve spektral korelasyonu tanımlamak için tensör nükleer normu, tensör katlanmış içbükey ceza fonksiyonlarını ve tüm hiperspektral boyunca yerel uzamsal ve spektral pürüzsüzlüğü karakterize etmek için üç boyutlu toplam varyasyonu kullanmışlardır. Ortaya çıkan optimizasyon problemini çözmek için ise, yerel doğrusal yaklaşım ve çarpanların alternatif yönü yöntemlerini kullanarak hibrit bir yöntem geliştirmişlerdir. Yöntemlerini AVIRIS sensöründen elde edilen Moffett alanı görüntüsünde deneyerek başarılı sonuçlar elde etmişlerdir [68]. Hu, Li ve Xie (2017) çalışmalarında; hiperspektral süper çözünürlüğü için hibrit bir uzamsal hata düzeltme modeli ile spektral fark evrişimli ve derin sinir ağı kombinasyonlu bir model önermişlerdir. Yöntemleri; uzamsal bilgiyi iyileştirirken, spektral bilginin maksimum oranda korunmasını sağlamaktadır. Önerdikleri derin spektral fark evrişimli sinir ağı; uzamsal bilgi ile spektral bilgi arasındaki ilişkiyi öğrenmektedir. Yöntem, öğrendiği bilgi ile uzamsal çözünürlüğün artırılmasından sonra geri kaynaştırma esnasında, maksimum verim ile süper çözünürlüklü görüntüyü oluşturmaktadır. Önerdikleri yöntemi CAVE veri setinde deneyerek başarılı sonuçlar elde etmişlerdir [69]. Lei, Shi ve Zou (2017) çalışmalarında; derin evrişimli sinir ağlarını kullanarak bir yöntem önermişlerdir. Yöntemlerinde; hem yerel ayrıntılar hem de küresel öncelikler dahil olmak üzere, uzaktan algılama görüntülerinin çok düzeyli temsillerini öğrenmek için çok katmanlı bir yapı kurmuşlardır. Önerdikleri yöntemi UC Merced veri setinde deneyerek genel algoritmalara göre iyileştirme yakalamışlardır [70]. Yuan, Zheng ve Lu (2017) çalışmalarında, öğrenme aktarımı tekniğinden yola çıkmışlardır. Çalışmalarında; aynı sahneye ait olmayan fakat benzer özelliklere sahip doğal görüntülerin, düşük ve yüksek uzamsal çözünürlükleri arasındaki ilişkiyi öğrenerek, hiperspektral görüntülerin düşük ve yüksek uzamsal çözünürlüğüne aktarmışlardır. Yöntemlerinde düşük ve yüksek uzamsal çözünürlük arasındaki ilişkiyi, derin evrişimli sinir ağlarını kullanarak çıkarmışlardır. Düşük ve yüksek uzamsal çözünürlüğe sahip hiperspektral görüntülerin spektral karakteristiğini ise işbirlikçi negatif olmayan matris ayrışımı yöntemiyle çıkarmışlardır. Yöntemlerini; CAVE, Nature, Pavia, Paris ve Montana veri setlerinde deneyerek başarılı sonuçlar elde etmişlerdir [71]. Li, Hu, Zhao, Xie ve Li (2017) çalışmalarında; evrişimli sinir ağı ile uzamsal kısıtlama stratejisini birleştirerek, spektral veriyi koruyan bir süper çözünürlük yöntemi önermişlerdir. Uzamsal kısıtlama stratejisi; yeniden yapılandırılmış süper çözünürlüklü hiperspektral görüntü tarafından oluşturulan düşük çözünürlüklü hiperspektral görüntüyü, orijinal düşük

uzamsal çözünürlüklü hiperspektral görüntü girişine uzamsal olarak yakınsak sınırlandırır ve uzamsal çözünürlüğü artırmayı amaçlar. Evrişimli sinir ağı modeli, düşük uzamsal çözünürlüklü hiperspektral görüntü ve süper çözünürlüklü hiperspektral görüntü arasında, uçtan uca bir spektral fark eşlemesi öğrenmektedir. Böylece uzamsal çözünürlük artırılırken, spektral çözünürlük korunmuş olur. Yöntemlerini; CAVE, Harvard ve Foster veri setlerinde denemiş ve başarılı sonuçlar elde etmişlerdir [72]. Irmak, Bozdağı Akar ve Esen Yüksel (2018) çalışmalarında; tekli görüntü süper çözünürlüğü için Bayes yaklaşımını kullanan bir yöntem önermişlerdir. Yöntemlerinde; spektral domenindeki kötü konumlandırılmış süper çözünürlük problemini, bolluk haritası domeninde ikinci dereceden bir optimizasyon problemine dönüştürmeyi hedeflemişlerdir. Düşük uzamsal çözünürlüklü görüntü üzerinde; son üye sayısı ve onların bolluk haritaları, Lagrange ve kısıtlanmış en küçük kareler yöntemleriyle elde edilmiştir. Elde edilen düşük uzamsal çözünürlüğe ait bolluk haritalarından, en büyük artımlı kestirimi yöntemi kullanılarak yüksek uzamsal çözünürlüklü görüntüye ait bolluk haritaları elde edilmiştir. Son olarak, çıkarılan son eleman ve geliştirilmiş bolluk haritaları yeniden yapılandırılarak süper çözünürlüklü görüntü elde edilmiştir [73]. Li, Zhang, Ding, Wei ve Zhang (2018) çalışmalarında; özel bir derin sinir ağıyla düşük çözünürlüklü bir hiperspektral görüntü ile yüksek çözünürlüklü bir hiperspektral görüntü arasında doğrudan eşleşmeyi öğrenen bir model önermişlerdir. Kompakt bir ağ ile karmaşık doğrusal olmayan eşleme işlevini iyi betimlemek ve giriş görüntülerini dönüştürmek için küresel artımlı yapıya gruplanmış bir öz-yinelemeli modül geliştirmişlerdir. Ayrıca, süper çözünürlük sonuçlarında hem sayısal hatayı hem de spektral bozulmayı azaltmayı sağlayan ağ parametrelerini öğrenmek için; geleneksel ortalama kare hatası kaybını, spektral açı eşleyici kaybıyla birleştirmişlerdir. Yöntemlerini, Harvard veri setinde denemiş ve başarılı sonuçlar elde etmişlerdir [74]. Jia, Ji, Zhao ve Geng (2018) çalışmalarında; derin evrişimli sinir ağlarını kullanarak, süper çözünürlüklü hiperspektral görüntü oluşturma yöntemi önermişlerdir. Yöntemlerini, spektral ve uzamsal bölümler olarak ikiye ayırmışlardır. Uzamsal çözünürlüğü iyileştirirken, modellerinde düşük ve yüksek uzamsal çözünürlüklü görüntülerin spektral bilgileri arasında bir eşleşme öğretmek, spektral verinin korunmasını sağlamışlardır. Yöntemlerini CAVE ve Harvard veri setlerinde deneyerek başarılı sonuçlar elde etmişlerdir [75]. Zheng, Gao, Ran, Cui, Zhang, Liao ve Jia (2019), çalışmalarında doğal görüntüler için geliştirilen 2 boyutlu evrişim tabanlı modellerin, hiperspektral görüntüler üzerindeki süper çözünürlük

uygulamalarında spektral veriyi bozmasının ve 3 boyutlu evrişim kullanarak geliştirilen modellerin ise işlem yükünden dolayı derinleşememesinin üzerine, hiperspektral görüntülerin her bir bandına ayrı ayrı 2 boyutlu evrişim uygulayarak birleştiren bir model önermiştir. Modellerini, CAVE ve Pavia veri setlerinde deneyerek başarılı sonuçlar elde etmişlerdir [76]. Xie, Jia, Li ve Lei (2019) çalışmalarında; derin sinir ağı tarafından çıkarılan öznelik matrisi ile negatif olmayan matris çarpanlara ayırma metodlarını harmanlayan hibrit bir yöntem önermişlerdir. Yöntemlerinde; düşük uzamsal çözünürlüğe sahip hiperspektral görüntü, korelasyon matrisine göre alt kümelere ayrılarak, her bir alt küme içerisinde spektral bantlardan anahtar bant seçer. Anahtar bantlar, derin sinir ağı modeli ile süper çözünürlük için kullanılmaktadır. Elde edilen bilgi, spektral verinin korunması için modelin bir sonraki aşamasında kılavuz olarak kullanılmaktadır. Yöntemlerini CAVE, Harvard ve Foster veri setleri üzerinde deneyerek başarılı sonuçlar elde etmişlerdir [77]. Wang, Li ve Li (2020) çalışmalarında; hiperspektral görüntü süper çözünürlüğü için yeni bir spektral-uzamsal metot önermişlerdir. Yöntemlerinde; potansiyel bilgileri daha iyi çıkartmak için 2 boyutlu evrişimli sinir ağı yerine 3 boyutlu evrişimli sinir ağı kullanarak, uzamsal-spektral bilgileri etkili bir şekilde çıkartmışlardır. Yöntemlerini CAVE, Harvard ve Foster veri setleri üzerinde denemiş ve başarılı sonuçlar elde etmişlerdir [78]. Arun, Buddhiraaju, Porwal ve Chanussot (2020) çalışmalarında; hiperspektral görüntülerin uzamsal-spektral özelliklerini daha iyi bir uzamsal çözünürlükle eşleştirebilen, 3 boyutlu evrişimli sinir ağı tabanlı tek görüntüden süper çözünürlüklü görüntü oluşturma yöntemi önermişlerdir. Önerileri, süper çözünürlük hedefi ile ilgili olarak seyrek kodların ve sözlüklerin eşzamanlı optimizasyonuna dayanmaktadır. Yöntemlerinde kayıp fonksiyonlar tasarlanırken, uç üye benzerlikleri ve spektral bilgi önsel olarak dikkate alınmıştır. Yöntemlerini KSC, Salinas, Pavia ve Indian Pines veri setlerinde deneyerek başarılı sonuçlar elde etmişlerdir [79]. Li, Wang ve Li (2020) çalışmalarında; hiperspektral görüntü süper çözünürlüğü için bir karma evrişimli ağ önermişlerdir. Potansiyel özellikleri, tek bir evrişim yerine, 2 boyutlu ve 3 boyutlu evrişim yoluyla çıkarmak için yeni bir karma evrişim modülü önermeleridir. 2 boyutlu modellerinde; görüntüden etkili özellikleri keşfetmek için, 2 boyutlu sinir ağının katmanlarındaki tüm hiyerarşik özelliklerden faydalanarak uyarlamalı analiz yapmak için yerel özellik füzyonunu tasarlamışlardır. 3 boyutlu modellerinde; uygun olmayan bellek kullanımını ve eğitim süresini azaltan uzamsal ve spektral bilgileri çıkarmak için, uzamsal ve spektral ayrılabilir 3 boyutlu evrişimli sinir ağı kullanmışlardır [80].

Li, Cui, Li, Song, Li, Dai ve Du (2020) çalışmalarında; çekişmeli öğrenme yöntemi kullanarak, yeni bir süper çözünürlük yöntemi önermişlerdir. İlk olarak, elde edilen yüksek çözünürlüklü hiperspektral görüntüden daha fazla ayrıntı çıkarabilmek için, çözünürlük iyileştirme sürecini, çekişmeli üretici ağlar ile geliştirmişlerdir. Spektral bantların korelasyonunu araştırmak ve spektral bozulmayı önlemek için yöntemlerinde bir bant dikkat mekanizması önermişlerdir. Spektral bozulmayı ve doku bulanıklığını daha da azaltarak, üretici yöntemlerine rehberlik etmesi için bir dizi uzamsal-spektral kısıtlama veya kayıp işlevi uygulamışlardır. Pavia ve Cave veri kümeleri üzerinde deneyerek başarılı sonuçlar üretmişlerdir [81]. Jiang, Sun, Liu ve Ma (2020) çalışmalarında; tek hiperspektral görüntü süper çözünürlüğü için öğrenme tabanlı, uzamsal bilgiden ve hiperspektral verilerin spektrumları arasındaki korelasyondan tam olarak yararlanabilen, SSPSR olarak isimlendirdikleri bir yöntem önermişlerdir. Paylaşılan ağ parametreleriyle hiperspektral bir grup evrişimi ve aşamalı üst örnekleme çerçevesi önerilmiştir. Yöntemleri, hiperspektral verilerin yüksek boyutu nedeniyle özellik çıkarmadaki zorluğu kolaylaştırırken, aynı zamanda eğitim sürecini daha kararlı hale getirmektedir [82]. Hu, Jia, Li, He ve Zhao (2020) çalışmalarında; hiperspektral görüntülerin süper çözünürlük uygulamaları için 3 modülden oluşan yöntem önermişlerdir. Çalışmalarında, hiperspektral görüntülerin süper çözünürlük uygulamalarının temel zorluğu olarak, uzamsal bilginin yanı sıra ardışık düşük çözünürlüklü bantlar arasındaki spektral bilginin nasıl verimli bir şekilde kullanılacağı üzerine durmuşlardır. Önerdikleri yöntemde yer alan spektral fark modülü; spektral bandı ayrı olarak değerlendirdikten sonra, benzer spektral bantlar arasından seçim yaparak paralel evrişim modülü ile özniteliklerini çıkartmaktadır. Füzyon katmanı aracılığıyla, spektral bilgi ve uzamsal bilgi ayrı ayrı değerlendirilerek birleştirilmektedir. Yöntemlerini, ICVL, Pavia Center ve Washington DC Mall veri setlerinde denemişler ve başarılı sonuçlar almışlardır [83]. Tang, Xu, Shi ve Pan (2021), tekli hiperspektral görüntü süper çözünürlüğü uygulaması üzerine çalışmışlardır. Bu problemin çözümü için geliştirilen derin öğrenme algoritmalarından yararlanarak, iyileştirilmiş geri beslemeye sahip yerel bir küresel ağ modeli önermişlerdir. Önerdikleri ağ modeli, uzamsal ve spektral özellik çıkarımını kolaylaştırmaktadır. Model içerisindeki geri bildirim yapısı, sonlu açılımlara sahip tekrarlayan bir yapı ile elde edilen düşük seviyeli özelliğin üretim sürecine rehberlik etmek için yüksek seviyeli bilgiyi aktarmaktadır. Ayrıca, geri iletilen üst düzey bilgiyi etkin bir şekilde kullanmak ve geri besleme bağlantılarını işlemek için model

içerisinde yerel bir spektral blok oluşturulmuştur. Oluşturulan blok, yerel spektral bantlardan düşük seviyeli özelliği düzeltmek için geri besleme ile yüksek seviyeli bilgiyi kullanmakta ve global spektral bantlar arasında güçlü yüksek seviye temsiller üretmektedir. Model bütün olarak, geri besleme yapısını ve yerel spektral bloğu birleştirerek, uzamsal bilgi ve spektral bilgi arasındaki korelasyondan yararlanmakta ve yüksek çözünürlüklü hiperspektral görüntüleri kademeli olarak yeniden yapılandırmaktadır. Yöntem, CAVE, Harvard ve Chikusei veri setlerinde denenmiş ve başarılı sonuçlar elde edilmiştir [84]. Li, Wang ve Li (2021) çalışmalarında, 2 boyutlu ve 3 boyutlu evrişimin arasındaki ilişkiyi çıkartarak süper çözünürlüklü görüntü eldesini sağlayan yeni bir model önermişlerdir. Yöntemleri, spektral özellikler çıkarıldığında daha fazla uzamsal bilgi öğrenmek için yeniden oluşturma aşamasında dönüşümlü olarak 2 boyutlu ve 3 boyutlu evrişim katmanlarını kullanmaktadır. Önerilen model, CAVE, Harvard ve Pavia Centre veri setlerinde denenmiş ve hem 2 boyutlu hem de 3 boyutlu evrişim kullanılması sayesinde modelin performansı artırılarak başarılı sonuçlar elde edilmiştir [85]. Fu, Liang ve You (2021) çalışmalarında; hiperspektral süper çözünürlüğü için rastgele sayıda bantla, çift yönlü bir 3 boyutlu yarı tekrarlayan sinir ağı tasarlamışlardır. Yöntemlerinde, sırasıyla spektrum boyunca yapısal uzamsal-spektral korelasyonu ve global korelasyonu etkin bir şekilde çıkarmak için bir 3 boyutlu evrişim modülü ve iki yönlü yarı tekrarlayan havuzlama modülü içeren bir sinir ağı önermişlerdir. Ayrıca hiperspektral görüntünün alan bilgisini, yeni bir ön eğitim stratejisiyle birleştirmişlerdir. Böylece yöntemleri, sınırlı sayıda eğitim verisi içeren hiperspektral veri kümelerine genelleştirilebilmektedir [86]. Liu, Li ve Yuan (2021) çalışmalarında; tüm spektral bantların modellenmesini kolaylaştırmak ve uzamsal-spektral özelliklerin keşfedilmesi için, spektral gruplama ve dikkat odaklı yoğun kalıntı ağ olarak adlandırılan, derin evrişim ağı tabanlı yeni bir hiperspektral süper çözünürlük yöntemi önermişlerdir. Hiperspektral görüntülerin yapısal karakteristiğinden dolayı uzamsal özellikleri çıkarmak ve normal evrişimin neden olduğu spektral düzensizliği önlemek amacıyla, benzer spektral bantlardan oluşan gruplar içinde ve arasında grup evrişimleri kullanmışlardır. Spektral bilgiden yararlanmak ve özellikleri uyarlanabilir şekilde yeniden kalibre etmek için kovaryans istatistikleriyle oluşturulan yeni bir spektral inceleme mekanizması tasarlamışlardır. Uzamsal-spektral özellikleri daha iyi elde etmek için yoğun kalıntı blok yapısını kullanmışlardır [87]. Wang, Ma ve Jiang (2021) çalışmalarında; spektrum korelasyonlarını dizi perspektifinden modelleyen yeni bir

tek hiperspektral görüntü süper çözünürlük yöntemi önermişlerdir. Özellikle, hiperspektral verilerin spektrumları arasındaki tamamlayıcı ve ardışık bilgilerden tam olarak yararlanmak amacıyla tekrarlayan bir geri bildirim ağı oluşturmuşlardır. Grup stratejisiyle, her gruplama bandı arasında ilk olarak, geri bildirim aralarındaki ardışık bilgileri keşfederek süper çözünürlük uygulamışlardır. Hiperspektral veriler arasındaki uzamsal-spektral yapının daha iyi korunması için, ara tahmin üzerinde uzamsal-spektral korelasyonları amacıyla düzenleme ağı eklemişlerdir [88]. Wang, Li ve Li (2021) çalışmalarında; bitişik bantlar arasındaki yüksek benzerlikten esinlenerek, önceki çalışmalardan farklı olarak, hem tek bant hem de bitişik bantlardan gelen bilgileri ortaklaşa kullanmak amacıyla 2 boyutlu ve 3 boyutlu evrişim ağını beraber kullanarak çift kanallı bir ağ tasarlamışlardır. Önerileri, bilginin tamamlayıcılığına katkıda bulunan ve ağ yapısını basitleştiren önceki banttan çıkarılan özellikleri tanıtmaktadır. Elde edilen özellikler kullanılarak uygulanan, bağlam füzyonu sayesinde, algoritmanın performansı önemli ölçüde arttırmaktadır [89].

