

**HİPERSPEKTRAL GÖRÜNTÜ VE LİDAR VERİSİNİN DERİN
ÖĞRENME İLE SINIFLANDIRILMASI**

**CLASSIFICATION OF HYPERSPECTRAL AND LIDAR DATA
WITH DEEP LEARNING**

HÜSEYİN EMRE MUTLU

YRD. DOÇ. DR. SENİHA ESEN YÜKSEL
Tez Danışmanı

Hacettepe Üniversitesi
Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin
Elektrik ve Elektronik Mühendisliği Anabilim Dalı için Öngördüğü
YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

2018

HÜSEYİN EMRE MUTLU tarafından hazırlanan “**Hiperspektral Görüntü ve Li-DAR Verisinin Derin Öğrenme ile Sınıflandırılması**” adlı bu çalışma, aşağıdaki jüri tarafından **Elektrik ve Elektronik Mühendisliği ANA BİLİM DALI’nda Yüksek Lisans Tezi** olarak kabul edilmiştir.

Prof. Dr. Atila YILMAZ

Başkan



Yrd. Doç. Dr. Seniha Esen YÜKSEL

Danışman



Prof. Dr. Gözde BOZDAĞI AKAR

Üye




Yrd. Doç. Dr. Mücahit Kani ÜNER

Üye



Yrd. Doç. Dr. Yakup Sabri ÖZKAZANÇ

Üye



Bu tez Hacettepe Üniversitesi Fen Bilimleri Enstitüsü tarafından **YÜKSEK LİSANS TEZİ** olarak onaylanmıştır.

Prof. Dr. Menemşe GÜMÜŞDERELİOĞLU

Fen Bilimleri Enstitüsü Müdürü

YAYINLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin/raporumun tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Hacettepe Üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

- ☒ **Tezimin/Raporumun tamamı dünya çapında erişime açılabilir ve bir kısmı veya tamamının fotokopisi alınabilir.**

(Bu seçenekle teziniz arama motorlarında indekslenebilecek, daha sonra tezinizin erişim statüsünün değiştirilmesini talep etseniz ve kütüphane bu talebinizi yerine getirirse bile, tezinin arama motorlarının önbelleklerinde kalmaya devam edebilecektir.)

- ☐ **Tezimin/Raporumun tarihine kadar erişime açılmasını ve fotokopi alınmasını (İç Kapak, Özet, İçindekiler ve Kaynakça hariç) istemiyorum.**

(Bu sürenin sonunda uzatma için başvuruda bulunmadığım takdirde, tezimin/raporumun tamamı her yerden erişime açılabilir, kaynak gösterilmek şartıyla bir kısmı ve ya tamamının fotokopisi alınabilir)

- ☐ **Tezimin/Raporumun tarihine kadar erişime açılmasını istemiyorum, ancak kaynak gösterilmek şartıyla bir kısmı veya tamamının fotokopisinin alınmasını onaylıyorum.**

- ☐ **Serbest Seçenek/Yazarın Seçimi**

03 / 01 / 2018



Hüseyin Emre MUTLU



Sevgili aileme,

ETİK

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmasında,

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversitede veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.



HÜSEYİN EMRE MUTLU

ÖZET

HİPERSPEKTRAL GÖRÜNTÜ VE LİDAR VERİSİNİN DERİN ÖĞRENME İLE SINIFLANDIRILMASI

Hüseyin Emre Mutlu

Yüksek Lisans, Elektrik ve Elektronik Mühendisliği Bölümü

Tez Danışmanı : Yrd. Doç. Dr. Seniha Esen YÜKSEL

Ocak 2018 , 68 sayfa

Uzaktan algılama teknolojisi, askeri ve sivil olmak üzere pek çok alanda etkin bir şekilde kullanılmaktadır. Bu teknoloji güvenlik alanında kullanıldığında, hassas ve güvenilir görüntüleme sistemlerine ihtiyaç duyulmaktadır. Gelişmiş algılayıcılar sayesinde, görüntülenen bölgenin nitelikleri hakkında oldukça ayrıntılı bilgi içeren veriler elde edilebilmektedir. Karmaşık ve doğrusal olmayan bir yapıya sahip olan bu zengin içerikli veriler ileri düzey makine öğrenmesi algoritmaları ile birleştirilince, bir insanın gözlemleyerek elde edeceği bilgiden çok daha fazlası, ayrıntılı ve hızlı bir şekilde çıkarılabilir.

Bu tez, farklı tipteki algılayıcılarla elde edilmiş hiperspektral görüntü (HSG) ve LiDAR verisinin birleştirilerek, bu verilerin görüntülediği bölgedeki yüzey materyallerinin yüksek isabet oranı ile sınıflandırılmasını hedeflemiştir. Bu hedef doğrultusunda, makine öğrenmesi alanındaki en güncel konu olan Derin Öğrenme'den faydalanılmıştır. Yapay sinir ağları ile kurulan çok katmanlı derin mimarilerin kullanıldığı Derin Öğrenme, son yıllarda uzaktan algılamada hedef tespiti ve sınıflandırma problemlerinin çözümünde ilk tercihlerden biri

haline gelmiştir. Kendi içinde çok geniş alt konular barındıran Derin Öğrenme, Evrimsel Sinir Ağı yapılarıyla bu tezdeki problemin asıl çözümü olmuştur. Yapılan deneylerde farklı sayıda katmandan oluşan sinir ağı modelleri test edilmiş ve sonuçlara göre modellerin parametreleri için en uygun değerler belirlenmiştir. Hiperspektral görüntü ve LiDAR verisi, eniyilenen modellerle sınıflandırılmış, sınıflandırma sonuçları, tezde önerilen birleştirme yöntemi ile birleştirilmiştir.