1.5.3 Literatürün Değerlendirilmesi

Süper çözünürlük, yüksek çözünürlük ile elde edilmesi istenen bir sahneye ait görüntünün; görüntüleme aracının donanımsal olarak iyileştirilmeden, görüntünün çeşitli görüntü işleme algoritmaları kullanılarak yazılımsal olarak geliştirilmesi işlemidir. Literatürde yapılan çalışmalar incelendiğinde; çalışmalar görüntü kaynaştırma tabanlı yöntemler ve tekli görüntü üzerinde yapılan yöntemler olmak üzere iki ana başlıkta sınıflandırılabilir. Her iki başlıktaki çalışmalara bakıldığında hiperspektral görüntüler için süper çözünürlük problemi iyileştirilebilir ve ilgi çekici bir problem olmaya devam etmektedir.

Görüntü kaynaştırma tabanlı yöntemler için literatürde; Bayes tabanlı algoritmalar, tensör analizi tabanlı algoritmalar, seyrek temsil tabanlı algoritmalar, matris ayrıştırma tabanlı algoritmalar ve derin öğrenme tabanlı algoritmaların çalışıldığı görülmektedir. Görüntü kaynaştırma tabanlı yöntemlerin en önemli dezavantajı kaynaştırma için, düşük uzamsal çözünürlüklü hiperspektral görüntü ile aynı sahneye sahip, yüksek uzamsal çözünürlüklü ikinci bir görüntünün temin edilmesinin zorluğudur. Bunun yanında, aynı sahneye sahip görüntülerin direk olarak kaynaştırılması mümkün olmayıp istatistiksel yöntemler ile uzamsal ve spektral bilgi arasında korelasyonun sağlanması gerekmektedir. Görüntü kaynaştırma tabanlı yöntemler incelendiğinde,

seyrek temsil tabanlı algoritmaların diğer algoritmalara göre daha iyi sonuçlar verdiği görülmektedir [54,63].

Tekli görüntü üzerinde yapılan çalışmalarda ise, enterpolasyon tabanlı yöntemler, istatistiksel analiz yöntemleri ve öğrenme tabanlı yöntemlerin çalışıldığı görülmektedir. Enterpolasyon tabanlı yöntemlerin hiperspektral görüntülerin karakteristiği gereği kötü sonuçlar vermektedir. İstatistiksel analiz yöntemlerinde ise dağılım hakkında ön bilgi gerekmektedir. Bu nedenle, özellikle derin öğrenme tabanlı yöntemler tekli görüntü üzerinde yapılan çalışmalarda ön plana çıkmaktadır. Derin öğrenme, günümüzde popüler bir algoritma haline gelmiş olsa da hala bazı kısıtlamalar barınmaktadır. Katmanlar arasında uygulanan seyreltme, yüksek hesaplama gereksinimi gibi etmenler beklenen sonuçları etkilemektedir. Ancak, düşük çözünürlük ile yüksek çözünürlük arasında yüksek ilişki kurması, derin öğrenmenin en önemli tercih sebebidir.

Literatürde doğal görüntüler için (RGB, gri seviyeli) derin öğrenme tabanlı süper çözünürlük çalışmaları oldukça başarılı sonuçlar vermiştir. Bu çalışmalar, farklı çalışmalarda hiperspektral görüntüler üzerine uyarlanmaya çalışılmıştır. Özellikle evrişimli sinir ağları, süper çözünürlük uygulamalarında anlamlı öznetelikler çıkarma noktasında oldukça başarılıdır. Literatürde, 2 boyutlu ve 3 boyutlu evrişim kullanılarak geliştirilen ağ modelleri bulunmaktadır. Yalnızca 2 boyutlu evrişim kullanarak geliştirilen ağlarda, uzamsal bilginin arttırıldığı ancak spektral bilgide kayıp yaşanarak zayıf yeniden yapılandırma sonuçlarının elde edildiği görülmektedir [76]. 3 boyutlu evrişim kullanarak geliştirilen ağlarda ise spektral bilginde iyileştirildiği görülmektedir. Ancak, 3 boyutlu evrişim kullanılarak geliştirilen ağ modellerinde, işlem yükü arttığı için donanım kısıtlarından dolayı derin bir ağ modeli kurmak zordur. Ayrıca, model tüm spektral bantları eş zamanlı olarak analiz ettiği için spektral bilgide karışım olabilmektedir.

1.6 Tezin Literatüre Katkısı

Bu tez çalışmasında, literatürde her iki başlık altında incelenen çalışmalar temel alınarak; derin öğrenmenin düşük ve yüksek uzamsal çözünürlük arasında kurduğu bağ ve seyrek temsil yöntemlerinin yeniden yapılandırmada spektral veriyi yüksek

oranda koruması prensibinden yararlanılmıştır. Tez kapsamında yapılan çalışmanın öne çıkan literatüre katkıları aşağıdaki gibi sıralanabilir:

- RGB görüntülerde uygulanan ve başarılı sonuçlar veren, derin öğrenme tabanlı süper çözünürlük yöntemlerinin, hiperspektral görüntüler için farklı bir uyarlaması yapılmıştır.
- Literatürde çalışılan görüntü kaynaştırma tabanlı ve tekli görüntüler üzerinde yapılan süper çözünürlük yöntemlerinden farklı olarak; her iki yöntemin ortak kullanımı sağlanmıştır. Derin öğrenme yöntemleri ile tekli görüntü üzerinde uzamsal bilgi artırılarak; seyrek temsil yöntemi ile orijinal görüntüden elde edilen spektral bilgi elde edilen görüntüye kaynaştırılmıştır. Bu yaklaşımın, literatürde daha önce çalışılmamış olması nedeni ile literature katkı sağlayacaktır.



2. METODOLOJİ

2.1 Denetimli ve Denetimsiz Öğrenme

Makinelere yapay zekâ (artificial intelligence) kazandırmak amacıyla geliştirilen makine öğrenmesi (machine learning) algoritmaları, olguların öğrenilebilmesi için eğitim sürecine ihtiyaç duymaktadır [90]. Bu eğitim süreci, bir dizi eğitim verisi gerektirmektedir. Basit olarak, öğrenme, x girdisi ile y çıktısı arasındaki ilişkinin kurulması olarak tanımlanabilir. Burada girdi; görüntüler, videolar, zaman serileri veya metin gibi çeşitli alanlardan olabilir. Çıktı; görüntü sınıflandırması için tek bir etiket, nesne algılama için bir görüntü içindeki hedef nesnesinin koordinatları veya otomatik kodlayıcılar için girdi görüntüsünün kendisinin yeniden yapılandırılması olabilir.


Denetimli öğrenmede (supervised learning) ağın amacı; girdiden hedefe bir eşleşme ilişkisini etiketli veriler kullanarak öğrenmektir [91]. Bu öğrenme ile geliştirilecek modelde, eğitim için karşılık gelen girdiler ve çıktı hedefleri gerekmektedir. Eğitim için kullanılan veriler, etiketlenmiş verilerdir. Model, etiketli verileri kullanarak öğrenme sürecine girer. Öğrenme sürecinde model, her bir aşamada tahmin sonucu üretir ve sonucu bir önceki tahmini ile çeşitli metrikleri kullanarak karşılaştırır. Çıktı tahmini, en optimal sonuca ulaştığında öğrenme süreci tamamlanır. Sonuç olarak elde edilen çıktı tahmini, hedef çıktı değeri ile karşılaştırılarak modelin başarısı ölçülür. Denetimli öğrenme modeli uygulamaları, daha çok sınıflandırma ve regresyon uygulamalarında kullanılmaktadır. Bir görüntü üzerinden nesnenin tespit edilmesi ve sınıflandırılması, rüzgâr verilerinden elektrik üretiminin tahmin edilmesi, denetimli öğrenmeye örnek olarak gösterilebilir.

Denetimsiz öğrenmede (unsupervised learning) ise ağın; veriler arasında herhangi bir etiketleme olmaksızın, girdiler ve çıktılar arasında ilişki kurması hedeflenmektedir [92]. Veriler arasında kümeleme yapılması ve bir veri yığını içerisinde, ortak özelliklerine göre veri kümelerini bulmak, buna örnek gösterilebilir. Giriş verilerini, orijinal verilerin minimum bozulma ile kurtarılacağı şekilde gizli birimler üzerindeki aktivasyonlara eşlemek olan bir otomatik kodlayıcı, denetimsiz öğrenmeye

örnek olarak gösterilebilir [93]. Öğrenme sırasında ağ, orijinal veriler ile çıktılar arasındaki farkı en aza indirmek için katmanlar (layer) arasında en iyi ağırlıkları bulmayı amaçlar. Öğrenme eşleşmesinde çözümün istenmeyen bozulmalara uğramaması için, amaca kısıtlar eklenebilir.

2.2 Yapay Sinir Ağları

Yapay sinir ağı (artificial neural network); bir giriş sinyalinden istenen bir çıkış arasında ilişkiyi haritalanmayı öğrenmeyi amaçlayan doğrusal olmayan bir tür makine öğrenimi modelidir [94]. Yapay sinir ağı; insan öğrenme modelinin matematiksel çıkarımının yapılarak makinelerle uygulanmasıdır. Yapay sinir ağlarında amaç, biyolojik sinir ağlarının yapısını makineler için taklit ederek; makinelerle öğrenme, hatırlama ve genelleme kabiliyeti kazandırmaktır. Yapay sinir ağının çalışma prensibi, beyindeki nöronların çalışma prensibini taklit eden bir matematiksel modele dayanmaktadır. Nöron yapısını taklit eden model Şekil 2.1’de gösterilmiştir [95].



Şekil 2.1 Yapay Sinir Ağı Yapısı [95]

Yapay sinir ağı, insan beyninin yapabileceği aktiviteler gibi öğrenme yoluyla yapılan, doğrusal olmayan problemlerin çözümü gibi karmaşık işlemlerde kullanılır. Bu aktiviteleri klasik metotlarla yapmak oldukça zordur. Yapay sinir ağı, herhangi bir konuda gösterilen olay ile ilgili bilgileri kendisi toplayarak, ağın öğrenme işlemini yapmış olur. Öğrendiği bilgiler ışığında, hiç görmediği bir olay karşısında yorum yapabilir hale gelebilmektedir. Bu işlem, nöronların bir araya gelerek oluşturduğu ağ ile yapılır. Bu nöronların aralarındaki sinaptik bağlantılar/ağırlık (weight) değerleri

güncellenerek en uygun değerler bulunur. Bu işleme, öğrenme denir. Yapay sinir ağına, öğrenmesi için girdi olarak belirlenen bilgiler girdi katmanını aracılığıyla dahil edilir. Bu girdi değişkenleri, ağırlıklarla çarpılarak ve bias değerleri eklenerek net değerleri elde edilir ve aktivasyon fonksiyonundan (activation function) geçilerek çıktı elde edilir. Beklenen değer ile çıktı değeri karşılaştırılarak elde edilen hataya göre ağırlık değerleri güncellenerek öğrenme işlemi tekrarlanır ve ağın tahmin doğruluğu artırılmış olur. Bir yapay nöronun matematiksel modeli Eşitlik 2.1’de verilmiştir.

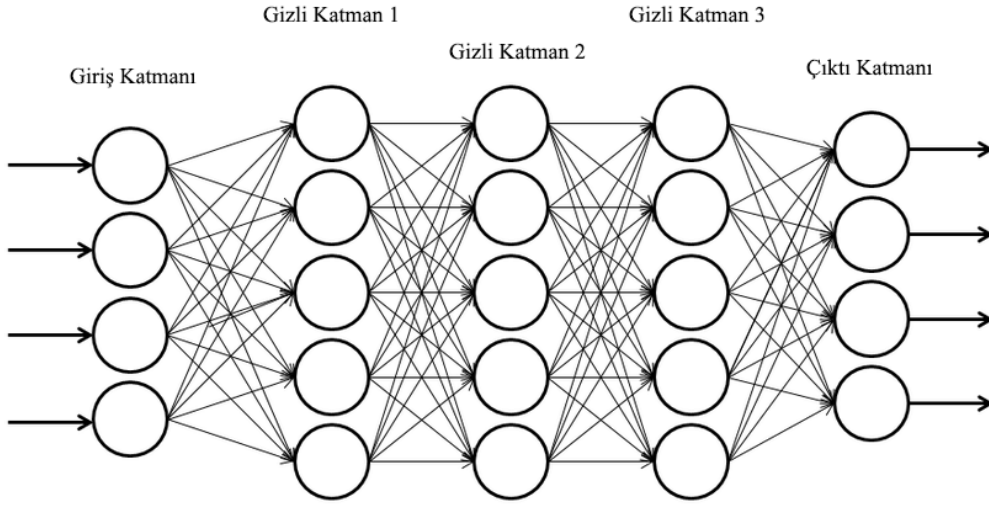
$$l = \sum_{k=0}^n x_k \cdot w_k + b_k \quad (2.1)$$

Burada; k adet girdi için l nöronu, x girdi, w ağırlık ve b bias değerini temsil etmektedir. Nöron, aktivasyon fonksiyonu σ ile değerlendirildikten sonra sinir ağının çıktısı Eşitlik 2.2’deki gibi olur.

$$\sigma(l) = \text{aktivasyon}\left(\sum_{k=0}^n x_k \cdot w_k + b_k\right) \quad (2.2)$$

2.2.1 Derin Öğrenme

1950’li yıllarda kullanılmaya başlanan yapay sinir ağları, hesaplama gücü yüksek makinelere ihtiyaç duyulması nedeni ile zamanla popülerliğini kaybetmiş, ancak son dönemde işlemcilerin güçlenmesi ve özellikle birden fazla grafik işlemci barındıran grafik kartlarının gelişmesi ile tekrar ilgi çekici bir alan olmaya başlamıştır. İşlem gücü yüksek cihazların gelişmesi; yapay sinir ağ modellerinde daha çok katman ve nöron kullanımına olanak sağlamıştır. Bu sayede, günümüzde popüler hale gelmiş olan derin öğrenme kavramı sıklıkla kullanılmaktadır. Yapısında birden fazla katman kullanılan sinir ağlarına çok katmanlı algılayıcı (multi-layer perceptron) veya derin öğrenme (deep learning) denilmektedir. Çok katmanlı algılayıcıların temel yapısı Şekil 2.2’de verilmiştir.




Şekil 2.2 Çok katmanlı algılayıcı temel yapısı [95]

Şekil 2.2'deki gibi birçok nöronun belli ağırlıklar dahilinde birbirleri ile bağlantılı olduğu yapıya çok katmanlı algılayıcı denilmektedir. Çok katmanlı algılayıcılar; giriş katmanı (input layer), çıkış katmanı (output layer) ve gizli katmanlardan (hidden layer) oluşmaktadır. Model kurulumunda, katman sayıları ve içerdiği nöron sayıları modelin ihtiyacına göre belirlenebilmektedir. Burada dikkat edilmesi gereken en önemli husus; katman ve nöron sayılarının uygun olarak seçilmesidir. Katman ve nöron sayılarının fazla belirlenmesi; eğitim hatasını azaltabilirken, hesaplama maliyetini arttırmakta, sistemin öğrenme yerine ezberleme (overfitting) yapmasına neden olmaktadır. Yine, katman ve nöron sayılarının az seçilmesi ise öğrenmenin düşük olarak gerçekleşmesine neden olmaktadır.

2.2.2 Aktivasyon Fonksiyonları

Yapay sinir ağlarında aktivasyon fonksiyonları; ağırlık ve bias değerlerini ayarlamak için kullanılır. Ayrıca, aktivasyon fonksiyonları doğrusal olmayan fonksiyonlardan seçilerek, ağın doğrusallaşması engellenir. Literatürde en çok kullanılan aktivasyon fonksiyonları; Sigmoid, tanh, ReLU ve softmax fonksiyonlarıdır. Bu fonksiyonlardan türetilmiş farklı aktivasyon fonksiyonları da kullanılmaktadır.

Sigmoid fonksiyonunun matematiksel ifadesi Eşitlik 2.3'te ve grafiksel gösterimi Şekil 2.3'te verilmiştir.




Şekil 2.3 Sigmoid fonksiyonunun grafiksel gösterimi

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.3)$$

Şekil 2.3'ten görüleceği üzere, Sigmoid fonksiyonu aldığı değerlere göre 0 ile 1 arasında çıktı üretmektedir. Aldığı yüksek değerler ile 1'e yakınsarken, negatif değerler ile 0'a yakınsamaktadır. Giriş değerlerine karşılık, çıktı değerlerinin 0 ile 1 arasında olması çıktının girdiye göre daha az tepki vermesine neden olmaktadır. Bu da yavaş öğrenmeye neden olmakta ve çıkışın optimizasyonunda lokal minimum noktasında takılı kalmasına neden olmaktadır. Ayrıca geri besleme (backpropagation) aşamasında her bir iterasyonda alınan türev ile doyuma ulaştığı uç noktalarının türevi 0'a yakınsamaktadır. Çıktının 0 olması, nöronun aktive olmamasına ve gradyan kaybı (gradient loss) problemine neden olmaktadır.

Hiperbolik tanjant (tanh) fonksiyonunun matematiksel ifadesi Eşitlik 2.4'te ve grafiksel gösterimi Şekil 2.4'te verilmiştir.




Şekil 2.4 tanh fonksiyonunun grafiksel gösterimi

$$\tanh(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (2.4)$$

Şekil 2.4'ten görüleceği üzere, tanh fonksiyonu, sigmoid fonksiyonundan farklı olarak, aldığı değerlere göre -1 ile 1 arasında çıktı üretmektedir. Aldığı yüksek değerler ile 1'e yakınsarken, negatif değerler ile -1'e yakınsamaktadır. Böylece öğrenme, sigmoid fonksiyonuna göre biraz hızlı olabilmekte ve lokal minimuma takılma ihtimali azalmaktadır. Ancak, sigmoid fonksiyonuna benzer şekilde geri besleme aşamasında her bir iterasyonda alınan türev ile doyuma ulaştığı uç noktalarının türevi 0'a yakınsayacaktır. Çıktının 0 olması ile, nöron aktive olmayacak ve gradyan kaybı problemine neden olacaktır.

Rektifiye Linear Birim (Rectified Linear Unit-ReLU) fonksiyonunun matematiksel ifadesi Eşitlik 2.5'te ve grafiksel gösterimi Şekil 2.5'te verilmiştir.



Şekil 2.5 ReLU fonksiyonunun grafiksel gösterimi

$$f(x) = \max(0, x) \quad (2.5)$$

Şekil 2.5'ten görüleceği üzere, ReLU fonksiyonu aldığı değerlere göre 0 ile $+\infty$ arasında çıktı üretmektedir. Girdi değeri negatifse 0, pozitifse herhangi bir sıkıştırma yapmadan girdinin değerini çıktı olarak vermektedir. Negatif değerler için geri besleme aşamasında her bir iterasyonda alınan türev ile doyum ulaştığı uç noktalarının türevi 0'a yakınsayacaktır. Çıktının 0 olması ile, nöron aktive olmayacak ve gradyan kaybı problemine neden olacaktır. Pozitif değerler için herhangi bir doyum noktası yoktur. Sigmoid ve tanh fonksiyonlarından farklı olarak, hesaplama yükü olmadığı için hesaplama hızı kolaylığı sağlamaktadır.

Softmax fonksiyonunun matematiksel ifadesi Eşitlik 2.6'da verilmiştir.

$$\hat{y}_i = \sigma(a)_i = \frac{e^{a_i}}{\sum_j e^{a_j}} \quad (2.6)$$

Softmax fonksiyonu; çıktıları olasılık dağılımı haline getiren ve genellikle çoklu sınıflandırma problemleri için kullanılan, verilen bir girdinin hangi sınıfa ait olduğunu gösteren bir fonksiyondur. Çıktıları olasılık dağılımı haline getirmesinden dolayı, tüm çıktıların toplamı olasılık kuramına göre 1'i geçemez. Diğer aktivasyon fonksiyonlarına göre daha yüksek hesaplama kapasitesine ihtiyaç duyar, ancak tüm

girdileri olasılıksal olarak değerlendirdiğinden, çoklu sınıflandırma problemleri için oldukça kullanışlı bir aktivasyon fonksiyonudur.

2.2.3 Kayıp Fonksiyonları

Kayıp fonksiyonları (loss function); bir yapay sinir ağı modelinin tahmin ettiği değerin gerçekteki değerden ne kadar uzak olduğunu hesaplar. Modelin çıktısı olarak ürettiği değer ile hedeflenen değer arasında bir değerlendirme yaparak, benzerlik değeri vermektedir. Modelin eğitim süresince kayıp fonksiyonunun bir yerde takılı kalmadan 0'a yaklaşması beklenir. En çok kullanılan kayıp fonksiyonları L2 kayıp fonksiyonu ve çapraz entropi kayıp fonksiyonudur. L2 kayıp fonksiyonunun matematiksel ifadesi Eşitlik 2.7'de verilmiştir.

$$S = \sum_{i=1}^n (y_i - f(x_i))^2 \quad (2.7)$$

Burada, y hedef değerini, $f(x)$ aktivasyon fonksiyonundan gelen tahmin değerini göstermektedir.

Çapraz entropi (cross entropy) kayıp fonksiyonu, çok sınıflı sınıflandırma için ortak bir denetimli kayıp fonksiyonu olarak tanımlanabilir. Özellikle çapraz entropi fonksiyonu, tahmini olasılık dağılımı ile gerçek olasılık dağılımı arasında bir mesafe ölçüsünü tanımlar.

Çok sınıflı sınıflandırma açısından, gerçek olasılık dağılımı, gerçek sınıf için 1, diğer sınıflar için 0 olasılığını gösteren temel gerçek vektör y 'dir. Tahmini olasılık Eşitlik 2.6 ile hesaplanan \hat{y} ; bir sinir ağı çıktısının softmax işlemi $\sigma(\cdot)$ aracılığıyla bir olasılık dağılımı olacak şekilde yeniden ölçeklenmesini kapsayan tahmin edicinin çıktısıdır.

Çapraz entropi kaybı fonksiyonu Eşitlik 2.8 ile hesaplanır.

$$J(\theta, x, y) = - \sum_i y_i \log(f(\theta, x)_i) = - \sum_i y_i \log(\hat{y}_i) \quad (2.8)$$

Eşitlik 2.8 ile çapraz entropi kayıp fonksiyonu; olası sınıflar üzerindeki tahmini olasılık dağılımı olarak yorumlanan model, $\hat{y} = f(\cdot)$ 'nin çıktısı ile hedef dağılım y arasındaki mesafeyi ölçer. Eşitlik kayıp fonksiyonu $J(\theta, x, y)$ için, dizi eğitilebilir parametre θ , girdi verileri x ve hedef çıktı sonucu y ile gösterilmektedir.

2.2.4 Gradyan Azalma

Bir sinir ağının eğitiminin amacı; kayıp fonksiyonunu en aza indirmek için modelin ağırlıklarının güncellemektir. Bu kayıp fonksiyonları, tipik olarak ağın genel amacını ifade eder. Örneğin; vektör olarak çıkarılan temel doğruluk sınıfı ile bir sinir ağının tüm bir veri kümesi üzerindeki çıktısı arasındaki çapraz entropi mesafesini en aza indirmek, hedeflenen çıktı için modelin ağırlıklarını optimize eder. Biçimsel olarak, bir dizi eğitilebilir parametre θ , girdi verileri x ve hedef çıktı y olan bir $J(\theta, x, y)$ kayıp fonksiyonu verildiğinde, ağın genel amaç fonksiyonu Eşitlik 2.9 ile hesaplanır.

$$\hat{\theta} = \arg_{\theta} \min J(\theta, x, y) \quad (2.9)$$

Bu optimizasyon problemini çözenin yaygın bir yolu, gradyan azalmadır (gradient descent). Spesifik olarak, prosedür; model ağırlıklarına ve kayıp fonksiyonunun kısmi türevine göre parametreleri yinelemeli olarak güncellemektir. Güncelleme işlemi Eşitlik 2.10 ile yapılmaktadır.

$$\Delta \theta = -\eta \nabla_{\theta} J = -\eta \frac{\delta J(\theta, x, y)}{\delta \theta} \quad (2.10)$$

Burada η , modelin öğrenme oranını kontrol eden kullanıcı tarafından ayarlanan bir parametredir. Sezgisel olarak, algoritma yakınsamaya kadar tekrarlayan şekilde en dik gradyan yönünde azalan bir adım atar.

Eşitlik 2.9 tüm x ve y eğitim kümesini optimize eder. Pratikte ise Eşitlik 2.11’de ifade edilen mini toplu stokastik gradyan inişinin kullanılması yaygındır.

$$\hat{\theta} = \arg_{\theta} \min \mathbb{E}_{x,y \in X,Y} [J(\theta, x, y)] \quad (2.11)$$

Eşitlik 2.11’de algoritma, bir veri setinden x girdilerini ve y hedef çıktılarını örnekler ve örneklenen girdi ile kayıp fonksiyonunun beklenen değerini optimize eder.

Gradyan azalma, Eşitlik 2.9 ve Eşitlik 2.11’i çözmeye zaman zaman yetersiz kalmaktadır. Eşitlik 2.9 ve Eşitlik 2.11 ile yapılan işlemlerde, optimizasyon işlemi yerel minimuma takılmakta ya da eğim kaybetmektedir. Bu sorun için en uygun çözümlerden birisi momentum kullanmaktır.

Momentum, Eşitlik 2.10’u Eşitlik 2.12 gibi günceller.

$$\Delta \theta = -\eta \nabla_{\theta} J + \beta \nabla \theta \quad (2.12)$$

β , momentum terimini kontrol eden kullanıcı tarafından ayarlanmış bir parametredir. Sezgisel olarak model, önceki güncellenmenin bir kısmını mevcut güncellemeye ekleyerek öğrenmeyi hızlandırır.

Gradyan azalmada, momentumun yaygın bir uygulaması Adam optimizasyonudur. Burada Adam optimizasyonu, J kayıp fonksiyonunun gradyanının birinci ve ikinci momentlerinin tahminlerine dayalı olarak bireysel parametreler için uyarlanabilir bir öğrenme oranı kullanır. Adam optimizasyonu, optimizasyon problemini Eşitlik 2.13 ile çözer. Eşitlik 2.13'te ki değişkenler Eşitlik 2.14, Eşitlik 2.15 ve Eşitlik 2.16 kullanılarak hesaplanır.

$$\Delta \theta = -\hat{\eta} \frac{m_t}{\sqrt{v_t + \varepsilon}} \quad (2.13)$$

$$m_t = (1 - \beta_1) \nabla_{\theta} J + \beta_1 m_{t-1} \quad (2.14)$$


$$v_t = (1 - \beta_2) (\nabla_{\theta} J)^2 + \beta_2 v_{t-1} \quad (2.15)$$

$$\hat{\eta} = \eta \frac{\sqrt{1 - \beta_2^t}}{1 - \beta_1^t} \quad (2.16)$$

Eşitlik 2.13'te η , kullanıcı tanımlı bir öğrenme oranıdır. β_1 ve β_2 sırasıyla birinci ve ikinci momentler terimleridir, ε sayısal kararlılık için küçük bir sabit, t iterasyon zaman adımıdır. β_1^t ve β_2^t ; β_1 ve β_2 'nin t 'ye göre kuvvetini gösterir. Momentum değişkenleri m ve v , optimizasyon başlangıcında 0'dan başlatılır. Eşitlik 2.14 ve 2.15, sırasıyla gradyanın birinci ve ikinci momentlerinin tahminlerini yinelemeli olarak günceller. Eşitlik 2.16, an tahminlerindeki yanlılıkları hesaba katmak için öğrenme oranını ayarlar.

2.3 Derin Evrişimli Sinir Ağları

Derin Evrişimli Sinir Ağları (Deep Convolutional Neural Network), giriş sinyalinden bir sınıf etiketine doğrusal olmayan bir işlemeyi temsil edecek şekilde eğitilir [96]. Derin Evrişimli Sinir Ağları (DESA) yapısal katmanlardan oluşur. Burada her bir katman, kendisine gelen giriş üzerindeki işlemi kapsar. Bu katmanlar; bir derin ağ oluşturmak için bir hiyerarşide sıralanır, böylece bir katmanın çıktı aktivasyonları bir sonraki katmana girdi olarak beslenir. Şekil 2.6'da bu kavram şematize edilmiştir. DESA'lar temel olarak üç yaygın katman türünden oluşmaktadır. Bunlar tam bağlantılı (fully connected), evrişimli (convolutional) ve havuzlama (pooling) katmanlarıdır.




Şekil 2.6 Bir Derin Evrişimli Sinir Ağının (DESA) yapısı [96].

2.3.1 Tam Bağlantılı Katman

Tam bağlantılı katman, bir DESA içindeki giriş sinyali veya başka bir katmanın çıkışı olabilen giriş vektörüne işlem uygular. Tam bağlantılı katmanın yaygın kullanımı, bir giriş görüntüsü için tek bir etiket üreten ağ içindedir. Bu durumda model, çıktının boyutunu sınıf sayısına indirmek için ağın sonunda tam bağlantılı katman kullanır. Böylece ağın çıktısı, tüm olası sınıflar üzerinde bir olasılık dağılımı olarak yorumlanabilir. Katmanın çıktısı, DESA yapısında ön katmanından gelen giriş vektörü ile bir ağırlık matrisi arasındaki matris-vektör çarpımı hesaplanarak bulunur. Çıktı daha sonra doğrusal olmayan bir aktivasyon fonksiyonu aracılığıyla beslenir. Tam bağlantılı katmanın yapısı Şekil 2.7'de verilmiştir.

Biçimsel olarak, m boyutlu bir girdi vektörü $X \in \mathbb{R}^m$, eğitilebilir bir ağırlık matrisi $W \in \mathbb{R}^{m \times f}$, ve eğitilebilir bir bias vektörü $B \in \mathbb{R}^f$ verildiğinde, f tam bağlantılı bir katman olmak üzere, tam bağlantılı katmanın çıkış aktivasyonları Eşitlik 2.2 ile hesaplanır.




Şekil 2.7 Tam bağlantılı bir katmanın yapısı [96].

2.3.2 Evrişimsel Katman

Evrişimsel katman; tam bağlantılı katmana benzer şekilde, belirli bir girdinin doğrusal dönüşümünü ve ardından bazı doğrusal olmayan aktivasyon fonksiyonunu hesaplar. Spesifik olarak, bir girdi sinyali x ve eğitilebilir filtreler koleksiyonu W verildiğinde, evrişim; bir giriş görüntüsünün parçasının ve bir filtrenin nokta çarpımının, görüntünün tüm parçaları ve tüm filtreler için uygulanması olarak tanımlanır. Şekil 2.8'de evrişimsel katmanın temel çalışma prensibi gösterilmiştir. Evrişim katmanının çıktısı, adım faktörü tarafından örneklenir. Bir evrişim katmanı, tipik olarak hiyerarşide bir önceki katmanın çıktı aktivasyonlarını alır.

Tam bağlantılı katmanların aksine, bir evrişim katmanı, öteleme değişmezliğini varsayar. Spesifik olarak, görüntü boyunca tek bir filtre kullanılır ve bu nedenle giriş içindeki mutlak konumu değişmez. Bu özellikle, katmanda genel olarak daha az ağırlık kullanma avantajına sahiptir. Bu da modelin bellek gereksinimlerini azaltmanın yanı sıra katmanın daha kolay eğitilmesini sağlar.



Şekil 2.8 Evrişimsel bir katmanın gösterimi [85].

Bir konum için (mavi renkte) çıktı sonuçları; bir filtre seti ile bir görüntü parçası arasındaki nokta çarpımı alınarak ve ardından doğrusal olmayan bir aktivasyon fonksiyonu takip edilerek hesaplanır. Bu işlem, aynı filtre seti ile farklı konumlardaki diğer görüntü parçaları için tekrarlanır. Burada filtre, ağırlık değerlerini belirtmek için gri tonlamalı bir görüntü olarak gösterilen bir ağırlık kümesidir.

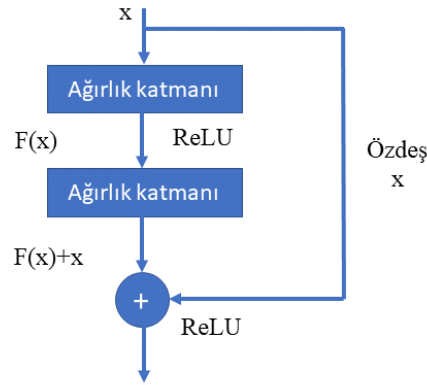
2.3.3 Havuzlama Katmanı

Bir DESA'da, önceki katmanın boyutlarını azaltmak için tipik olarak havuz katmanı kullanılır. Evrişim katmanına benzer şekilde, girdi yamalarında havuzlama yapılır. Evrişimsel katmanın aksine, havuzlama katmanının işlevi; girdinin uzamsal boyutları üzerinden katmana verilen girdinin maksimumunu veya ortalamasını üretmektir. Ek olarak, havuz katmanları, genellikle eğitim sırasında optimize edilecek ağırlıklara sahip değildir [97].

2.4 Derin Kalıntı Ağlar

Microsoft tarafından geliştirilen derin kalıntı ağlar (deep residual networks), temel olarak; 2 katman önce evrişime uğrayan girdinin etkisini, 2 katman sonra tekrar ağa dahil eden bir evrişimli derin ağ çeşitidir [98]. Bu özelliği sayesinde, eğitim esnasında


nöronun ağırlığı kaybolursa bile; girdinin etkisinin tekrar ağa dahil edilmesi ile gradyan kaybı önlenmektedir. Ayrıca, derin kalıntı ağları; model katmanlarının azaltılmasını sağlayarak, kaynak tüketimini düşürmektedir. Şekil 2.9’da derin kalıntı ağlarının temel evrişim işlemi gösterilmiştir.



Şekil 2.9 Derin kalıntı ağlarında temel bir evrişim işlemi [98].

2.5 Yoğun Evrişimli Ağlar

Yoğun evrişimli ağlar (dense convolutional networks), ileri beslemeli bir ağ yapısında geliştirilmiştir [99]. Daha derin ve verimli bir eğitim sağlamak için, katmanlar arasında bağlantılar bulunmaktadır. Bu bağlantılar sayesinde, her katman kendisinden önce gelen tüm katmanların öznetelik matrislerini giriş olarak kullanmaktadır. Modelin dezavantajı; yüksek hesaplama gücü gerektirmesidir. Şekil 2.10’da temel bir yoğun evrişimli ağ mimarisi verilmiştir.



Şekil 2.10 Temel bir yoğun evrişimli ağ mimarisi [99].

2.6 Seyrek Temsil

Seyrek temsil (sparse representation), Barlow ve meslektaşlarının sinirsel hesaplama teorisine dayanan, denetimsiz bir öğrenme algoritmasıdır [100]. Spesifik olarak seyrek temsil; seyrek bir girişi, orijinal sinyalin minimum bozulma ile kurtarılabilceği şekilde bir dizi seyrek gizli birim aktivasyonu olarak kodlamayı amaçlar.