Tezde önerilen yöntemlerin başarısının ölçülmesi için Houston – ABD üzerinden alınan ve kentsel bölgeyi görüntüleyen bir veri kümesi kullanılmıştır. Bu veri kümesinin içerdiği çeşitli zorluklar nedeniyle bir takım ön işlemlere ve farklı tipte veriler bulunduğu için sınıflandırma sonrası işlemlere ihtiyaç duyulmuştur. Ön işlemlerden ilki, sınıflandırma sonucunda düşük isabet oranına sebep olan bulut gölgesinin etkisini azaltmak için geliştirilen gölge kestirimi ve düzeltme yöntemidir. Hiç bir işlem görmemiş HSG ile yapılan sınıflandırma sonucunda başarımlar %77.71 iken gölge düzeltildikten sonra bu başarımlar %81.49'a çıkmaktadır. Ayrıca bu aşamada elde edilen gölge haritası veri birleştirme aşamasında da kullanılmaktadır. Bir sonraki aşama olan gürültü filtrelemede *Yön Bağımlı Nüfuz Filtreleme (YBNF)* tercih edilmiştir. Görüntülenen bölgenin kentsel alan olması sebebiyle görüntüde keskin hatlar bulunmaktadır ve gürültü, YBNF sayesinde görüntüdeki keskin hatlar kaybedilmeden azaltılabilmektedir. Filtreleme işlemi sonucunda isabet oranı %83.56'ya çıkmaktadır. Ön işlemlerin sonuncusu olan *EMAP (Extended Morphological Attribute Profiles)* ise LiDAR verisinden uzamsal bilgileri çıkarmak için kullanılmıştır. Bu uzamsal bilgilerin sınıflandırılması sonucu elde edilen başarımlar %56.87 iken, sınıflandırma sonrası işlem olarak önerilen birleştirme yöntemi kullanılarak HSG ile birleştirildiğinde başarımlar %89.12'ye çıkmaktadır. Son olarak uygulanan *Çoğunluk Oylaması* ile düzenlileştirilen sınıflandırma sonucu %93.88'dir.

Anahtar Kelimeler: Hiperspektral Görüntü, LiDAR, Sınıflandırma, Derin Öğrenme, Evrimsel Sinir Ağı

ABSTRACT

CLASSIFICATION OF HYPERSPECTRAL AND LIDAR DATA WITH DEEP LEARNING

Hüseyin Emre Mutlu

M.S., Department of Electrical and Electronics Engineering

Supervisor : Assist. Prof. Dr. Seniha Esen YÜKSEL

January 2018, 68 pages

Remote sensing is a technology which has many military and civil applications. In applications for security, sensitive and reliable imaging systems are needed. Thanks to high end sensors, data obtained by these sensors contains detailed information about the attributes of the observed region. If this rich data which has a complex nonlinear structure is combined with advanced machine learning algorithms, far more information can be inferred compared to a human observer.

This thesis aims to classify surface materials over the region of interest with high accuracy by fusing hyperspectral image (HSI) and LiDAR data which are acquired by different types of sensors. To achieve this goal, Deep Learning, which is the most current topic of machine learning, is utilized. In recent years, Deep Learning, where deep network architectures that are constructed with multiple artificial neural layers, is the first option for the solution of classification and detection problems in remote sensing applications. Deep Learning has

many subtopics and the Convolutional Neural Network is the main solution of the problem in this thesis. In the experiments, neural network models with different number of layers are tested, and their parameters are optimized according to the test results. Hyperspectral image and LiDAR data are classified with optimized models, and the results are fused by the method proposed in this thesis.

For the evaluation of the performance of methods in this thesis, a dataset acquired over urban area in Houston – USA is used. Various preprocessing steps dealing with difficulties of dataset and postprocessing steps to fuse different type of data are needed. First of preprocessing steps is detection and correction of the effect of cloud shadow which degrades performance. Classification accuracy on unprocessed HSI is %77.71 and it increases to %81.49 after shadow correction. Also, the shadow map obtained in this step is used for fusion. In next step where the noise is filtered, *Anisotropic Diffusion Filter (ADF)* is preferred. Images include sharp edges since data was acquired over urban area and by ADF, edges are preserved while noise is filtered. After filtering, classification accuracy increases to %83.56. *EMAP (Extended Morphological Attribute Profiles)* technique, which is the last preprocessing task, is used to extract spatial features from LiDAR data. While the accuracy of classification of spatial features is %56.87, fusion method proposed as postprocessing in this thesis is used and accuracy is increased to %89.12. Finally, after applying *Majority Voting* for regularization, overall accuracy is %93.88.

Keywords: Hyperspectral Image, LiDAR, Classification, Deep Learning, Convolutional Neural Network

TEŞEKKÜR

İlk olarak araştırma ve çalışmalarına değerli görüşleri ile yön veren ve her konuda yardımcı olan tez danışmanım Yrd. Doç. Dr. Seniha Esen Yüksel'e,

Sağladıkları arkadaşlık ve yardımlaşma ortamından dolayı başta Sefa Küçük, Mevlüt Said Saraçoğlu ve Funda Cinyol olmak üzere tüm asistan arkadaşlarıma,

Zor zamanlarımda sağladıkları manevî destekleri ile motivasyonumu tazeleyerek yolumda ilerlememe yardımcı olan dostlarım Hazal Lezki'ye, Ezgi Harmandalı'ya, Duygu Çenet'e, kuzenim Alaaddin Yiğit Dincer'e ve çocukluk arkadaşım Başak Armağan'a,

Ve son olarak beni çok sevdiklerini, bana inandıklarını ve güvendiklerini bildiğim, her zaman yanımda olan canım aileme, annem Muhterem Mutlu, babam Ahmet Fuat Mutlu ve kardeşim Melike Mutlu'ya sonsuz teşekkürlerimi sunarım.