Matematiksel açıklamaya dayalı sabit sözlükler kullanan geleneksel Fourier Dönüşümü (FD), Karhunen-Loeve Dönüşümü (KLD) veya dalgacık dönüşümlerinden farklı olarak, seyrek temsiller; fazla tamamlanmış sözlükleri doğrudan veri üzerinde öğrenmesi sebebiyle daha fazla seyrekliğe sahip olmaktadır. Daha spesifik olarak, karmaşık doğal olayların yapısı, belirli sinyal içeriğinden daha doğru ve uyarlanabilir bir şekilde çıkarılabilir [101]. Böylece orijinal sinyaller, seyrek olarak yeniden oluşturulabilir veya bozulmuş sinyallerden, seyrek bir kodlama tekniği ile temsil edilebilir ve öğrenilmiş sözlükler oluşturulabilir. Son yıllarda, sözlük eğitim yöntemlerinin ve seyrek kodlama tekniklerinin geliştirilmesiyle, seyrek temsil; görüntü gürültü giderme, görüntü süper çözünürlüğü ve diğer birçok görüntü işleme görevlerinde en gelişmiş sonuçları elde etmiştir.

Seyrek temsil, otomatik kodlayıcılar (auto encoders) ile benzerlik göstermektedir. Her iki yöntem de denetlenmediği ve belirli bir girişi temsil etmek için bir kodlama hesaplama mantığına dayandığı için aynı hedefi paylaşmaktadırlar. Bununla birlikte, otomatik kodlayıcılar; tipik olarak tek katmanda giriş için aktivasyonları hesaplarken, seyrek kodlama; girişi kodlayan seyrek gizli birim aktivasyonları kümesini bulmak için bir optimizasyon problemini çözer. Hem otomatik kodlayıcılar hem de seyrek kodlama, modeli yeniden yapılandırma için optimize eden bir eğitim seti üzerinden, bir dizi ağırlık / sözlük değerleri öğrenir.

Seyrek temsil; kodlama (sparse coding) ve sözlük öğrenme (dictionary learning) olmak üzere iki ana parçadan oluşur. Kodlama herhangi bir sözlükle yapılabilirken, amaç daha iyi seyrek gösterimler sağlayan bir sözlük öğrenmektir. Burada kodlama, her sözlük öğesinin atom adı verilen bir ağırlık alt kümesi olduğu, seyrek bir sözlük öğeleri kümesinin toplamını kullanarak bir girdiyi temsil etmeyi amaçlar.

2.6.1 Kodlama

Seyrek kodlamada bir girdiyi kodlamanın matematiksel formülasyonu, kısıtlı en küçük kareler problemidir. İyi bilinen en küçük kareler problemi, m boyutlu bir sinyali $x \in \mathbb{R}^m$, $x \approx D_a$ ayrıştırılmayı amaçlar. Burada, $D \in \mathbb{R}^{m \times p}$ atomlu, $a \in \mathbb{R}^p$ atomları gizli katmanlarda ağırlıklandırılmış bir sözlüğü temsil eder. Seyrek kodlama, aktivasyonların seyrek olması gerektiği kısıtlaması altında, belirsiz bir en küçük kareler problemini çözmeyi amaçlar. Optimizasyon probleminin amaç fonksiyonu Eşitlik 2.17’de verilmiştir.

$$S(x, D) = \hat{a} = \arg_a \min \frac{1}{2} \|x - D_a\|_2^2 + \lambda \|a\|_1 \quad (2.17)$$

Başka bir deyişle, kodlama; Öklid mesafesi ile tanımlanan verileri en iyi temsil eden aktivasyonlarla çarpılan, seyrek bir sözlük atomları kümesi bulmaktan ibarettir. Burada a , yeniden yapılandırma hatası ve seyreklik arasındaki alışverişi kontrol eden kullanıcı ayarlı bir parametre olan λ ile $\|\cdot\|_1$ veya ℓ_1 norm² ile seyrek olarak kısıtlanır.

2.6.2 Sözlük Öğrenme


D sözlüğünü seyrek kodlama içinde öğrenmek, evrişimli bir katmandaki filtreleri öğrenmeye benzer ve gradyan azalma yoluyla yapılır. Ancak ortaya çıkan sözlük, denetimsiz bir şekilde eğitilir. Eğitim hedefi açık etiketler gerektiren bir sınıflandırma görevinin aksine, yalnızca bir dizi etiketlenmemiş örnek gerektirir.

n tane eğitim girdisinden oluşan bir $X \in \mathbb{R}^{n \times m}$ veri kümesi verildiğinde, sözlük öğrenimi, veri kümesinin en iyi seyrek temsiline izin veren bir sözlüğü optimize etmeyi amaçlar. Spesifik olarak, sözlük öğrenimi Eşitlik 2.18’de matematiksel olarak ifade edilmiştir.

$$\hat{D} = \arg_D \min \mathbb{E}_{x \in X} [S(x, D)] \quad (2.18)$$

Burada x , küçük parçalar yoluyla X ’ten örneklenir. Sözlük, görüntüler üzerinde eğitildiğinde, elde edilen sözlük atomları tipik olarak belirli frekanslarda yönlendirilmiş kenarlara karşılık gelir. Şekil 2.11 doğal görüntüler üzerinde eğitilmiş bir sözlük örneğini göstermektedir. Şekil 2.11’de her kare bir sözlük atomunu göstermektedir, beyaz en yüksek değer ve siyah en düşük değerdir.

Eşitlik 2.18'in yazıldığı şekliyle dejenere bir çözümü vardır; Eşitlik 2.17'deki seyreklik terimi; aktivasyonların büyüklüğünü küçük, bu da sözlük atomlarının büyüklüğünü büyük olmaya yönlendirir. Bunu önlemek için, her sözlük atomu ℓ_2 normuna sahip olacak şekilde kısıtlanmıştır.



Şekil 2.11 Atomların seyrek gösterimi [101].

2.7 Değerlendirme Metrikleri

Süper çözünürlük sonuçlarının kalitesini nicel olarak değerlendirmek için, bu tezde birkaç temsili metrik kullanılmıştır. Görüntü niteliklerinin nicel değerlendirmesinde yaygın olarak uygulanan Ortalama Karekök Hatası (root mean square error), değerlendirmeler için birinci indeks olarak seçilmiştir. Süper çözünürlük sonucunun spektral bozulmasını incelemek için Spektral Açılı Haritacısı (spectral angle mapper) kullanılmıştır.

Yeniden oluşturulan süper çözünürlüklü görüntü ile, girdi olarak verilen düşük çözünürlüklü görüntü arasında sayısal bir değerlendirme yapmak ve diğer yöntemler ile karşılaştırabilmek için literatürde sıkça kullanılan Ortalama Karekök Hatası (OKH) yöntemi kullanılmıştır. OKH değeri aşağıdaki Eşitlik 2.19 ile hesaplanmaktadır [102].

$$OKH = \sqrt{\frac{\sum \|I - \hat{I}\|^2}{LMN}} \quad (2.19)$$

Eşitlik 2.19'da yer alan; I girdi görüntüsünü, \hat{I} önerilen yöntem sonucu elde edilen çıktı görüntüsünü, $M \times N$ görüntünün uzamsal boyutlarını, L görüntünün spektral boyutunu temsil etmektedir.

Spektral Açık Haritacısı (SAH) algoritması, görüntü spektrumları ile referans spektrumlarının spektral benzerliğinin ölçülmesi için geliştirilen bir araçtır [103]. Referans spektrumları; laboratuvar veya saha ölçümlerinden alınabilmekte veya doğrudan görüntüden çıkarılabilmektedir. SAH, n -boyutlu uzayda spektrumları vektörel olarak ele alarak, iki spektrum arasındaki açı hesabıyla, spektral benzerliği ölçmektedir. SAH, Eşitlik 2.20 ile hesaplanmaktadır.

$$SAH = \arccos\left(\frac{\sum_{i=1}^{bs} t_i r_i}{\sqrt{\sum_{i=1}^{bs} t_i^2} \sqrt{\sum_{i=1}^{bs} r_i^2}}\right) \quad (2.20)$$

Burada bs , spektral verideki bant sayısını, t görüntü spektrumu bilgisini, r referans spektrumu bilgisini göstermektedir.

3. ÖNERİLEN MODEL

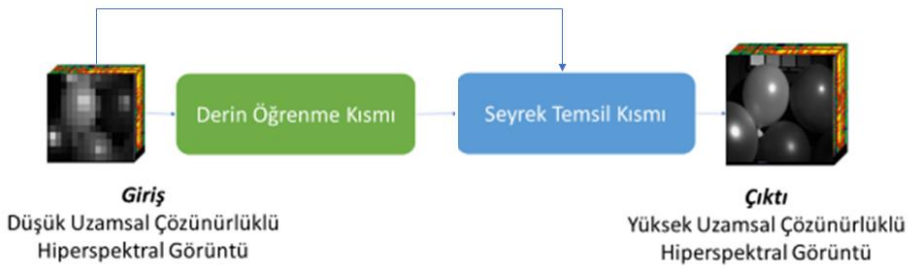
Bu tez çalışmasında, düşük uzamsal çözünürlüğe sahip hiperspektral görüntüler için öğrenme tabanlı süper çözünürlük algoritmaları önerilmiştir. Hiperspektral görüntülerin uzamsal çözünürlüklerini arttırmak üzere literatürde yapılmış çalışmalar bulunmaktadır. Bu çalışmalar incelendiğinde, yöntemler görüntü kaynaştırma tabanlı ve tekli görüntü üzerinden iyileştirme tabanlı olarak iki kategoride sınıflanabilmektedir. Görüntü kaynaştırma tabanlı çalışmalar daha başarılı süper çözünürlük sonuçları üretmesine rağmen yöntemin ikinci bir yüksek çözünürlüklü görüntüye ihtiyaç duyması temel dezavantajdır. Ancak tekli görüntüler üzerinde yapılan süper çözünürlük yöntemleri de; gerektirdiği alan ile ilgili ön bilgi ihtiyacı, eğitim için ihtiyaç duyulan veriler gibi kısıtlardan dolayı dezavantaj oluşturmaktadır. Ayrıca tekil görüntülerin uzamsal çözünürlüklerinin artırılması üzerine yapılan çalışmalarda, spektral verinin kayba uğrayabildiği görülmektedir.

Derin öğrenme, hesaplama gücü yüksek cihazların gelişmesi ile popüler bir konu haline gelmişse de hala birçok kısıt barındırmaktadır. Eğitim süreci yüksek veri miktarına ve hesaplama için yüksek kapasiteli cihazlara ihtiyaç duymaktadır. Derin sinir ağları son yıllarda süper çözünürlük uygulamalarında kullanışlı sonuçlar vermektedir. Derin ağların, düşük çözünürlüklü görüntü ile yüksek çözünürlük görüntüler arasında anlamlı ilişki kurması, derin öğrenmeyi süper çözünürlük uygulamalarında öne çıkarmaktadır. Ancak derin sinir ağları uygulamaları esnasında bazı ayrıntı bilgileri kaybedilerek; daha kötü bir yeniden yapılandırma sonucuna neden olmaktadır. Özellikle spektral veride oluşan kayıplar, görüntülenen bölgede bulunan nesnelerin spektral imzalarının karışmasına neden olmaktadır. Spektral imzanın karışması, bölgede veya gerçekte hiç olmayan bir nesneye ait spektral veri oluşturmakta, bu durum da analizin sonucunu etkilemektedir. Bu nedenle, spektral verinin korunması oldukça önem arz etmektedir.

Seyrek temsil; bir giriş sinyalini, sinyalin temel atomlarının lineer kombinasyonları ile kodlayarak, sinyalin esas özelliklerini koruyacak şekilde temsil edilmesidir. Seyrek temsil birçok alanda başarılı sonuçlar üretmesiyle dikkat çekici bir algoritma haline

gelmiştir. Seyrek temsil ile hiperspektral görüntülerin süper çözünürlük çalışmaları da oldukça başarılı sonuçlar üretmektedir [54,63]. Buradaki temel prensip, eğitim aşamasında düşük ve yüksek çözünürlüğe sahip görüntü parçaları, aynı seyrek vektörü kullanarak ortak bir sözlük oluşturmayı amaçlamaktadır. Daha sonra düşük çözünürlüklü görüntü girdi olarak verildiğinde, görüntü seyrek olarak temsil edilerek, oluşturulan sözlük ve seyreklik katsayısı ile yüksek çözünürlüklü görüntü oluşturulmaktadır. Yöntemin doğası gereği yüksek çözünürlüklü görüntü ile düşük çözünürlüklü görüntü aynı anda kullanılmaktadır. Bu nedenle, yöntem görüntü kaynaştırma tabanlı uygulamalar için uygundur.

Bu tez çalışmasında, seyrek temsilin spektral veriyi kaynaştırmadaki başarısından ve derin öğrenmenin düşük ve yüksek uzamsal bilgiler arasında güçlü bir bağ kurmasından yararlanılmıştır. İki temel unsurdan oluşan yöntemin ana görüntüsü Şekil 3.1’de verilmiştir.



Şekil 3.1 Önerilen yöntemin algoritmik gösterimi

Temel olarak, düşük uzamsal çözünürlüğe sahip hiperspektral görüntünün derin ağ modeli ile uzamsal çözünürlüğü artırılırken, seyrek temsil yöntemi ile spektral veri yeni oluşturulan süper çözünürlüklü görüntüye kaynaştırılarak aktarılmaktadır.

3.1 Derin Öğrenme Modellerinin Geliştirilmesi

Derin öğrenme ile geliştirilen süper çözünürlük uygulamaları doğal görüntüler üzerinde oldukça başarılı sonuçlar üretmektedir [104,105]. Geliştirilen algoritmalar, hiperspektral görüntülerin yapısı gereği direk olarak hiperspektral görüntülere uygulanamamaktadır. Bu nedenle, literatürde geliştirilen yöntemler hiperspektral görüntülere uyarlanmaya çalışılmıştır. Yapılan çalışmalarda, evrişimli sinir ağı modellerinin süper çözünürlük uygulamalarında başarılı olduğu görülmüştür. Ancak, 2 boyutlu evrişim kullanan modellerde uzamsal bilgi artırılırken, spektral bilgide

kayıp yaşandığı; 3 boyutlu evrişim kullanan modellerde, evrişim işleminin tüm görüntüyü aynı anda işleme aldığı için işlem yükünü arttırdığı ve modelin derinleşemediği görülmüştür. 2 boyutlu evrişim görüntünün her bir bandının özelliğini çıkararak tek bir öznelik haritası oluşturmaktadır. Bu durum, elektromanyetik tayf üzerinde gözle görülebilir aralıktaki dar bir banttıan oluşan RGB görüntüler için uygulanabilmektedir. RGB görüntülerin bantları arasında gürültü oranı yüksek değildir. Ancak, daha geniş bir bant aralığında onlarca banttıan oluşan hiperspektral görüntülere 2 boyutlu evrişim uygulamak uygun değildir. Bantlar arasındaki gürültü farkı yüksek olabileceği için 2 boyutlu evrişim, bantlar arasındaki yüksek gürültüyü diğer bantlara kaydırabilmektedir. Bu problemin çözümü için literatürde, hiperspektral görüntülerin her bir bandına ayrı ayrı evrişimin uygulandığı yöntem önerilmiştir [76]. Ancak bu tarz bir uygulama onlarca banttıan oluşan hiperspektral görüntü için çok fazla işlem yükü gerektirmektedir. Bu tez çalışması kapsamında, doğal görüntüler üzerinde uygulanan süper çözünürlük çalışmalarında başarılı sonuçlar veren, evrişim ağı tabanlı ve derin kalıntı ağı tabanlı yöntemlerin hiperspektral görüntülere uygulanması için iki ayrı model üretilmiştir. Her iki modelde, giriş görüntüsünden uzamsal ve spektral veriler ayrılmakta ve her bir özellik ayrı olarak değerlendirilmektedir. Hesaplama yükünü azaltmak için kullanılacak spektral veri, yakın dalga boyuna sahip her 3 spektral katmandan 1 tanesi seçilerek değerlendirilmektedir.

3.1.1 Derin Evrişim Ağı Modeli

Son yıllarda evrişimsel sinir ağlarının görüntü işlemedeki başarılarından esinlenerek, doğal görüntüler için basit bir evrişimsel sinir ağı mimarisi kullanan, tekli görüntülerin süper çözünürlüğü yöntemi önerilmiştir [104]. Tez çalışmasında bu yöntem hiperspektral görüntülere uygulayabilmek için geliştirilmiştir. Yöntemin derin öğrenme yapısı Şekil 3.2’de verilmiştir. Giriş görüntüsü olarak verilen düşük çözünürlüklü hiperspektral görüntünden öncelikle spektral ve uzamsal bilgiler ayrıştırılmaktadır. Ayrıştırılan her bir bant istenilen ölçeklendirme katsayısı oranında bikübik enterpolasyon ile yeniden boyutlandırılmaktadır. Yeniden boyutlandırılan görüntü, görüntü parçalarının ve öznelik matrislerinin çıkarılması için ilk olarak, birinci evrişim katmanına girmektedir. Birinci evrişim katmanının matematiksel olarak ifadesi Eşitlik 3.1’de verilmiştir.

$$F_1(Y) = \max(0, W_1 * Y + B_1) \quad (3.1)$$

Burada, Y bikübik enterpolasyon ile yeniden boyutlandırılmış düşük çözünürlüklü görüntüyü, $F_1(Y)$ birinci evrişim katmanının filtre tepkisinin ReLU ile aktive edilmiş çıkış fonksiyonunu, W_1 evrişim filtresini B_1 bias değerini göstermektedir. W_1 , n_1 adet evrişim filtresinden oluşmaktadır. Giriş kanalı sayısı c olan bir görüntü için boyutu f_1 olan bir filtre uygulandığında her bir evrişim $c \times f_1 \times f_1$ boyutunda çekirdeğe sahip olur. Çıkış ise n_1 adet öznitelik matrisinden oluşur. B_1 , n_1 boyutlu ve her bir elemanı filtre ile ilişkili bir bias vektörüdür.

İkinci evrişim katmanında, birinci evrişim katmanından elde edilen n_1 adet öznitelik matrisi kullanılarak, yüksek çözünürlüklü öznitelikler adı verilen başka bir n_2 adet öznitelik matrisi ile doğrusal olmayan bir eşleşme haritalaması oluşturulur. Bu katmanın matematiksel ifadesi Eşitlik 3.2'de verilmiştir.

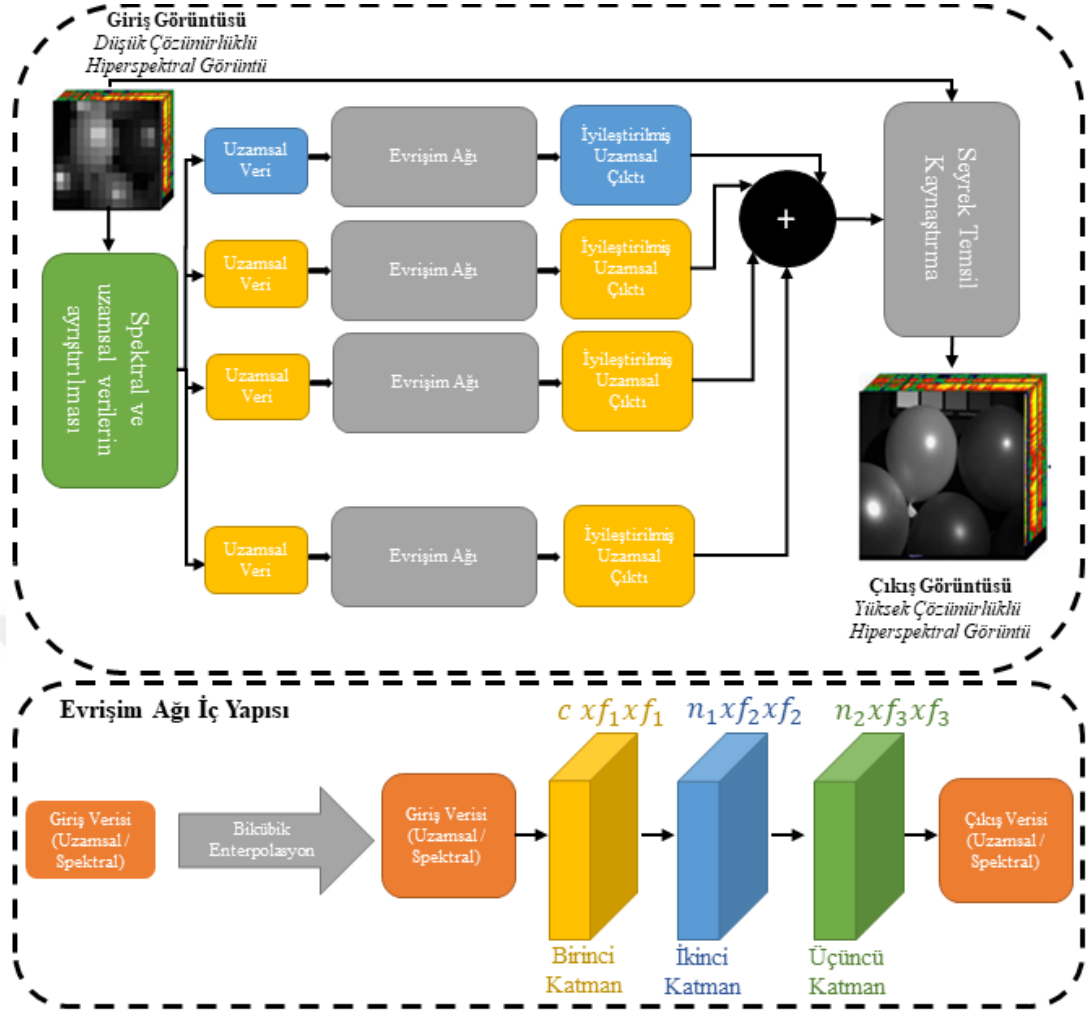
$$F_2(Y) = \max(0, W_2 * F_1(Y) + B_2) \quad (3.2)$$

Burada, W_2 , n_2 adet $n_1 \times f_2 \times f_2$ boyutunda evrişim filtresinden oluşmaktadır. B_2 , n_2 boyutludur. Her bir çıktı yeniden yapılandırma için kullanılmak üzere oluturan n_2 boyutlu yüksek çözünürlüklü bilgileri içeren parçalara sahip matrislerdir. $F_2(Y)$ ikinci evrişim katmanının filtre tepkisinin ReLU ile aktive edilmiş çıkış fonksiyonunu göstermektedir.

Son adım olan üçüncü evrişim katmanında, ikinci evrişim katmanından elde edilen yüksek görüntü özellikleri içeren parçalar, yeniden yapılandırılarak yüksek çözünürlüklü görüntüyü oluşturmaktadır. Son adımın matematiksel ifadesi Eşitlik 3.3'te verilmiştir.

$$F(Y) = W_3 * F_2(Y) + B_3 \quad (3.3)$$

Burada $F(Y)$ üçüncü evrişim katmanının filtre tepkisini, yani elde edilmek istenilen yüksek çözünürlüklü görüntüyü göstermektedir. W_3 , c adet $n_2 \times f_3 \times f_3$ boyutunda evrişim işleminden oluşmaktadır. B_3 , c boyutlu bir matristir.



Şekil 3.2 Derin evrişim ağı ile önerilen yöntemin gösterimi.

3.1.2 Derin Kalıntı Ağı Modeli

Doğal görüntüler için evrişimli sinir ağları ile kurulan süper çözünürlük algoritmalarında evrişim işleminin ardışık olarak yapılmasıyla kaybolan özniteliklerinde yeniden yapılandırmaya dahil edilmesi için yoğun atlamalı ağları ve derin kalıntı ağları kullanılarak yöntem önerilmiştir [105]. Tez çalışmasında bu yöntem hyperspektral görüntülere uygulamak için geliştirilmiştir. Yöntem lokal ve global artık ağları ile ana ağın beslenmesi prensibine dayanmaktadır. Yöntemin derin öğrenme yapısı Şekil 3.3'te verilmiştir.

Yoğun atlamalı ağlar, klasik derin kalıntı ağlarından farklı olarak, öznitelik matrislerini doğrudan toplamak yerine yoğun atlama bağlantılarında birleştirmektedir. Böylece, yoğun bloktaki i . katman, kendisinden önceki tüm katmanların öznitelik matrislerine de sahip olmaktadır. Eşitlik 3.4 ile i . katmanın girişi matematiksel olarak ifade edilmektedir.

$$x_i = H_i([x_0, x_1, \dots, x_{i-1}]) \quad (3.4)$$

Burada x_i önceki katmanlar kullanılarak üretilen, öznitelik matrislerinin birleşimini temsil etmektedir. H_i ; i . katmanın girişinde doğrusal olmayan bir dönüşüm uygulayan rektifiye lineer birim, evrişim gibi işlemlerin bileşik bir işlevini ifade etmektedir.

Geliştirilen modelde, giriş görüntüsünden uzamsal ve spektral veriler ayrılmakta ve her bir özellik ayrı ağlarda değerlendirilmektedir. Şekil 3.3'te görüleceği üzere, derin kalıntı ağında eğitilecek uzamsal veri ve seçilmiş spektral verilere ait öznitelik matrislerinin çıkarılması için, ilk adım olarak evrişim işlemine tabi tutularak, ağ içerisinde oluşturulmuş ardışık besleme katmanlarına girmektedir. Besleme katmanları, yerel olarak oluşturulmuş derin kalıntı ağlarından oluşmaktadır. Besleme katmanlarında elde edilen öznitelik matrisleri doğrudan toplanmak yerine, lokal kalıntı öğrenme bağlantısı ile ilk öznitelik matrisinde yeniden oluşturmaya dahil edilmektedir. Ayrıca her bir besleme katmanını oluşturan ardışık konvolüsyon ve aktivasyon işlemleri sonucunda elde edilen öznitelik matrisleride bir sonraki yapıya dahil edilmektedir. Böylece, besleme katmanındaki yapı, kendisinden önceki tüm katmanların öznitelik matrislerine de sahip olmaktadır. Eşitlik 3.4 ile besleme katmanının matematiksel olarak çıktısı ifade edilmektedir.

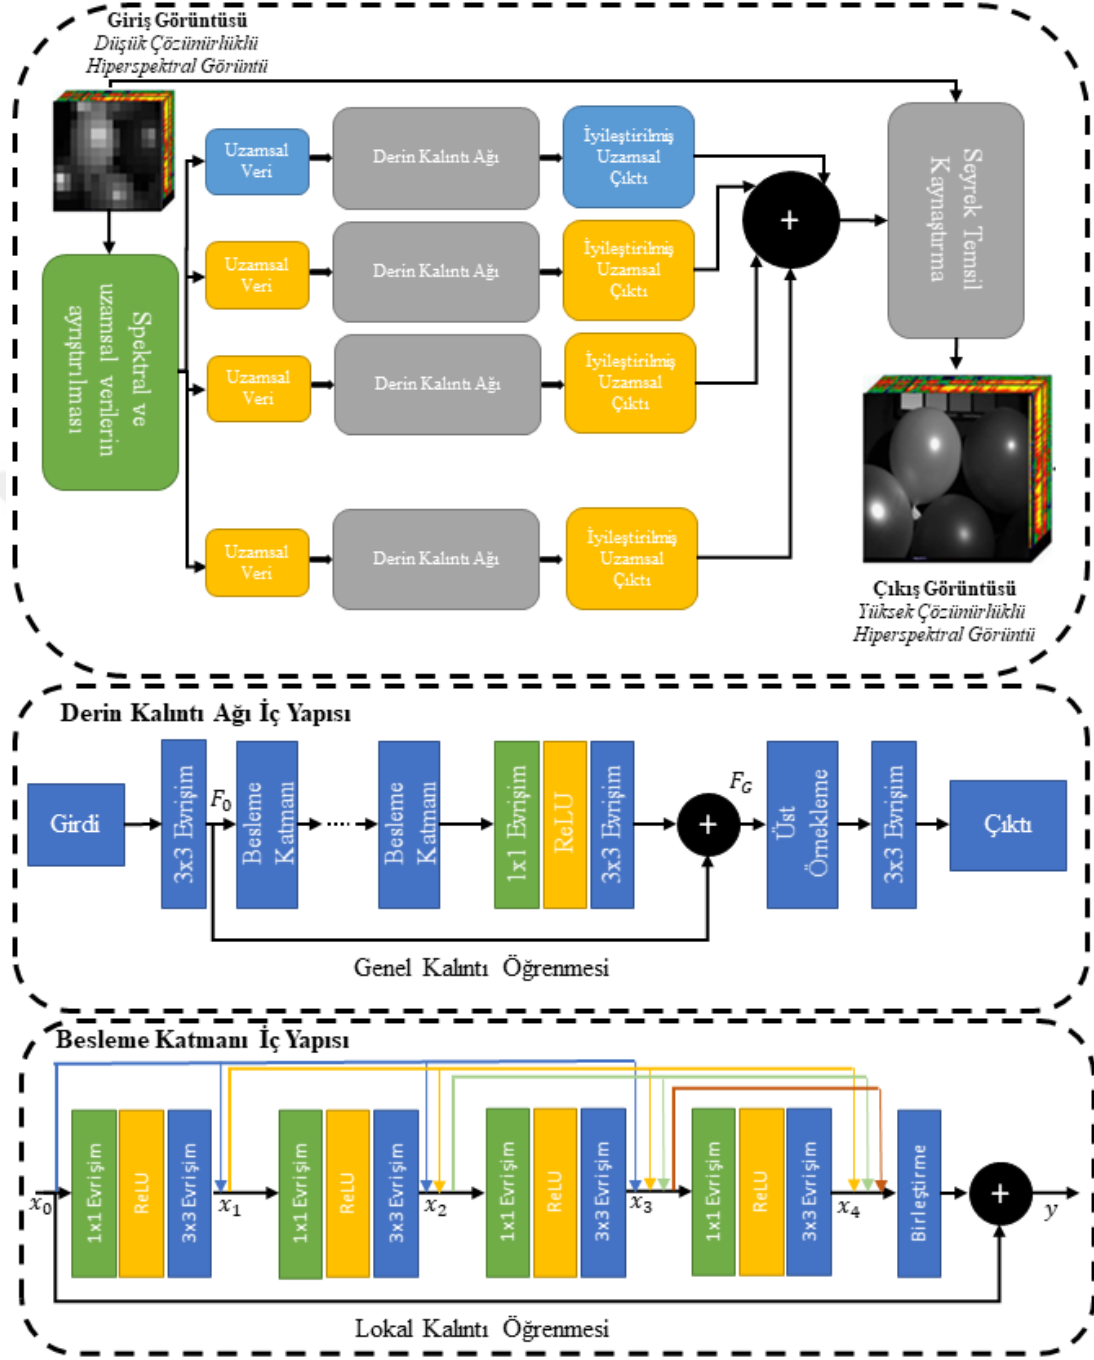
$$y = x_0 + [x_1, x_2, \dots, x_n] \quad (3.4)$$

Burada y besleme katmanının çıktısını, x_0 besleme katmanının girdisini, $[x_1, x_2, \dots, x_n]$ evrişim ve aktivasyon işlemlerinden oluşan her bir yapının çıktısını göstermektedir.

Kalıntı öğrenme; ilk olarak derin kalıntı ağlarda önerilen, belirli bir katmanın giriş özelliklerini başka bir katmana atlayan, bir atlama bağlantısı ile gerçekleştirilmektedir. Bu özellik sayesinde, düşük çözünürlüklü görüntü bilgisi ile yüksek çözünürlüklü görüntü bilgisi arasında olan ilişkinin öğrenilmesi için katkı sağlamaktadır. Ayrıca, kalıntı ağlarının kullanılması, kaybolan gradyan sorununu azaltmakta ve yeniden yapılandırma performansını anlamlı şekilde iyileştirmektedir.

Her bir H_i işlevi k adet öznitelik matrisi üretmektedir, bu durumda i . katman girdi öznitelik matrisi sayısı Eşitlik 3.6 ile hesaplanmaktadır.

$$k_i = k_0 + k_1 + \dots + k_{i-1} \quad (3.6)$$



Şekil 3.3 Derin kalıntı ağı ile önerilen yöntemin gösterimi

Burada, k_0 ; besleme bloklarındaki giriş kanallarının sayısını temsil etmektedir. k_i ; i . katmandaki büyüme oranını göstermektedir. Büyüme oranı k , her katmanın besleme bloğunun çıktısına ne kadar bilgi kattığını kontrol etmektedir. Her bir besleme katmanı için, giriş kanallarının sayısı oldukça fazla hesaplanmaktadır. Bu nedenle, yoğun

evrişimli ağlarda kullanılan darboğaz katmanı ile ağ parametreleri azaltılarak, aşırı uyum riski azaltılmaktadır. Darboğaz katmanı, besleme bloklarında 3×3 evrişim katmanının önüne 1×1 evrişim katmanı yerleştirilerek kullanılmıştır.

Önerilen yöntemde, genel kalıntı öğrenmesi ise Eşitlik 3.7'deki gibi hesaplanmaktadır.

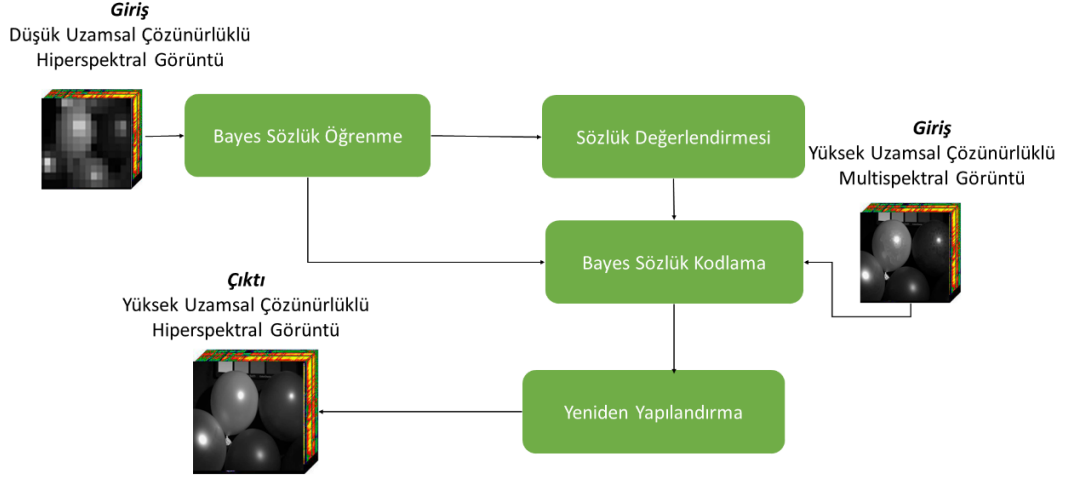
$$F_G = F_0 + H_F(H_D(F_0)) \quad (3.7)$$

Burada, F_0 ; öznelilik matrisi çıkarmak için uygulanan konvolüsyon işleminin sonucudur. H_B ; besleme bloklarının çıktısını ve H_Y ; yeniden yapılandırma işlemini belirtmektedir.

3.2 Seyrek Temsil Tabanlı Kısım

Görüntü kaynaştırma tabanlı süper çözünürlük uygulamalarında, seyrek temsil tabanlı yöntemler oldukça başarılı sonuçlar göstermektedir. Bu tez çalışmasında, geliştirilen derin öğrenme modellerinden elde edilen yüksek uzamsal çözünürlüğü çıktı ile düşük uzamsal çözünürlüklü giriş görüntüsünün spektral verisi, literatürde başarılı sonuçlar veren Bayes seyrek temsil yöntemi ile kaynaştırılmıştır. Bayes seyrek temsil yöntemi 4 aşamalı olarak sunulmuş bir görüntü kaynaştırma yöntemidir [54]. Yöntemin temel şeması, Şekil 3.4'te verilmiştir.

Birinci adımda, öncelikle $Y^h \in \mathbb{R}^{m \times n \times L}$ düşük uzamsal çözünürlüklü görüntü $(m \times n) \times L$ boyutunda 2 boyutlu bir matrise çevirilerek ifade edilmektedir. Elde edilen matris ile öncelikle görüntünün içerdiği spektral imza sayısı, Bernoulli dağılımı yardımıyla hesaplanmaktadır. İkinci aşamada, spektral veriden öğrenilen dağılım kullanılarak sözlük hesaplaması yapılmaktadır. Hesap edilen sözlük, aynı sahnenin yüksek çözünürlüklü bir görüntüsünün spektral nicelenmesine göre dönüştürülmektedir. Üçüncü aşamada; Bayes seyrek kodlama kullanılarak hesaplanan sözlük ve dağılımlar yardımıyla, yüksek uzamsal çözünürlüklü görüntünün seyrek kodlaması yapılmaktadır. Dördüncü aşamada; hesaplanan sözlük ve seyrek kodlar kullanılarak yüksek uzamsal çözünürlüklü hiperspektral görüntü elde edilmektedir.