Bu tez TÜBİTAK tarafından 115E318 numaralı, *Hiperspektral Görüntüler ile LiDAR Verilerinin Kaynaştırılması* isimli proje kapsamında desteklenmiştir.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER	vi
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	xiii
SİMGELER VE KISALTMALAR	xiv
TÜRKÇE - İNGİLİZCE TERİMLER SÖZLÜĞÜ	xv
İNGİLİZCE - TÜRKÇE TERİMLER SÖZLÜĞÜ	xvi
1 GİRİŞ	1
1.1 Hiperspektral Görüntü (HSG)	2
1.2 LiDAR Verisi	3
1.3 Sınıflandırma	3
1.4 Tezin Amacı ve Yapılan Çalışmalar	4
1.4.1 Kullanılan Veri Kümesi	6
1.4.2 Derin Öğrenme Hakkında	9
1.5 Tezin Akışı	9
2 LİTERATÜR ÖZETİ	11

2.1	Derin Öğrenme ile Sınıflandırmada Yapılmış Çalışmalar	11
2.2	Kullanılan Veri Kümesi Üzerinde Yapılmış Çalışmalar	13
3	DERİN ÖĞRENME	15
3.1	Algılayıcı (Perceptron)	16
3.2	Çok Katmanlı Algılayıcı (Multi Layer Perceptron – MLP)	17
3.3	Evrişimsel Sinir Ağları (Convolutional Neural Networks)	19
3.4	Etkinleşme Fonksiyonları (Activation Functions)	20
3.5	Katman Düzgeleme (Layer Normalization)	23
3.6	SoftMax Regresyon	24
3.7	Çapraz Entropi, Eğim Düşümü ve Geri Yayılım Algoritması	24
4	ÖNERİLEN SINIFLANDIRMA YÖNTEMİ	26
4.1	Veri Kümesi Üzerinde Ön İşlemler	28
4.1.1	Eğitim Verisi Çoğaltma	28
4.1.2	Gölge Kestirimi ve Düzeltme	28
4.1.3	HSG’de YBNF ile Gürültü Azaltma	35
4.1.4	HSG’de Evrişim İşlemi ile Öznitelik Çıkarımı	36
4.1.5	LiDAR’da EMAP ile Uzamsal Bilgi Çıkarımı	37
4.2	Hiperspektral Veri Sınıflandırma için ESA	39
4.3	LiDAR Verisi Sınıflandırma için TBSA	39
4.4	Sınıflandırma Sonrası İşlemler	39
4.4.1	Karar Birleştirme Yöntemi	42
4.4.2	Çoğunluk Oylaması ile Düzenleştirme	44

5	DENEYLER	46
5.1	Deney Kurulumu	46
5.2	HSG Sınıflandırma Deneyleri	47
5.2.1	Gölge Düzeltmenin Etkisi	50
5.2.2	YBNF ile Gürültü Azaltmanın Etkisi	51
5.2.3	Katman Sayısının Etkisi	51
5.2.4	Çoğunluk Oylamasının HSG Sınıflandırmadaki Etkisi	52
5.3	LiDAR Sınıflandırma Deneyleri	53
5.3.1	Katman Sayısının Etkisi	53
5.3.2	Uzamsal Bilgi Çıkarma Yönteminin Etkisi	54
5.4	Karar Birleştirme Yönteminin Etkisi	55
5.5	Çoğunluk Oylamasının Etkisi	57
5.6	Karşılaştırmalar	58
6	SONUÇLAR	60
	KAYNAKLAR	63
	ÖZGEÇMİŞ	67

ŞEKİLLER LİSTESİ

ŞEKİLLER

- Şekil 1.1 Bütün işlemler tamamlandığında elde edilen sınıflandırma haritası. Her renk farklı bir sınıfı işaret etmektedir. Renklerin karşılık geldiği sınıfların bilgisi şekil 1.4c’de gösterilmiştir. 6
- Şekil 1.2 Elektromanyetik tayfın görünür ışık bölgesinden alınmış kırmızı, yeşil ve mavi ışık dalgaboyundaki reflektans verileri birleştirilince KYM görüntü oluşmaktadır. Bu üç reflektans verisi, HSG’deki 144 reflektans verisinden 3 tanesidir. 7
- Şekil 1.3 Veri kümesinin içerdiği LiDAR yükselti verisinden bir örnek. 8
- Şekil 1.4 Veri kümesi ile verilen etiketli verilerin, görüntülenen bölgedeki dağılımı gösterilmektedir. Verinin içerdiği 15 sınıf haritalarda farklı renklerle gösterilmiştir. Her rengin karşılık geldiği sınıfa ait bilgiler tablo 1.1’de verilmiştir. 16 numara, etiketi olmayan boşluk bölgeleri göstermektedir. 8
- Şekil 3.1 Derin evrişimsel mimariler, yapısal bilgilerden anlamsal bilgiler çıkarabilir. Evrişim katmanları ile çıkarılan öznitelikler, tam bağlantılı katmanların gerçekleştirdiği dönüşümler ile sınıflandırılır. 16
- Şekil 3.2 Şematik olarak algılayıcı. 17
- Şekil 3.3 XOR problemi doğrusal olmayan bir problemdir. Mavi daireleri turuncu olanlarından ayırabilen bir doğru yoktur. Dolayısıyla tek bir algılayıcı ile çözümlenemez. 18
- Şekil 3.4 XOR problemini çözümleyebilen ileri beslemeli ağ. 18
- Şekil 3.5 Çok katmanlı sinir ağları girdi uzayını bozarak farklı sınıflara ait verilerin bulunduğu bölgeleri doğrusal olarak ayrılabilir hale getirir [8]. 19

Şekil 3.6	Evrişim işlemini gösteren bir şema. Evrişim filtresinin ağırlıkları w , evrişimin girdisi x ve çıktısı da y ile gösterilmiştir.	21
Şekil 3.7	Sık kullanılan etkinleşme fonksiyonlarının grafikleri.	22
Şekil 4.1	Sınıflandırma yönteminin iş akışı şeması. Y (sarı) eğitim verisinin sınıf bilgisini, X (mavi) hyperspektral verisini, I (turuncu) LiDAR yansımaya parlaklığı verisini, Z (yeşil) LiDAR yükselti verisini temsil etmektedir. Siyah çerçeveli beyaz kutular, işlemlerin gerçekleştirildiği düğümlerdir. Beyaz fontlu gri kutular, önceki işlem kutusunun çıktısının bulunduğu veri düğümleridir.	27
Şekil 4.2	R matrisi üzerinden hesaplanan histogram. Gölgenin kestirimi için bulunan eşik değeri, histogram üzerinde kesikli çizgi ile gösterilmiştir. Kesikli çizginin sol tarafı gölge bölgede kalan pikselleri, sağ tarafı da aydınlık bölgedeki pikselleri temsil etmektedir.	31
Şekil 4.3	Gölge tespiti ve düzeltme işlemi aşamalarında elde edilen haritalar.	32
Şekil 4.4	Kestirilen zayıflama katsayılarının ($\alpha^{(d)}$) dalgaboyuna göre grafiği.	33
Şekil 4.5	Etiket bilgisi kullanmadan kestirilen zayıflama katsayılarının, etiketli verilerle elde edilen gerçek zayıflamayla katsayılarıyla kıyaslanması. Karşılaştırmalar sınıf bazında yapılmıştır. Kırmızı kesikli çizim, aydınlık bölgedeki test verileri ile gölge bölgedeki test verileri kıyaslanarak elde edilmiştir. Yeşil çizim, önerilen yöntemle hesaplanmış değerlerdir ve bütün grafiklerde aynıdır. Gölge bölgede 3, 5, 6, 12, 14 ve 15'inci sınıflara ait etiketli veri olmadığı için bu sınıflarda karşılaştırma yapılamamıştır.	34
Şekil 4.6	YBNF ile gürültü azaltmanın etkisi.	36
Şekil 4.7	EMAP üretiminde kullanılan yapısal elemanlar: Soldan sağa doğru karo, daire, kare ve çizgi.	38
Şekil 4.8	EMAP yöntemi ile elde edilen örnek sonuçlar.	38
Şekil 4.9	HSG sınıflandırma için önerilen ESA mimarisi.	40
Şekil 4.10	LiDAR sınıflandırma için önerilen TBBSA mimarisi.	41

Şekil 4.11 Çoğunluk oylamasını gösteren bir örnek.	44
Şekil 4.12 Çoğunluk oylamasını gösteren bir örnek. Yeşiller doğru, kırmızılar yanlış sınıflandırmayı göstermektedir.	45
Şekil 4.13 Doğru sınıfı <i>ticari alan</i> (yeşil) olan piksellerin büyük bir kısmı <i>park yeri</i> 2 (turuncu) sınıfı ile etiketlenmiş ve sınıflandırma sonucunda ticari alan etiketi alan az sayıdaki piksel de park yeri 2 etiketi ile etiketlenmiştir.	45
Şekil 5.1 Sabit öğrenme oranı ile isabet oranı ($\eta = 0.1$).	48
Şekil 5.2 Sabit öğrenme oranı ile kayıp fonksiyonu ($\eta = 0.1$).	48
Şekil 5.3 Uyarlı öğrenme oranı ile isabet oranı. Öğrenme oranı değişimleri, kesik çizgi ile gösterilen yinelemelerde gerçekleşmiştir.	49
Şekil 5.4 Uyarlı öğrenme oranı ile kayıp fonksiyonu. Öğrenme oranı değişimleri, kesik çizgi ile gösterilen yinelemelerde gerçekleşmiştir.	49
Şekil 5.5 Gölge düzeltme yönteminin etkileri. Yeşiller doğru, kırmızılar yanlış sınıflandırılan pikselleri göstermektedir.	50
Şekil 5.6 LiDAR sınıflandırma ortalama sonuçları: Çarpılar her bir deneyin sonucunu, kırmızı yuvarlaklar ve çizgiler de deneylerin ortalama başarısını göstermektedir.	54
Şekil 5.7 LiDAR sınıflandırmanın HSG ile birleştirme ortalama sonuçları: Çarpılar her bir deneyin sonucunu, kırmızı yuvarlaklar ve çizgiler de deneylerin ortalama başarısını göstermektedir.	55
Şekil 5.8 Karar birleştirme sonucu elde edilen doğru/yanlış haritası. Yeşil renk doğru sınıflandırmayı, kırmızı renk yanlış sınıflandırmayı göstermektedir. İncelenen bölgeler; soldan sağa doğru 1, 2 ve 3 numaralı bölge olarak ifade edilmiştir.	56
Şekil 5.9 İncelenen birinci bölgenin yakınlaştırılmış görüntüleri. HSG sınıflandırma sonucu (a) ile LiDAR sınıflandırma sonucunun (b) birleştirilmesi sonucunda c'de gösterilen sınıflandırma elde edilmiştir. (Yeşil: doğru, Kırmızı: yanlış)	56

Şekil 5.10 İncelenen ikinci bölgenin yakınlaştırılmış görüntüleri. HSG sınıflandırma sonucu (a) ile LiDAR sınıflandırma sonucunun (b) birleştirilmesi sonucunda c’de gösterilen sınıflandırma elde edilmiştir. (Yeşil: doğru, Kırmızı: yanlış) 57