Şekil 3.4 Bayes seyrek temsil ile süper çözünürlüğün algoritmik gösterimi [54]

$Y^h \in \mathbb{R}^{m \times n \times L}$ düşük uzamsal çözünürlüklü hiperspektral görüntüsünde, $m \times n$ uzamsal boyutu, L spektral boyutu göstermektedir. $Y^m \in \mathbb{R}^{M \times N \times l}$ yüksek uzamsal çözünürlüklü multispektral görüntüsünde, $M \times N$ uzamsal boyutu, l spektral boyutu göstermektedir. Görüntü kaynaştırma işlemi sonucunda, $S \in \mathbb{R}^{M \times N \times L}$ boyutlarında süper çözünürlüklü hiperspektral görüntü elde edilmektedir.

$\Phi \in \mathbb{R}^{L \times |K|}$, φ_k sütuna sahip bilinmeyen bir matris olsun. Burada, $k \in K = \{1, \dots, K\}$ ve $|\cdot|$ spektral imza kümesinin kardinalitesini belirtmektedir. φ_k , hiperspektral görüntü içerisindeki farklı nesnelerin spektral imzalarını ifade etmektedir. Düşük uzamsal çözünürlüklü Y^h matrisinin her sütunu işleme sokularak, Y^h ve bir katsayı matrisi $A \in \mathbb{R}^{K \times mn}$ ile \bar{Y}^h matrisi elde edilir. Bu işlemin matematiksel ifadesi Eşitlik 3.8’de verilmiştir.

$$\bar{Y}^h = \Phi A \quad (3.8)$$

Benzer şekilde $\hat{\Phi} \in \mathbb{R}^{L \times |K|}$ sözlüğü, yüksek uzamsal çözünürlüklü görüntü Y matrisinin her sütunu işleme sokularak, bir katsayı matrisi $B \in \mathbb{R}^{K \times MN}$ ile bir \bar{Y} matrisi elde edilir. Bu işlemin matematiksel ifadesi Eşitlik 3.9’da verilmiştir.

$$\bar{Y} = \hat{\Phi} B \quad (3.9)$$

Elde edilen yeni matrisler ile \bar{Y}^h ve \bar{Y} aynı sahneye ait görüntüleri temsil etmektedir. Φ ve $\hat{\Phi}$ orijinal Y ve Y^h görüntülere ait oluşturulan sözlükleri, A ve B matrisleri ise seyrek kodlama matrislerini göstermektedir. Φ ve $\hat{\Phi}$ sözlükleri arasında $\hat{\Phi} = \Phi \pi$ şeklinde bir ilişki vardır. Burada, $\pi \in \mathbb{R}^{l \times L}$ dönüşüm matrisini göstermektedir.

Bayes sözlük öğrenmesinde, y_i^h , Y^h 'nin i 'ninci pikselini temsil etmektedir. Φ sözlüğü üzerinde her bir pikselin seyrek gösterimi β_i^h ve oluşturma hatası ϵ_i^h olduğunda; Bayes sözlük öğrenme Eşitlik 3.10 ile ifade edilir.

$$y_i^h = \Phi\beta_i^h + \epsilon_i^h \quad (3.10)$$

Sözlük öğrenme süreci, belli iterasyonlarda aralara baz noktası yerleştirilerek test edilir. Test süreci, OKH sabit bir değer verinceye kadar devam etmektedir.



4. UYGULAMA VE SONUÇLARI

4.1 Veri Setleri

Bu tez çalışması kapsamında geliştirilen yöntemlerde, literatürde sıkça kullanılan CAVE ve Harvard veri setleri kullanılmıştır.

CAVE veri seti, 32 adet hiperspektral görüntüden oluşmaktadır. Görüntüler 512x512x31 boyutunda ve spektral görsel aralığı 400-700 nm olup, 10 nm 'lik dalga boyu aralığında elde edilmiştir [106]. Harvard veri seti; 400 nm-700nm dalga boyu aralığında Nuance FX, CRI Inc. kamera ile elde edilmiştir. Veri seti; gün ışığı aydınlatması altında, gerçek dünya iç veya dış mekân sahnelerinin 77 adet hiperspektral görüntüsünden oluşur. Bu veri setinde her hiperspektral görüntünün boyutu $1392 \times 1040 \times 31$ 'dir [107].

4.2 Uygulama Detayları

Harvard veri setindeki görüntüler sol köşeden referans alınarak 1024x1024x31 boyutunda olacak şekilde kırpılmıştır. CAVE veri setindeki görüntüler orijinal boyutunda kullanılmıştır. Orijinal görüntüler referans alınarak, düşük uzamsal çözünürlüklü görüntü oluşturmak için, orijinal görüntü üzerinde Gauss blurlama, yatay olarak döndürme (90° , 180° ve 270°) ve biküçük enterpolasyon ile ölçeklendirme (1, 0.75 ve 0.5) işlemlerine tabi tutulmuştur. Son olarak, tekrar biküçük enterpolasyon ile orijinal boyutlarına getirilerek, düşük uzamsal çözünürlüklü hiperspektral görüntüler elde edilmiştir.

Veri setlerindeki görüntüler %80 eğitim, %10 doğrulama ve %10 tanesi test verisi olacak şekilde seçilmiştir. CAVE veri setinde her bir görüntü, en az bir kere test verisi olacak şekilde; eğitim, doğrulama ve test verileri kombinasyonları değiştirilerek, model birden fazla kez çalıştırılmıştır. Harvard veri setinde 61 adet görüntü eğitim, 8 adet görüntü doğrulama ve 8 adet test verisi her iki modelde de sabit tutularak, sinir ağları eğitilmiştir. Derin öğrenme algortimalarının başarısında eğitim verisi miktarı önem arz etmektedir. Eğitim verisini arttırmak için kurulan sinir ağlarını eğitmek

üzere, veri setindeki görüntüler $32 \times 32 \times L$ boyutunda düşük çözünürlüklü hiperspektral görüntüler olarak alt parçalara ayrılmıştır. Test görüntüleri ölçek faktörü 2,3 ve 4 alınarak yeniden boyutlandırılmış ve farklı büyütme oranlarındaki başarımlar test edilmiştir.

Oluşturulan sinir ağlarında kayıp fonksiyonu orijinal modelden farklı olarak, OKH ve SAH değerleri kullanılmıştır. Kayıp fonksiyonlarını minimize etmek için ise Adam optimizasyonu kullanılmıştır. Eğitmek için $\beta_1 = 0,9$ ve $\beta_2 = 0,999$ olarak alınmıştır. Öğrenme oranı tüm katmanlar için 10^{-4} olarak belirlenmiştir. Derin evrişimli sinir ağında kullanılan parametreler Çizelge 4.1’de verilmiştir. Derin kalıntı ağında ise 16 adet besleme bloğundan oluşan genel ağ yapısı kullanılmıştır. Her bir besleme bloğunun içerisinde 4 adet 3×3 evrişim, ReLU ve 1×1 evrişim katmanından oluşan yapı bulunmaktadır. Modelin büyüme kat sayısı k, 16 olarak alınmıştır.

Çizelge 4.1 Derin evrişimli sinir ağında kullanılan parametreler

Katman	Kanal Sayısı	Filtre Boyutu	Filtre Sayısı
Birinci Katman	1	9×9	64
İkinci Katman	64	1×1	32
Üçüncü Katman	32	5×5	1

Sinir ağı modelleri ile elde edilen süper-çözünürlüklü görüntü ile giriş görüntüsü olan düşük uzamsal çözünürlüklü görüntü, füzyon tabanlı olan Bayes Sözlük Öğrenmesi yöntemi ile kaynaştırılmıştır. Algoritma, sözlük öğrenme için 1000 ve her bir seyrek kod için 25 iterasyon yapacak şekilde ayarlanmıştır.

4.3 Sonuçlar

CAVE veri seti üzerinde yapılan derin evrişimli sinir ağı ve seyrek temsil tabanlı hibrit yöntemin uygulamasından elde edilen sonuçları Çizelge 4.2’de ve derin kalıntı ağı ve seyrek temsil tabanlı hibrit yöntemin uygulamasından elde edilen sonuçları Çizelge 4.3’de verilmiştir.

Çizelge 4.2 Derin evrişimli sinir ağı ve seyrek temsil tabanlı hibrit yöntemin, CAVE veri setine uygulanması sonucu elde edilen süper-çözünürlüklü görüntülerin OKH ve SAH sonuçları

SIR A	GÖRÜNTÜ ADI	Ölçek Faktörü (x2)		Ölçek Faktörü (x3)		Ölçek Faktörü (x4)	
		OKH	SAH	OKH	SAH	OKH	SAH
1	Apple	1,8769	3,5814	2,1043	5,0628	2,4758	6,4065
2	Balloons	1,5895	1,4524	1,7821	2,0530	2,0967	2,5980
3	Beads	4,0858	0,8598	4,5810	1,2155	5,3896	1,5380
4	Beers	1,7406	3,7482	1,9517	5,2986	2,2961	6,7047
5	CD	4,0105	0,8538	4,4966	1,2069	5,2902	1,5272
6	Chart and Stuffed toys	2,4146	3,1057	2,7072	4,3903	3,1850	5,5554
7	Clay	2,0429	2,1447	2,2905	3,0319	2,6948	3,8364
8	Cloth	3,0272	3,5820	3,3940	5,0635	3,9930	6,4074
9	Egyptian Statue	1,0596	6,4875	1,1881	9,1710	1,3978	11,6049
10	Face	1,4380	1,6877	1,6123	2,3858	1,8969	3,0189
11	Feathers	3,0266	3,5182	3,3934	4,9735	3,9923	6,2935
12	Flowers	3,4826	11,6483	3,9046	16,4664	4,5937	20,8363
13	Food	1,9449	3,3498	2,1806	4,7353	2,5655	5,9920
14	Glass tiles	1,9684	3,4702	2,2070	4,9055	2,5965	6,2074
15	Hairs	1,6653	4,0784	1,8671	5,7653	2,1966	7,2953
16	Jelly beans	3,6332	5,8259	4,0734	8,2356	4,7924	10,4214
17	Lemon slices	2,1950	1,4867	2,4610	2,1017	2,8954	2,6595
18	Lemons	1,8142	2,0010	2,0340	2,8288	2,3931	3,5795
19	Oil Painting	1,4361	7,9521	1,6102	11,2414	1,8944	14,2247
20	Paints	2,4196	1,3059	2,7129	1,8460	3,1916	2,3360
21	Peppers	2,0410	5,5487	2,2884	7,8437	2,6923	9,9254
22	Photo and face	1,4365	2,3427	1,6106	3,3118	1,8949	4,1906
23	Pompoms	3,0233	2,2089	3,3897	3,1226	3,9879	3,9512
24	Sponges	3,0244	1,7296	3,3910	2,4450	3,9894	3,0938
25	Strawberries	1,9655	3,6830	2,2037	5,2065	2,5926	6,5882
26	Stuffed toys	3,0235	4,7475	3,3899	6,7113	3,9882	8,4924
27	Super balls	1,9653	1,5006	2,2036	2,1215	2,5925	2,6845
28	Sushi	2,1927	1,4852	2,4584	2,0996	2,8923	2,6568
29	Thread spools	3,4762	2,5396	3,8974	3,5901	4,5853	4,5428
30	Tomatoes	2,0411	1,1887	2,2886	1,6805	2,6925	2,1264
31	Yellow peppers	1,5869	2,6774	1,7792	3,7849	2,0932	4,7895

Çizelge 4.3 Derin kalıntı ağı ve seyrek temsil tabanlı hibrit yöntemin, CAVE veri setine uygulanması sonucu elde edilen süper-çözünürlüklü görüntülerin OKH ve SAH sonuçları

SIR A	GÖRÜNTÜ ADI	Ölçek Faktörü (x2)		Ölçek Faktörü (x3)		Ölçek Faktörü (x4)	
		OKH	SAH	OKH	SAH	OKH	SAH
1	Apple	1,6127	3,1079	1,7114	4,4418	1,9782	5,5832
2	Balloons	1,3656	1,2602	1,4492	1,8010	1,6751	2,2639
3	Beads	3,5115	0,7463	3,7266	1,0667	4,3074	1,3407
4	Beers	1,4956	3,2527	1,5873	4,6487	1,8346	5,8432
5	CD	3,4465	0,7410	3,6576	1,0590	4,2276	1,3312
6	Chart and Stuffed toys	2,0744	2,6947	2,2014	3,8512	2,5445	4,8408
7	Clay	1,7557	1,8616	1,8633	2,6606	2,1537	3,3442
8	Cloth	2,6011	3,1085	2,7604	4,4426	3,1906	5,5842
9	Egyptian Statue	0,9104	5,6293	0,9662	8,0454	1,1168	10,1128
10	Face	1,2355	1,4645	1,3112	2,0931	1,5156	2,6309
11	Feathers	2,6011	3,0537	2,7604	4,3644	3,1906	5,4859
12	Flowers	2,9913	10,1049	3,1745	14,4418	3,6692	18,1527
13	Food	1,6712	2,9071	1,7736	4,1548	2,0500	5,2224
14	Glass tiles	1,6907	3,0103	1,7943	4,3022	2,0739	5,4078
15	Hairs	1,4306	3,5385	1,5182	5,0571	1,7548	6,3566
16	Jelly beans	3,1214	5,0551	3,3125	7,2247	3,8288	9,0813
17	Lemon slices	1,8858	1,2900	2,0013	1,8437	2,3132	2,3175
18	Lemons	1,5606	1,7385	1,6562	2,4847	1,9144	3,1232
19	Oil Painting	1,2355	6,9096	1,3112	9,8752	1,5156	12,4127
20	Paints	2,0809	1,1343	2,2084	1,6211	2,5525	2,0377
21	Peppers	1,7557	4,8207	1,8633	6,8896	2,1537	8,6600
22	Photo and face	1,2355	2,0350	1,3112	2,9085	1,5156	3,6558
23	Pompoms	2,6011	1,9194	2,7604	2,7432	3,1906	3,4480
24	Sponges	2,6011	1,5023	2,7604	2,1471	3,1906	2,6988
25	Strawberries	1,6907	3,1997	1,7943	4,5730	2,0739	5,7481
26	Stuffed toys	2,6011	4,1250	2,7604	5,8954	3,1906	7,4103
27	Super balls	1,6907	1,3038	1,7943	1,8635	2,0739	2,3423
28	Sushi	1,8858	1,2901	2,0013	1,8438	2,3132	2,3176
29	Thread spools	2,9913	2,2071	3,1745	3,1545	3,6692	3,9650
30	Tomatoes	1,7557	1,0327	1,8633	1,4760	2,1537	1,8552
31	Yellow peppers	1,3656	2,3270	1,4492	3,3257	1,6751	4,1804


Harvard veri seti üzerinde yapılan derin evrişimli sinir ağı ve seyrek temsil tabanlı hibrit yöntemin uygulamasından elde edilen sonuçları Çizelge 4.4'te ve derin kalıntı ağı ve seyrek temsil tabanlı hibrit yöntemin uygulamasından elde edilen sonuçları Çizelge 4.5'te verilmiştir.

Çizelge 4.4 Derin evrişimli sinir ağı ve seyrek temsil tabanlı hibrit yöntemin, Harvard veri setine uygulanması sonucu elde edilen süper-çözünürlüklü görüntülerin OKH ve SAH sonuçları

SIRA	GÖRÜNTÜ ADI	Ölçek Faktörü (x2)		Ölçek Faktörü (x3)		Ölçek Faktörü (x4)	
		OKH	SAH	OKH	SAH	OKH	SAH
1	imga2	2,4388	1,9445	2,8582	2,4638	3,6251	3,0367
2	imgb5	1,0016	1,6853	1,1739	2,1354	1,4893	2,6326
3	imgc7	1,0225	1,6593	1,1979	2,1016	1,5207	2,5926
4	imgd3	1,1381	2,5927	1,3337	3,2848	1,6917	4,0489
5	imge7	1,5603	2,0223	1,8251	2,5576	2,3184	3,1571
6	imgf6	2,9763	3,5779	3,4815	4,5248	4,4213	5,5840
7	imgf8	2,7459	4,7446	3,2133	6,0028	4,0781	7,4034
8	imggh0	1,8932	1,5038	2,2148	1,9019	2,8132	2,3476

Çizelge 4.5 Derin kalıntı ağı ve seyrek temsil tabanlı hibrit yöntemin, Harvard veri setine uygulanması sonucu elde edilen süper-çözünürlüklü görüntülerin OKH ve SAH sonuçları

SIRA	GÖRÜNTÜ ADI	Ölçek Faktörü (x2)		Ölçek Faktörü (x3)		Ölçek Faktörü (x4)	
		OKH	SAH	OKH	SAH	OKH	SAH
1	imga2	2,2101	2,1068	2,4391	2,6821	3,0211	3,3179
2	imgb5	1,1179	1,6321	1,2337	2,0776	1,5284	2,5705
3	imgc7	0,6017	1,7211	0,6642	2,1914	0,8231	2,7122
4	imgd3	0,9537	2,0475	1,0528	2,6072	1,3046	3,2267
5	imge7	0,7951	1,2166	0,8765	1,5472	1,0863	1,9151
6	imgf6	2,3214	2,7003	2,5593	3,4340	3,1715	4,2500
7	imgf8	3,4120	4,4511	3,7608	5,6592	4,6588	7,0016
8	imggh0	1,1904	1,1869	1,3121	1,5090	1,6254	1,8671



(a)




(b)



(c)

Şekil 4.1 Harvard veri setindeki “imga2”, “imgb5” ve “imgc7” isimli hiperspektral görüntülerin, derin kalıntı ağı ve seyrek kodlama tabanlı hibrit model ile süper çözünürlük uygulaması sonucunda girdi ve çıktılarının görüntüsü



(a)



(b)




(c)


Şekil 4.2 Harvard veri setindeki “imgd3”, “imge7” ve “imgf8” isimli hiperspektral görüntülerin, derin kalıntı ağı ve seyrek kodlama tabanlı hibrit model ile süper çözünürlük uygulaması sonucunda girdi ve çıktıların görüntüsü



(a)





(b)





(c)

Şekil 4.3 CAVE veri setinde bulunan “Egyptian Statue”, “Tomatoes” ve “Flowers” isimli hiperspektral görüntülerin, derin kalıntı ağı ve seyrek kodlama tabanlı hibrit model ile süper çözünürlük uygulaması sonucunda girdi ve çıktılarının görüntüsü



(a)




(b)



(c)

Şekil 4.4 CAVE veri setinde bulunan “Beads”, “CD” ve “Chart and Stuffed toys” isimli hiperspektral görüntülerin, derin kalıntı ağı ve seyrek kodlama tabanlı hibrit model ile süper çözünürlük uygulaması sonucunda girdi ve çıktılarının görüntüsü



(a)



(b)



(c)

Şekil 4.5 CAVE veri setinde bulunan “Cloth”, “Faces” ve “Food” isimli hyperspektral görüntülerin, derin kalıntı ağı ve seyrek kodlama tabanlı hibrit model ile süper çözünürlük uygulaması sonucunda girdi ve çıktıların görüntüsü

Şekil 4.1 ve Şekil 4.2’de sırasıyla Harvard veri setindeki imga2, imgb5, imgc7, imgd3, imge7 ve imgf8 isimli hiperspektral görüntüleri ile Şekil 4.3, Şekil 4.4 ve Şekil 4.5’te sırasıyla CAVE veri setinde bulunan “Egyptian Statue”, “Tomatoes”, “Flowers”, “Beads”, “CD”, “Chart and Stuffed toys”, “Cloth”, “Faces” ve “Food” isimli hiperspektral görüntülerin derin kalıntı ağı ve seyrek kodlama tabanlı hibrit model ile süper çözünürlük uygulaması sonucunda girdi ve çıktılarının görüntüsü verilmiştir.