Şekil 5.11 İncelenen üçüncü bölgenin yakınlaştırılmış görüntüleri. HSG sınıflandırma sonucu (a) ile LiDAR sınıflandırma sonucunun (b) birleştirilmesi sonucunda c’de gösterilen sınıflandırma elde edilmiştir. (Yeşil: doğru, Kırmızı: yanlış) 57



TABLÖLER LİSTESİ

TABLÖLER

Tablo 1.1	Eğitim ve test için etiketlenen piksel sayıları.	6
Tablo 5.1	YBNF'nin gölge düzeltmeli ve düzeltmesiz kullanımlarının sonuçları. . .	51
Tablo 5.2	Derin mimaride bulunan ESA ve TBSA katmanlarının sayısına göre ortalama isabet oranları.	52
Tablo 5.3	LiDAR sınıflandırmada TBSA katman sayısına göre ortalama isabet oranları.	53
Tablo 5.4	Sınıflandırma sonuçlarının rakip yöntemlerle karşılaştırılması.	58
Tablo 5.5	Karışıklık matrisi: Tüm haritada sınıflandırma sonucu. Değerler yüzde cinsindendir.	59
Tablo 5.6	Karışıklık matrisi: Aydınlık bölgede sınıflandırma sonucu. Değerler yüzde cinsindendir.	59
Tablo 5.7	Karışıklık matrisi: Gölge bölgede sınıflandırma sonucu. Değerler yüzde cinsindendir.	59

SİMGELER VE KISALTMALAR

Simgeler

N	Piksel Sayısı
D	Spektral bant sayısı
$\mathbf{X}$	Hiperspektral veri matrisi ($D \times N$)
$\mathbf{X}^{(d)}$	Hiperspektral görüntünün d 'inci bandı ($1 \times N$)
$\mathbf{x}_n$	n 'inci piksele ait spektral vektör ($D \times 1$)
$x_{n,d}$	n 'inci pikselin d 'inci spektral banttaki değeri
$\mathbf{Z}$	LiDAR yükselti verisi matrisi ($1 \times N$)
z_n	n 'inci piksele ait LiDAR yükseklik değeri
$\mathbf{z}_n$	n 'inci piksele ait EMAP vektörü
$\mathbf{I}$	LiDAR yansımaya parlaklık verisi matrisi ($1 \times N$)
i_n	n 'inci piksele ait LiDAR yansımaya parlaklık değeri
$\mathbf{Y}$	Etiket bilgisi matrisi ($1 \times N$)
y_n	n 'inci piksele ait etiket bilgisi
$\mathbf{G}$	Gölge bilgisi matrisi ($1 \times N$)
g_n	n 'inci piksele ait gölge bilgisi

Kısaltmalar

EMAP	Extended Morphological Attribute Profiles (Genişletilmiş Biçimsel Özellik Profilleri)
ESA	Evrişimsel Sinir Ağı
HSG	Hiperspektral Görüntü
KYM	Kırmızı-Yeşil-Mavi
LiDAR	Light Detection and Ranging (Işık ile Algılama ve Menzil Tayini)
TBSA	Tam Bağlantılı Sinir Ağı
YBNF	Yön Bağımlı Nüfuz Filtreleme
YSA	Yapay Sinir Ağı

TÜRKÇE - İNGİLİZCE TERİMLER SÖZLÜĞÜ

Atlama	: Stride
Başarım	: Performance
Birleşik Karar Dağılımı	: Joint Decision Distribution
Birleştirme	: Fusion
Çapraz Entropi	: Cross Entropy
Çoğunluk Oylaması	: Majority Voting
Çok Katmanlı Algılayıcı	: Multi Layer Perceptron
Dalgaboyu	: Wavelength
Değişinti	: Variance
Derin Öğrenme	: Deep Learning
Destek Vektör Makinesi	: Support Vector Machine
Doğrusal Ayrılabilir	: Linearly Separable
Doğrusal Olmayan Dönüşüm	: Nonlinear Transform
Düzenleştirme	: Regularization
Düzgeleme	: Normalization
Eğim Düşümü	: Gradient Descent
Eniyileme	: Optimization
Etkinleşme Fonksiyonu	: Activation Function
Evrişim	: Convolution
Geçerleme	: Validation
Geri Yayılım	: Back Propagation
Gizli Katman	: Hidden Layer
Gölge Düzeltme	: Shadow Correction
Gölge Tespiti	: Shadow Detection
Gözetimli Öğrenme	: Supervised Learning
Gürültü Azaltma	: Denoising
Güvenirlik Katsayısı	: Confidence Coefficient

Hiperspektral Görüntü	: Hyperspectral Image
İleri Beslemeli Ağ	: Feed Forward Network
İlinti	: Correlation
İsabet	: Accuracy
Kayıp	: Loss
Kırmızı-Yeşil-Mavi	: Red-Green-Blue
Makine Öğrenmesi	: Machine Learning
Matematiksel Biçimbilim	: Mathematical Morphology
Ortalama	: Mean
Ön İşlem	: Preprocessing
Öznitelik Çıkarımı	: Feature Extraction
Öznitelik Haritası	: Feature Map
Parlaklık	: Intensity
Sayısal Yükselti Modeli	: Digital Elevation Model
Sınıflandırma	: Classification
Tam Bağlantılı Ağ	: Fully Connected Network
Uyarlamalı Öğrenme Oranı	: Adaptive Learning Rate
Uzaktan Algılama	: Remote Sensing
Uzamsal Bilgi Çıkarımı	: Spatial Information Extraction
Veri Çoğaltma	: Data Augmentation
Veri Kümesi	: Dataset
Yapay Sinir Ağı	: Artificial Neural Network
Yapısal Eleman	: Structuring Element
Yineleme	: Iteration
Yön Bağımlı Nüfuz Filtre	: Anisotropic Diffusion Filter
Zayıflama Katsayısı	: Attenuation Coefficient

İNGİLİZCE - TÜRKÇE TERİMLER SÖZLÜĞÜ

Accuracy	: İsalet
Activation Function	: Etkinleşme Fonksiyonu
Adaptive Learning Rate	: Uyarlamalı Öğrenme Oranı
Anisotropic Diffusion Filter	: Yön Bağımlı Nüfuz Filtre
Artificial Neural Network	: Yapay Sinir Ağı
Attenuation Coefficient	: Zayıflama Katsayısı
Back Propagation	: Geri Yayılım
Classification	: Sınıflandırma
Confidence Coefficient	: Güvenirlik Katsayısı
Convolution	: Evrişim
Correlation	: İlinti
Cross Entropy	: Çapraz Entropi
Data Augmentation	: Veri Çoğaltma
Dataset	: Veri Kümesi
Deep Learning	: Derin Öğrenme
Denoising	: Gürültü Azaltma
Digital Elevation Model	: Sayısal Yükselti Modeli
Feature Extraction	: Öznelik Çıkarımı
Feature Map	: Öznelik Haritası
Feed Forward Network	: İleri Beslemeli Ağ
Fully Connected Network	: Tam Bağlantılı Ağ
Fusion	: Birleştirme
Gradient Descent	: Eğim Düşümü
Hidden Layer	: Gizli Katman
Hyperspectral Image	: Hiperpektral Görüntü
Intensity	: Parlaklık
Iteration	: Yineleme

Joint Decision Distribution	: Birleşik Karar Dağılımı
Linearly Separable	: Doğrusal Ayrılabilir
Loss	: Kayıp
Machine Learning	: Makine Öğrenmesi
Majority Voting	: Çoğunluk Oylaması
Mathematical Morphology	: Matematiksel Biçimbilim
Mean	: Ortalama
Multi Layer Perceptron	: Çok Katmanlı Algılayıcı
Nonlinear Transform	: Doğrusal Olmayan Dönüşüm
Normalization	: Düzgeleme
Optimization	: Eniyileme
Performance	: Başarım
Preprocessing	: Ön İşlem
Red-Green-Blue	: Kırmızı-Yeşil-Mavi
Regularization	: Düzenlileştirme
Remote Sensing	: Uzaktan Algılama
Shadow Correction	: Gölge Düzeltme
Shadow Detection	: Gölge Tespiti
Spatial Information Extraction	: Uzamsal Bilgi Çıkarımı
Stride	: Atlama
Structuring Element	: Yapısal Eleman
Supervised Learning	: Gözetimli Öğrenme
Support Vector Machine	: Destek Vektör Makinesi
Validation	: Geçerleme
Variance	: Değişinti
Wavelength	: Dalgaboyu

1. GİRİŞ

Günümüzde teknolojinin ulaştığı seviye ve bu teknolojinin sağladığı imkanlarla elde edilen medeniyet, insanoğlunun en güçlü özelliklerinden birisi olan merak duygusu sayesinde. Çağlar boyunca merakının peşinde sürüklenen insan, yaptığı gözlemler ile elde ettiği bilgiyi kullanarak, fayda sağlayacak araçlar ve yöntemler üretmiş ve geliştirmiştir. Bu üretme ve geliştirme sürecinde, merak duygusunun tetiklediği bir sonraki adım olan gözlem yapmaya her zaman ihtiyaç duymuştur. Gözlemler neticesinde edinilen bilgi arttıkça, evren ve yaşam hakkında daha fazla bilgi sahibi olan insanoğlu, artık doğrudan gözlemleyemediği varlıkları ve olguları merak etmeye başlamış ve bu merakı tatmin etmeye yönelik girişimlerde bulunmuştur. Bu girişimlerin sonucunda, günümüzde var olan üstün gözlem teknikleri sayesinde çeşitli alanlarda ve uygulamalarda çok miktarda ve detaylı veriler elde edilmektedir. Söz konusu ileri gözlem tekniklerinden iki tanesi olan *Hiperspektral Görüntüleme (HSG)* ve *LiDAR - Light Detection and Ranging (Işık ile Algılama ve Menzil Tayini)*, bu tezde kullanılacak olan veri kümesinin kaynak teknolojisidir. Hiperspektral görüntülerle ilgili detaylı bilgi bölüm 1.1’de, LiDAR verisiyle ilgili detaylı bilgi ise bölüm 1.2’de, ayrıca tezde kullanılan ve bu iki veri tipini içeren veri kümesi hakkındaki bilgi bölüm 1.4.1’de verilecektir.

Yapay zeka, antik çağdan beri insanlığın hayalini kurduğu bir olgu iken, günümüzde basit anlamda hayatta etkisini göstermeye başlamıştır. Transistörün icadıyla birlikte 20. yüzyılın birinci yarısında araştırılmaya başlanmış olan yapay zekanın basit ilkeleri bugün olgunluk kazanmış, ve bilgisayar teknolojisinin sağladığı hesaplama ve veri saklama hacmi sayesinde günlük hayatta kullanılabilir hâle gelmiştir. Yapay zekanın temel parçalarından birisi olan öğrenme ve öğrenilen bilgiye göre sınıflandırma işinde gelinen son nokta *Derin Öğrenme (Deep Learning)*’dir. Temelde, veriyi sınıflandırma ve bazen bu sınıflandırma sonucuna göre yeni bir bilgi ya da eylem üretme amacıyla kullanılan derin öğrenme, bölüm 1.4.2’de kısaca tanımlanacak, bölüm 3’te ise derin öğrenmenin bu tezde kullanılan unsurları detaylı bir şekilde anlatılacaktır.