Çizelge 4.6 ve Çizelge 4.7’de, önerilen yöntemlerin literatürde kullanılan, bikübik, GFPCA [39] ve SCT_SDCNN [72] yöntemlerine göre karşılaştırması sunulmuştur. Önerilen yöntemlerin, literatürde kabul görmüş yöntemlere göre özellikle spektral düzlemde iyi sonuçlar verdiği görülmüştür.

Çizelge 4.6 Önerilen yöntemlerin, CAVE veri setine göre literatürdeki diğer yöntemlere göre OKH ve SAH ortalama değerlerinin karşılaştırılması

Yöntem	Ölçek Faktörü (x2)		Ölçek Faktörü (x3)		Ölçek Faktörü (x4)	
	Ortalama OKH	Ortalama SAH	Ortalama OKH	Ortalama SAH	Ortalama OKH	Ortalama SAH
Bikübik	3,0751	7,7547	3,1290	10,2485	3,3475	11,4764
GFPCA	2,9098	6,6691	2,9307	9,1212	3,1352	10,4437
SCT_SDCNN	2,0625	3,6156	2,3320	5,4177	2,7023	6,3318
Evrişimli Sınır Ağı Tabanlı	2,3435	3,2836	2,6275	4,6418	3,0912	5,8737
Derin Kalıntı Ağı Tabanlı	2,0146	2,8507	2,1380	4,0742	2,4712	5,1211

Çizelge 4.7 Önerilen yöntemlerin, Harvard veri setine göre literatürdeki diğer yöntemlere göre OKH ve SAH ortalama değerlerinin karşılaştırılması

Yöntem	Ölçek Faktörü (x2)		Ölçek Faktörü (x3)		Ölçek Faktörü (x4)	
	Ortalama OKH	Ortalama SAH	Ortalama OKH	Ortalama SAH	Ortalama OKH	Ortalama SAH
Bikübik	2,6287	6,2398	2,9034	7,0563	3,3343	8,7641
GFPCA	2,5172	5,0676	2,4595	6,2308	2,8997	7,5734
SCT_SDCNN	1,6542	2,7320	1,9421	3,6680	2,4770	4,4290
Evrişimli Sinir Ağı Tabanlı	1,8471	2,4663	2,1623	3,1216	2,7447	3,8504
Derin Kalıntı Ağı Tabanlı	1,5753	2,1328	1,7373	2,7135	2,1524	3,3576

4.4 Tartışma

Bu tezin temel amacı; hiperspektral görüntüler ile yapılan uygulamalarda, uygulama performansının artırılması için yüksek uzamsal çözünürlüğe sahip hiperspektral görüntülerin, süper çözünürlük yöntemleri ile oluşturulmasıdır.

Tez çalışması kapsamında, literatürde yer alan tekli görüntüler üzerinde yapılan süper çözünürlük yöntemleri ve görüntü kaynaştırma tabanlı yöntemlerin ortak kullanımı ile yeni bir model geliştirilmesi üzerine çalışılmıştır. Bu kapsamda, derin öğrenme yöntemleri ile uzamsal çözünürlük artırılırken; seyrek temsil yöntemi ile spektral verinin görüntü üzerine kaynaştırılması sağlanmıştır. Geliştirilen yöntem sayesinde, derin öğrenmenin düşük ve yüksek uzamsal çözünürlük arasındaki bağı kurması sağlanmış, 2 boyutlu evrişim işleminin sadece seçilen bantlara uygulanması ile işlem yükü azaltılmıştır. Literatürde başarılı sonuçlar veren seyrek temsil yöntemi sayesinde de spektral verinin başarılı bir şekilde kaynaştırılması yapılmıştır.

Elde edilen sonuçlara bakıldığında; önerilen yöntemlerin literatürde kabul görmüş yöntemlere göre başarılı sonuçlar verdiği görülmüştür. Böylece, tekli görüntüler için geliştirilen yöntemler ile görüntü kaynaştırma tabanlı yöntemlerin ortak kullanımı

sonucunda başarılı sonuçlar elde edilebileceği gösterilerek, literatüre katkı sağlayacak öncü bir çalışma yapılmıştır.

Önerilen her iki derin öğrenme tabanlı yöntem incelendiğinde, derin kalıntı ağını kullanan yöntemin hem evrişimli sinir ağı tabanlı yöntemine hemde karşılaştırma yapılan diğer yöntemlere göre başarılı sonuçlar ürettiği görülmektedir. Yöntemin başarısının; ardışık evrişim işlemleri esnasında kaybedilen bazı özneliklerin, kalıntı ağları ile tekrar değerlendirilmeye alınmasından ötürü geldiği düşünülmektedir. Ölçeklendirme faktörü büyüdükçe, diğer yöntemler daha çok kayba uğrarken, derin kalıntı ağı ile geliştirilen model daha az kayba uğramıştır.

Öğrenme tabanlı olarak geliştirilen yöntem, veri setlerinden eğitim için ayrılan görüntülerin derin öğrenme ağlarını eğitmesi ile gerçekleşmektedir. Bu nedenle yöntem, uygulamadan önce eğitim verilerine ihtiyaç duymaktadır. Kullanılan veri setleri her ne kadar farklı sahnelere ait olsa da benzer özellikler taşımaktadır. Yöntemin farklı veriler üzerine uygulanabilmesi için, benzer özelliklere sahip eğitim verilerine ihtiyaç duyulacaktır.

Gelecekte yapılacak çalışmalarda, farklı derin öğrenme modelleri kullanılarak, elde edilecek sonuçların performans kıyaslaması yapılabilecektir. Ayrıca, derin öğrenme modelinde kullanılan katman sayısı ve diğer hiper parametrelerin optimizasyonu çalışılarak; hem hesaplama doğruluğu hemde işlem hızı geliştirilebilir. Tezin ana amacından faydalanarak, farklı tekli görüntü üzerinde süper çözünürlük modelleri ile görüntü kaynaştırma modellerinin bir arada kullanıldığı modeller geliştirilebilecektir.



KAYNAKLAR

- [1] Schowengerdt, R. A. (2006). *Remote sensing: models and methods for image processing*. Elsevier.
- [2] Graham, S. (1999). *Remote Sensing: Introduction and History*. NASA. Retrieved July 23, 2021, from <https://earthobservatory.nasa.gov/features/RemoteSensing>
- [3] Campbell, J. B., & Wynne, R. H. (2011). *Introduction to remote sensing*. Guilford Press.
- [4] Goel, M., Patel, S. N., Whitmire, E., Mariakakis, A., Saponas, T. S., Joshi, N., Morris, D., Guenter, B., Gavriiliu, M., & Borriello, G. (2015). HyperCam. *Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing- UbiComp'15*. <https://doi.org/10.1145/2750858.2804282>
- [5] Briottet, X., Boucher, Y., Dimmeler, A., Malaplate, A., Cini, A., Diani, M., Bekman, H., Schwering, P., Skauli, T., Kasen, I., Renhorn, I., Klasén, L., Gilmore, M., & Oxford, D. (2006). Military applications of hyperspectral imagery. *Targets and Backgrounds XII: Characterization and Representation*. <https://doi.org/10.1117/12.672030>
- [6] Lu, G., & Fei, B. (2014). Medical hyperspectral imaging: a review. *Journal of biomedical optics*, 19(1), 010901.
- [7] Salgarello, M., Visconti, G., & Barone-Adesi, L. (2013). Interlocking circumareolar suture with undyed polyamide thread: a personal experience. *Aesthetic plastic surgery*, 37(5), 1061-1062.
- [8] Vajna, B., Patyi, G., Nagy, Z., Bódis, A., Farkas, A., & Marosi, G. (2011). Comparison of chemometric methods in the analysis of pharmaceuticals with hyperspectral Raman imaging. *Journal of Raman Spectroscopy*, 42(11), 1977-1986.
- [9] Adão, T., Hruška, J., Pádua, L., Bessa, J., Peres, E., Morais, R., & Sousa, J. J. (2017). Hyperspectral imaging: A review on UAV-based sensors, data processing and applications for agriculture and forestry. *Remote Sensing*, 9(11), 1110.
- [10] Kamruzzaman, M., & Sun, D. W. (2016). Introduction to hyperspectral imaging technology. In *Computer vision technology for food quality evaluation* (pp. 111-139). Academic Press.

- [11] Jensen, J. R. (2005). Introductory digital image processing—A remote sensing Perspective [M]. *Prentice Hall Series in Geographic Information Science*.
- [12] Toth, C., & Józków, G. (2016). Remote sensing platforms and sensors: A survey. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, 22-36.
- [13] Lulla, K., Nellis, M. D., & Rundquist, B. (2012). Celebrating 40 years of Landsat program's Earth observation accomplishments. *Geocarto International*, 27(6), 459-459.
- [14] Landsat NASA. (2021, December 3). *The Multispectral Scanner System / Landsat Science*. Landsat Science | A Joint NASA/USGS Earth Observation Program. Retrieved January 2, 2022, from <https://landsat.gsfc.nasa.gov/multispectral-scanner-system/>
- [15] Landsat NASA. (2021a, December 3). *Landsat 9 Spectral Specifications / Landsat Science*. Landsat Science | A Joint NASA/USGS Earth Observation Program. Retrieved January 2, 2022, from <https://landsat.gsfc.nasa.gov/satellites/landsat-9/landsat-9-instruments/landsat-9-spectral-specifications/>
- [16] Kerle, N., Janssen, L. L., & Huurneman, G. C. (2004). Principles of remote sensing. *ITC, Educational textbook series*, 2, 250.
- [17] Matese, A., Toscano, P., Di Gennaro, S. F., Genesio, L., Vaccari, F. P., Primicerio, J. & Gioli, B. (2015). Intercomparison of UAV, aircraft and satellite remote sensing platforms for precision viticulture. *Remote Sensing*, 7(3), 2971-2990.
- [18] Demattê, J. A., Ramirez-Lopez, L., Rizzo, R., Nanni, M. R., Fiorio, P. R., Fongaro, C. T. & Paulo, P. (2016). Remote sensing from ground to space platforms associated with terrain attributes as a hybrid strategy on the development of a pedological map. *Remote Sensing*, 8(10), 826.
- [19] Aggarwal, S. (2004). Principles of remote sensing. *Satellite remote sensing and GIS applications in agricultural meteorology*, 23, 23-28.
- [20] “Passive vs. Active Sensing,” Government of Canada, 2019. Accessed: Jun. 25, 2021. [Online]. Available: <https://www.nrcan.gc.ca/maps-tools-publications/satellite-imagery-air-photos/remote-sensing-tutorials/introduction/passive-vs-active-sensing/14639>
- [21] Tempfli, K., Huurneman, G., Bakker, W., Janssen, L. L., Feringa, W. F., Gieske, A. S. M. & Woldai, T. (2009). *Principles of remote sensing: an introductory textbook*. International Institute for Geo-Information Science and Earth Observation.

- [22] Gonzalez, R. C., & Woods, R. E. (2002). Digital image processing second edition. *Beijing: Publishing House of Electronics Industry*, 455.
- [23] Gibson, P. J., Power, C. H., & Keating, J. (2013). *Introductory remote sensing: Principles and concepts*. Routledge.
- [24] Liang, S., Li, X., & Wang, J. (2012). A systematic view of remote sensing. *Advanced remote sensing*, 1-31.
- [25] Irons, J. R., Markham, B. L., Nelson, R. F., Toll, D. L., Williams, D. L., Latty, R. S., & Stauffer, M. L. (1985). The effects of spatial resolution on the classification of Thematic Mapper data. *International Journal of Remote Sensing*, 6(8), 1385-1403.
- [26] Wilson, R. (2013). *Advanced remote sensing: terrestrial information extraction and applications*, by Shunlin Liang, Xiaowen Li and Jindi Wang: Oxford, Academic Press, 2012, 799 pp., £ 95 (hardback), ISBN 978-0-12-385954-9.
- [27] Théau J. (2008), “Temporal Resolution,” in *Encyclopedia of GIS*, S. Shekhar and H. Xiong, Eds. Boston, MA: Springer US, pp. 1150–1151. doi: 10.1007/978-0-387-35973-1_1376.
- [28] *Dalgalar ve Elektromanyetik Tayf (Spektrum)- Türkiye Uzay Ajansı*. (2021). TUA. Retrieved January 2, 2022, from <https://tua.gov.tr/tr/blog/havacilik-ve-teknoloji/dalgalar-ve-elektromanyetik-tayf-spektrum>
- [29] Ertürk, A. (2013). *Hiperspektral görüntüler için uzamsal yaklaşımlar*, Doktora Tezi, Kocaeli Üniversitesi
- [30] Shaw, G. A., & Burke, H. K. (2003). Spectral imaging for remote sensing. *Lincoln laboratory journal*, 14(1), 3-28.
- [31] Manolakis, D., Marden, D., & Shaw, G. A. (2003). Hyperspectral image processing for automatic target detection applications. *Lincoln laboratory journal*, 14(1), 79-116.
- [32] Keshava N. and Mustard J. F. (2002), “*Spectral unmixing*,” IEEE Signal Process. Mag., vol. 19, no. 1, pp. 44–57, doi: 10.1109/79.974727.
- [33] Rad, A. A., Meylan, L., Vandewalle, P., & Süsstrunk, S. (2007, February). Multidimensional image enhancement from a set of unregistered differently exposed images. In *Computational Imaging V* (Vol. 6498, p. 649808). International Society for Optics and Photonics.
- [34] Zhukov, B., Oertel, D., Lanzl, F., & Reinhackel, G. (1999). Unmixing-based multisensor multiresolution image fusion. *IEEE Transactions on Geoscience and Remote Sensing*, 37(3), 1212-1226.

- [35] R. B. Gomez, A. Jazaeri, and M. Kafatos, "Wavelet-based hyperspectral and multispectral image fusion," Orlando, FL, Jun. 2001, pp. 36–42. doi: 10.1117/12.428249.
- [36] Eismann, M. T., & Hardie, R. C. (2004). Application of the stochastic mixing model to hyperspectral resolution enhancement. *IEEE transactions on geoscience and remote sensing*, 42(9), 1924-1933.
- [37] Hardie, R. C., Eismann, M. T., & Wilson, G. L. (2004). MAP estimation for hyperspectral image resolution enhancement using an auxiliary sensor. *IEEE Transactions on Image Processing*, 13(9), 1174-1184.
- [38] Winter, M. E., Winter, E. M., Beaven, S. G., & Ratkowski, A. J. (2006, May). High-performance fusion of multispectral and hyperspectral data. In *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XII* (Vol. 6233, p. 62331R). International Society for Optics and Photonics.
- [39] Liao, W., Huang, X., van Coillie, F., Gautama, S., Pizurica, A., Philips, W., Liu, H., Zhu, T., Shimoni, M., Moser, G., & Tuia, D. (2015). Processing of Multiresolution Thermal Hyperspectral and Digital Color Data: Outcome of the 2014 IEEE GRSS Data Fusion Contest. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(6), 2984–2996. <https://doi.org/10.1109/jstars.2015.2420582>
- [40] Moeller, M., Wittman, T., & Bertozzi, A. L. (2009, April). A variational approach to hyperspectral image fusion. In *Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XV* (Vol. 7334, p. 73341E). International Society for Optics and Photonics.
- [41] Chen, Q., Shi, Z., & An, Z. (2014). Hyperspectral image fusion based on sparse constraint NMF. *Optik*, 125(2), 832-838.
- [42] Zhang, Y., De Backer, S., & Scheunders, P. (2008, July). Bayesian fusion of multispectral and hyperspectral image in wavelet domain. In *IGARSS 2008-2008 IEEE International Geoscience and Remote Sensing Symposium* (Vol. 5, pp. V-69). IEEE.
- [43] Zhang, Y., De Backer, S., & Scheunders, P. (2009). Noise-resistant wavelet-based Bayesian fusion of multispectral and hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 47(11), 3834-3843.
- [44] Wei, Q., Dobigeon, N., & Tournieret, J. Y. (2014, October). Bayesian fusion of multispectral and hyperspectral images with unknown sensor spectral response. In *2014 IEEE International Conference on Image Processing (ICIP)* (pp. 698-702). IEEE.

- [45] Palsson, F., Sveinsson, J. R., Ulfarsson, M. O., & Benediktsson, J. A. (2014). Model-based fusion of multi-and hyperspectral images using PCA and wavelets. *IEEE Transactions on Geoscience and Remote Sensing*, 53(5), 2652-2663.
- [46] Bendoumi, M. A., He, M., & Mei, S. (2014). Hyperspectral image resolution enhancement using high-resolution multispectral image based on spectral unmixing. *IEEE Transactions on Geoscience and Remote Sensing*, 52(10), 6574-6583.
- [47] Yokoya, N., Yairi, T., & Iwasaki, A. (2011). Coupled nonnegative matrix factorization unmixing for hyperspectral and multispectral data fusion. *IEEE Transactions on Geoscience and Remote Sensing*, 50(2), 528-537.
- [48] Bendoumi, M. A., He, M., Mei, S., & Zhang, Y. (2012, December). Unmixing approach for hyperspectral data resolution enhancement using high resolution multispectral image. In *2012 12th International Conference on Control Automation Robotics & Vision (ICARCV)* (pp. 1369-1373). IEEE.
- [49] Borsoi, R. A., Imbiriba, T., & Bermudez, J. C. M. (2019). Super-resolution for hyperspectral and multispectral image fusion accounting for seasonal spectral variability. *IEEE transactions on image processing*, 29, 116-127.
- [50] Li, S., Dian, R., Fang, L., & Bioucas-Dias, J. M. (2018). Fusing hyperspectral and multispectral images via coupled sparse tensor factorization. *IEEE Transactions on Image Processing*, 27(8), 4118-4130.
- [51] Zhang, K., Wang, M., Yang, S., & Jiao, L. (2018). Spatial-spectral-graph-regularized low-rank tensor decomposition for multispectral and hyperspectral image fusion. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(4), 1030-1040.
- [52] Wei, Q., Bioucas-Dias, J. M., Dobigeon, N., & Tourneret, J. Y. (2014, September). Fusion of multispectral and hyperspectral images based on sparse representation. In *2014 22nd European Signal Processing Conference (EUSIPCO)* (pp. 1577-1581). IEEE.
- [53] Huang, B., Song, H., Cui, H., Peng, J., & Xu, Z. (2013). Spatial and spectral image fusion using sparse matrix factorization. *IEEE Transactions on Geoscience and Remote Sensing*, 52(3), 1693-1704.
- [54] Akhtar, N., Shafait, F., & Mian, A. (2015). Bayesian sparse representation for hyperspectral image super resolution. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3631-3640).

- [55] Palsson, F., Sveinsson, J. R., & Ulfarsson, M. O. (2017). Multispectral and hyperspectral image fusion using a 3-D-convolutional neural network. *IEEE Geoscience and Remote Sensing Letters*, 14(5), 639-643.
- [56] Han, X. H., Shi, B., & Zheng, Y. (2018, October). SSF-CNN: Spatial and spectral fusion with CNN for hyperspectral image super-resolution. In *2018 25th IEEE International Conference on Image Processing (ICIP)* (pp. 2506-2510). IEEE.
- [57] Zhou, F., Hang, R., Liu, Q., & Yuan, X. (2019). Pyramid fully convolutional network for hyperspectral and multispectral image fusion. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(5), 1549-1558.
- [58] Han, X. H., & Chen, Y. W. (2019, September). Deep residual network of spectral and spatial fusion for hyperspectral image super-resolution. In *2019 IEEE Fifth International Conference on Multimedia Big Data (BigMM)* (pp. 266-270). IEEE.
- [59] Han, X., Yu, J., Luo, J., & Sun, W. (2019). Hyperspectral and multispectral image fusion using cluster-based multi-branch BP neural networks. *Remote Sensing*, 11(10), 1173.
- [60] Xu, Y., Wu, Z., Chanussot, J., Comon, P., & Wei, Z. (2019). Nonlocal coupled tensor CP decomposition for hyperspectral and multispectral image fusion. *IEEE Transactions on Geoscience and Remote Sensing*, 58(1), 348-362.
- [61] Wan, W., Guo, W., Huang, H., & Liu, J. (2020). Nonnegative and nonlocal sparse tensor factorization-based hyperspectral image super-resolution. *IEEE Transactions on Geoscience and Remote Sensing*, 58(12), 8384-8394.
- [62] Wei, W., Nie, J., Zhang, L., & Zhang, Y. (2020). Unsupervised Recurrent Hyperspectral Imagery Super-Resolution Using Pixel-Aware Refinement. *IEEE Transactions on Geoscience and Remote Sensing*.
- [63] Simsek, M., & Polat, E. (2021). Performance evaluation of pan-sharpening and dictionary learning methods for sparse representation of hyperspectral super-resolution. *Signal, Image and Video Processing*, 15(6), 1099-1106.
- [64] Vella, M., Zhang, B., Chen, W., & Mota, J. F. (2021, September). Enhanced Hyperspectral Image Super-Resolution via RGB Fusion and TV-TV Minimization. In *2021 IEEE International Conference on Image Processing (ICIP)* (pp. 3837-3841). IEEE.
- [65] Li, X., Zhang, Y., Ge, Z., Cao, G., Shi, H., & Fu, P. (2021). Adaptive Nonnegative Sparse Representation for Hyperspectral Image Super-Resolution. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 4267-4283.

- [66] Wang, X., Chen, J., Wei, Q., & Richard, C. (2021). Hyperspectral Image Super-Resolution via Deep Prior Regularization with Parameter Estimation. *IEEE Transactions on Circuits and Systems for Video Technology*.
- [67] Mianji, F. A., Gu, Y., Zhang, Y., & Zhang, J. (2011). Enhanced self-training superresolution mapping technique for hyperspectral imagery. *IEEE Geoscience and Remote Sensing Letters*, 8(4), 671-675.
- [68] He, S., Zhou, H., Wang, Y., Cao, W., & Han, Z. (2016, July). Super-resolution reconstruction of hyperspectral images via low rank tensor modeling and total variation regularization. In *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)* (pp. 6962-6965). IEEE.
- [69] Hu, J., Li, Y., & Xie, W. (2017). Hyperspectral image super-resolution by spectral difference learning and spatial error correction. *IEEE Geoscience and Remote Sensing Letters*, 14(10), 1825-1829.
- [70] Lei, S., Shi, Z., & Zou, Z. (2017). Super-resolution for remote sensing images via local-global combined network. *IEEE Geoscience and Remote Sensing Letters*, 14(8), 1243-1247.
- [71] Yuan, Y., Zheng, X., & Lu, X. (2017). Hyperspectral image superresolution by transfer learning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(5), 1963-1974.
- [72] Li, Y., Hu, J., Zhao, X., Xie, W., & Li, J. (2017). Hyperspectral image super-resolution using deep convolutional neural network. *Neurocomputing*, 266, 29-41.
- [73] Irmak, H., Akar, G. B., & Yuksel, S. E. (2018). A map-based approach for hyperspectral imagery super-resolution. *IEEE Transactions on Image Processing*, 27(6), 2942-2951.
- [74] Li, Y., Zhang, L., Dingl, C., Wei, W., & Zhang, Y. (2018, September). Single hyperspectral image super-resolution with grouped deep recursive residual network. In *2018 IEEE Fourth International Conference on Multimedia Big Data (BigMM)* (pp. 1-4). IEEE.
- [75] Jia, J., Ji, L., Zhao, Y., & Geng, X. (2018). Hyperspectral image super-resolution with spectral-spatial network. *International Journal of Remote Sensing*, 39(22), 7806-7829.
- [76] Zheng, K., Gao, L., Ran, Q., Cui, X., Zhang, B., Liao, W., & Jia, S. (2019). Separable-spectral convolution and inception network for hyperspectral image super-resolution. *International Journal of Machine Learning and Cybernetics*, 10(10), 2593-2607.

- [77] Xie, W., Jia, X., Li, Y., & Lei, J. (2019). Hyperspectral image super-resolution using deep feature matrix factorization. *IEEE Transactions on Geoscience and Remote Sensing*, 57(8), 6055-6067.
- [78] Wang, Q., Li, Q., & Li, X. (2020). Spatial-spectral residual network for hyperspectral image super-resolution. *arXiv preprint arXiv:2001.04609*.
- [79] Arun, P. V., Buddhiraju, K. M., Porwal, A., & Chanussot, J. (2020). CNN-based super-resolution of hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 58(9), 6106-6121.
- [80] Li, Q., Wang, Q., & Li, X. (2020). Mixed 2D/3D convolutional network for hyperspectral image super-resolution. *Remote Sensing*, 12(10), 1660.
- [81] Li, J., Cui, R., Li, B., Song, R., Li, Y., Dai, Y., & Du, Q. (2020). Hyperspectral image super-resolution by band attention through adversarial learning. *IEEE Transactions on Geoscience and Remote Sensing*, 58(6), 4304-4318.
- [82] Jiang, J., Sun, H., Liu, X., & Ma, J. (2020). Learning spatial-spectral prior for super-resolution of hyperspectral imagery. *IEEE Transactions on Computational Imaging*, 6, 1082-1096.
- [83] Hu, J., Jia, X., Li, Y., He, G., & Zhao, M. (2020). Hyperspectral image super-resolution via intrafusion network. *IEEE Transactions on Geoscience and Remote Sensing*, 58(10), 7459-7471.
- [84] Tang, Z., Xu, Q., Wu, P., Shi, Z., & Pan, B. (2022). Feedback Refined Local-Global Network for Super-Resolution of Hyperspectral Imagery. *Remote Sensing*, 14(8), 1944.
- [85] Li, Q., Wang, Q., & Li, X. (2021). Exploring the relationship between 2D/3D convolution for hyperspectral image super-resolution. *IEEE Transactions on Geoscience and Remote Sensing*, 59(10), 8693-8703.
- [86] Fu, Y., Liang, Z., & You, S. (2021). Bidirectional 3D Quasi-Recurrent Neural Network for Hyperspectral Image Super-Resolution. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 2674-2688.
- [87] Liu, D., Li, J., & Yuan, Q. (2021). A Spectral Grouping and Attention-Driven Residual Dense Network for Hyperspectral Image Super-Resolution. *IEEE Transactions on Geoscience and Remote Sensing*.
- [88] Wang, X., Ma, J., & Jiang, J. (2021). Hyperspectral Image Super-Resolution via Recurrent Feedback Embedding and Spatial-Spectral Consistency Regularization. *IEEE Transactions on Geoscience and Remote Sensing*.

- [89] Wang, Q., Li, Q., & Li, X. (2020). Hyperspectral image super-resolution using spectrum and feature context. *IEEE Transactions on Industrial Electronics*.
- [90] McCharty J (2007) What is artificial intelligence? Technical report, Computer Science Department, Stanford University
- [91] Burrell, J. (2016). How the machine ‘thinks’: Understanding opacity in machine learning algorithms. *Big Data & Society*, 3(1). <https://doi.org/10.1177/2053951715622512>
- [92] Hopfield, J. (1988). Artificial neural networks. *IEEE Circuits and Devices Magazine*, 4(5), 3–10. <https://doi.org/10.1109/101.8118>
- [93] Cunningham, P., Cord, M., & Delany, S. J. (2008). Supervised learning. In *Machine learning techniques for multimedia* (pp. 21-49). Springer, Berlin, Heidelberg.
- [94] Cord, M., & Cunningham, P. (Eds.). (2008). Machine Learning Techniques for Multimedia. *Cognitive Technologies*. <https://doi.org/10.1007/978-3-540-75171-7>
- [95] Bank, D., Koenigstein, N., & Giryes, R. (2020). Autoencoders. *arXiv preprint arXiv:2003.05991*.
- [96] Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017, August). Understanding of a convolutional neural network. *2017 International Conference on Engineering and Technology (ICET)*. <https://doi.org/10.1109/icengtechnol.2017.8308186>
- [97] Elad, M. (2010). *Sparse and Redundant Representations: From Theory to Applications in Signal and Image Processing (2010th ed.)*. Springer.
- [98] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778).
- [99] Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 4700-4708).
- [100] Barlow, H. (1989). Unsupervised Learning. *Neural Computation*, 1(3), 295–311. <https://doi.org/10.1162/neco.1989.1.3.295>
- [101] Bioucas-Dias, J. M., Plaza, A., Dobigeon, N., Parente, M., Du, Q., Gader, P., & Chanussot, J. (2012). Hyperspectral Unmixing Overview: Geometrical, Statistical, and Sparse Regression-Based Approaches. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2), 354–379. <https://doi.org/10.1109/jstars.2012.2194696>

- [102] Kruse, F., Lefkoff, A., Boardman, J., Heidebrecht, K., Shapiro, A., Barloon, P., & Goetz, A. (1993). The spectral image processing system (SIPS)—interactive visualization and analysis of imaging spectrometer data. *Remote Sensing of Environment*, 44(2–3), 145–163. [https://doi.org/10.1016/0034-4257\(93\)90013-n](https://doi.org/10.1016/0034-4257(93)90013-n)
- [103] Girouard, G., Bannari, A., El Harti, A., & Desrochers, A. (2004, July). Validated spectral angle mapper algorithm for geological mapping: comparative study between QuickBird and Landsat-TM. In *XXth ISPRS congress, geo-imagery bridging continents, Istanbul, Turkey* (Vol. 12, p. 23).
- [104] Dong, C., Loy, C. C., He, K., & Tang, X. (2015). Image super-resolution using deep convolutional networks. *IEEE transactions on pattern analysis and machine intelligence*, 38(2), 295-307.
- [105] Wen, R., Fu, K., Sun, H., Sun, X., & Wang, L. (2018). Image superresolution using densely connected residual networks. *IEEE Signal Processing Letters*, 25(10), 1565-1569.
- [106] Yasuma, F., Mitsunaga, T., Iso, D., & Nayar, S. K. (2010). Generalized assorted pixel camera: postcapture control of resolution, dynamic range, and spectrum. *IEEE transactions on image processing*, 19(9), 2241-2253.
- [107] Chakrabarti, A., & Zickler, T. (2011, June). Statistics of real-world hyperspectral images. In *CVPR 2011* (pp. 193-200). IEEE.

ÖZGEÇMİŞ

Adı Soyadı :HüseyinAYDİLEK :

Yabancı Dil : İngilizce

Eğitim Durumu

:

Lisans : Eskişehir Osmangazi Üniversitesi, Elektrik Elektronik Mühendisliği, 2012

Yüksek Lisans : Kırıkkale Üniversitesi Üniversitesi, Elektrik Elektronik Mühendisliği, 2015

Çalıştığı Kurum/Kurumlar ve Yıl/Yıllar:

Pozitif Akademi ve
Teknoloji

Yazılım Geliştirici ve
Eğitmen

Temmuz 2011-
Ağustos 2012

Kırıkkale Üniversitesi

Araştırma Görevlisi

Kasım 2012-Halen

Yayımları (SCI) :

Yayımları (Diğer) :

Aydilek, H. & İnanç, N. (2021). Learning Based Super Resolution Application for Hyperspectral Images. International Scientific and Vocational Studies Journal, 5 (2), 210-217. DOI: 10.47897/bilmes.1049338

Yalçınkaya, F., Aydilek, H., Erten M. Y., İnanç, N. (2020). IoT based Smart Home Testbed using MQTT Communication Protocol. International Journal of Engineering Research and Development, 12 (1), 317-324. DOI: 10.29137/umagd.654056

- Kılıçarslan, M., Ateş, V., Aydilek, H., Çam, E. (2018). Electrical Vehicles Charging Coordination by Fuzzy Logical System. *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi*, 10 (2), 53-59. DOI: 10.29137/umagd.426804
- Erten, M.Y., Aydilek, H., Çam, E., İnanç, N. (2018). Comparing Time Series Forecasting Methods to Estimate Wind Speed in Kırıkkale Region. *Technological Applied Sciences*, 13 (2), 98-107.
- Aydilek, H. & Polat, E., (2015). Image Processing Based Non-Metallic Inclusion Detection Framework with Extreme Value Distribution. *Third International Conference on Advances in Information Processing and Communication Technology - IPCT 2015*. <https://doi.org/10.15224/978-1-63248-077-4-16>

Yayınları (Diğer) :

- Erten M.Y., Aydilek H., İnanç N. (2018). Kısıtlı Cihazlar Üzerinde Nesnelerin İnterneti Haberleşme Protokolleri için Karşılaştırmalı Çalışma. II. International Scientific and Vocational Studies Congress (BILMES 2018)
- Erten M.Y., Aydilek H., İnanç N. (2018). IOT Tabanlı Haberleşme Verimli Yerel Ulaşım Sistemi Geliştirilmesi. II. International Scientific and Vocational Studies Congress (BILMES 2018)
- Sezgin S., Aydilek H., Erten M.Y., Çam E. (2017). Rüzgâr Yönü ve Şiddeti Hesaplanarak Rüzgâr Türbinleri için Otomatik Güvenli Uyarı Sisteminin Geliştirilmesi I. International Scientific and Vocational Studies Congress (BILMES 2017)
- Aydilek H., Erten M.Y., Çam E., İnanç N. (2017). Comparing Time Series Forecasting Methods to Estimate Wind Speed in Kırıkkale Region. I. International Scientific and Vocational Studies Congress (BILMES 2017)
- Aydilek H., Erten M.Y., İnanç N. (2017). Image Processing based Weather Prediction and Outdooractivity Decision Framework with Support Vector Machines. *International Conference on Advanced Technology Sciences (ICAT'17)*

Erten M.Y., Aydilek H., İnanç N. (2017). Wind Generation Estimation based on Weather Forecasting in Kırıkkale Turkey. International Conference on Advanced Technology Sciences (ICAT'17)

Erten M.Y., Aydilek H., İnanç N. (2017). Risk Assessment for Wind Turbines Based on Wind Speed Forecasting. CBU International Conference, 243-243.

Aydilek, H., & Polat, E. (2014, April). Automatic detection and classification of non metallic inclusions in steel via image processing. 2014 22nd Signal Processing and Communications Applications Conference (SIU). <https://doi.org/10.1109/siu.2014.6830412>

Projeler:

Bilimsel Araştırma Projeleri (BAP)- “Rüzgâr Türbini için Gerçek Zamanlı İzleme ve Güvenlik Sistemi Geliştirilmesi”, Yürütücü: Prof. Dr. Nihat İNANÇ, Yardımcı Araştırmacı, 2017, Kırıkkale.

Sanayi Tezleri Programı “Mühimmat güvenliği için çelik içerisindeki metal olmayan kalıntıların tespiti ve sınıflandırılması”, Bursiyer, 2016, Kırıkkale.