1.1 Hiperspektral Görüntü (HSG)

Görme olgusu, akla ilk gelen anlamıyla, dalgaboyu $400nm - 700nm$ aralığında olan elektromanyetik dalgaların, gözün retina tabakasında oluşturduğu elektrokimyasal değişimlerin, beyin oksipital lobunda anlamlandırılması ile gerçekleşir. Elektromanyetik ışınların retina-daki etkisinin beyinde kazandığı bu anlama *görüntü* denmiştir. Görme, bulunulan ortamla etkileşime girme konusunda insanın en önemli yardımcısıdır.

Daha önce bahsedildiği üzere, merak duygusu üzerine yapılan gözlemler genellikle görerek yapılır. İnsan gözünün görme yetisi elektromanyetik tayfin $400nm - 700nm$ dalga boyu aralığıyla sınırlı iken, daha fazlasını görebilme merakı sayesinde, bu aralığın dışında kalan elektromanyetik ışınların gözlemlenmesi için çeşitli teknolojiler geliştirilmiştir. Hiperspektral görüntüleme, söz konusu teknolojilerden bir tanesidir ve bu teknoloji ile elektromanyetik tayfin, görünür ışık bölgesiyle birlikte, insan gözünün göremediği kızılötesi tayfin da bir bölümünü kapsayan geniş bir banttan (ortalama $0.7\mu m - 2.0\mu m$, görüntülemede kullanılan algılayıcının tipine göre daha dar ya da daha geniş), çok sayıda görüntü alınabilmektedir. HSG'ler, görüntülenen varlık hakkında, insan gözünün görebildiği kırmızı, yeşil ve mavi (KYM) görüntülerden çok daha fazla ve ayrıntılı bilgi sağlayabilmektedir.

Hiperspektral görüntüleme, oldukça geniş bir kullanım alanına sahiptir. Madencilik ve jeolojide kullanılması için geliştirilen bu teknolojinin diğer sivil ve askerî uygulamalardan başlıcalarını saymak gerekirse; gıda işleme, kimya, astronomi, tarım ve ormancılık, çevre gözlemi, güvenlik denetimi, güvenlik denetimi, hedef ve patlayıcı tespiti şeklinde sıralanabilir.

Pasif bir görüntüleme tekniği olan hiperspektral görüntüleme, harici bir aydınlatma kaynağıyla aydınlatılan nesnelerin görüntüsünü almaktadır. Dolayısıyla havadan alınan HSG'lerde aydınlatma kaynağı güneştir. Güneş, elektromanyetik tayfin hiperspektral görüntülemede ihtiyaç duyulan bantlarında oldukça güçlü bir aydınlatma sağlamaktadır. Ancak görüntünün havadan alınmasının bazı olumsuzlukları vardır. Görüntülemenin yapıldığı yere ve zamana bağlı olarak değişiklik gösteren atmosferik koşullar, elektromanyetik tayfin farklı bantlarını farklı şekilde etkilemekte ve görüntüleme sonucunda elde edilen verinin niteliğini düşürebilmektedir.

1.2 LiDAR Verisi

Aktif bir görüntüleme tekniği olan LiDAR, görüntülenmek istenen bölgeye ışık atımları gönderip alınan yansımalar üzerinden ölçüm yaparak veri toplamaktadır. Işık kaynağı olarak *lazer (LASER - Light Amplification by Stimulated Emission of Radiation)* kullanan bu sistem *LADAR (LASER Detection And Ranging)* olarak da anılmaktadır. Sistemin kaynağından çıkan bir ışının, hedeften yansayıp sensöre geliş süresini ölçen bu sistem, ölçtüğü bu bilgi ile hedefin uzaklığını kestirmektedir. Çalışma prensibi ve amacıyla benzerlik gösterdiği *radar (RADAR - Radio Detection And Ranging)*'dan farkı, kullandığı kaynaktır. Bu farkın etkisi, radar ve LiDARın menzilinde kendisini göstermektedir. Lazerin dalga boyu radarlarda kullanılan radyo dalgalarından çok daha kısa olduğu için LiDARın menzili daha düşük fakat hassasiyeti yüksektir.

LiDAR, 1960'lerde lazerin icadından kısa bir süre sonra ortaya çıkmış ve meteorolojide, bulutlarla ölçümler yapmak için kullanılmıştır. Bugün hiperspektral görüntüleme gibi oldukça geniş kullanım alanı bulan LiDAR; tarım ve ormancılık, arkeoloji, jeodezi, madencilik, astronomi ve askerî amaçlı uygulamalarda faydalanan bir teknolojidir. En güncel uygulama alanları ise otonom araçlar, robotik ve video oyunları olarak örneklendirilebilir.

Yeryüzü şekillerini haritalamak için kullanılan LiDAR, hava araçlarına monte edilerek *Sayısal Yükselti Modeli (Digital Elevation Model - DEM)* denen veriler elde etmektedir. Bu veriler sayesinde, görüntülenen bölgenin fiziksel yapısı 3 boyutlu olarak incelenebilmektedir. Sistemde kullanılan lazer, kullanım amacına ve görüntülenecek bölgenin özelliklerine göre değişiklik göstermektedir. Örneğin; su kütlelerinin içine sızarak bir gölün tabanını modellemek gerekirse, $5.32\mu m$ dalga boyundaki lazer kullanılmaktadır. Atmosferik koşulların etkisinin azalması ve görüntülenen bölgedeki bitki örtüsünün görüntülenmesinde hassasiyet istenirse, kullanılacak lazerin dalgaboyu $1.64\mu m$ olmaktadır [1].

1.3 Sınıflandırma

İstatistik biliminin ve makine öğrenmesinin çözmeyi amaçladığı problemlerden birisi olan sınıflandırma; yeni bir gözlemin, eski gözlemlerden *öğrenilmiş* bir kurala göre, eski gözlemlerle oluşturulan sınıflardan birisine atanması problemidir. Bu tanımdan anlaşılacağı üzere

bu problemin çözümü, *öğrenme* gerektirmektedir. Bu tezde öğrenme kavramı, etiketi bilinen (haricen verilmiş) gözlemler üzerinden, sınıflandırma işleminde kullanılacak kuralların çıkarılması işidir. Etiketi bilinen gözlemler kullanılarak (bir öğretici ile) yapılan bu tip öğrenmeye *gözetimli öğrenme* (*supervised learning*) denmektedir [2].

Gelişen teknolojiyle birlikte, veri toplayan sensörler sayısı ve çeşit olarak artmış, sonuç olarak bu sensörlerin ürettiği verinin insan eliyle analizi imkansız hale gelmiştir. Hesap yapma konusunda insandan milyarlarca kat hızlı olan bilgisayarlar ise bu *büyük verinin* (*big data*) analizini oldukça kolay hâle getirmektedir. Hatta veri arttıkça, veri hakkında yapılan istatistiksel kestirimler daha tutarlı hâle gelmekte ve bu da bilgisayarların işini daha da kolaylaştırmaktadır [3].

1.4 Tezin Amacı ve Yapılan Çalışmalar

Uzaktan algılama çalışmalarında sınıflandırma, en önemli problemlerden birisidir. Yeryüzünün hava araçlarından alınan görüntüleri, bölüm 1.1 ve 1.2’de bahsi geçen uygulama alanlarının çoğunda sınıflandırma amaçlı kullanılmaktadır. Görüntüde bulunan cisimlerin bir kısmı, uygulamanın türüne bağlı olarak hedef teşkil etmektedir. Bu hedeflerin türü, sayısı ve çeşitli niteliklerinin belirlenmesi işi, uzaktan algılamada sınıflandırma probleminin amacını oluşturmaktadır. Alınan bir görüntüde, sınıflandırılması gereken bölgelerin genişliği, ya da söz konusu bölgeyi oluşturan piksellerin sayıca fazla olması, sınıflandırma işinin insan eliyle yapılmasını imkansız hale getirmektedir. Bu işi bilgisayarlara yaptırmak alternatifi olmayan bir seçenektir.

HSG ve LiDAR verilerinin sınıflandırılmasında çeşitli zorluklar bulunmaktadır. HSG’nin spektral olarak yüksek çözünürlüğe sahip olması bir avantaj gibi görünmekte; fakat düşük uzamsal çözünürlük, verinin yüksek boyutluluğu ve artık bilgi içermesi, etiketlenmiş eğitim ve test verisi miktarındaki dengesizlik gibi sebeplerden dolayı sınıflandırma işi zorlaşmaktadır [4]. HSG’lerin atmosferik koşullara duyarlı olması ise yerine göre problemi çözümsüz hale getirebilmektedir. LiDAR verisi ise, görüntülenen bölgenin sadece yükselti bilgisini sağlamaktadır. Yükselti bilgisi, aynı yükseklikte bulunan farklı sınıflara ait bölgelerin ayırt edilmesi için yetersiz kalmaktadır. LiDAR verisinin içerdiği yansıma yoğunluğu verisi de tek bantlı olduğu ve kullanılan lazerin türüne göre değişiklik gösterdiği için, yükselti veri-

sinin yetersizliğini telafi edememektedir. HSG ve LiDAR verisi birlikte kullanıldığında ise, birbirini tamamlayarak, kaliteli ve zengin içerikli bir veri kümesi haline gelmektedir. Bu tezde kullanılan veri kümesi, bahsedilen bu özellikleri barındırmaktadır ve bölüm 1.4.1’de detaylı bir şekilde tanıtılacaktır.

Tezin amacı; HSG ve LiDAR verilerini, yüksek bir isabet oranıyla, birlikte sınıflandırmaktır. Bu amaca ulaşmak için iki alt amaç ise; sınıflandırma için etkin sınıflandırıcılar geliştirilmek, sınıflandırma sonuçlarını iyileştirilmesi için HSG ve LiDAR verisini birleştiren bir strateji geliştirilmek şeklinde sıralanabilir. Asıl amaç olan yüksek isabet oranıyla sınıflandırma görevinin başarı ölçütü, aynı veri kümesi üzerinde yapılmış rakip yöntemleri geçebilmektir. Rakip yöntemlerden daha iyi sonuçlar elde edilmesi, iyi sınıflandırıcılar ve iyi bir birleştirme stratejisi geliştirildiğinin göstergesi olacaktır.

Yapay sinir ağları, literatürde bilinen en etkin ve güncel sınıflandırıcılardır. HSG’lerin *evrimsel sinir ağları* (ESA) ile sınıflandırılması, çalışmaların ilk ayağını oluşturmaktadır. Çok katmanlı (*derin*) sinir ağı mimarilerinin kullanıldığı HSG sınıflandırma deneylerinde, değişik sayılarda katmanlarla deneyler yapılmış ve katman parametrelerinin (katmandaki nöron sayısı, evrişim filtresi boyu ve sayısı, ağırlıkların başlangıç değeri vb.) en uygun değerleri deneysel olarak bulunmaya çalışılmıştır. İstenen başarının elde edilememesi üzerine, başarıyı olumsuz etkileyen sebepler araştırılmış; HSG’nin içerdiği gürültünün ve şekil 1.2’deki görüntülerde seçilebilen bulut gölgesinin, sınıflandırma sonuçlarındaki düşük isabet oranının en önemli sebepleri olduğu anlaşılmıştır. Bunun üzerine; HSG’deki gölgenin tespiti ve düzeltilmesi için kısa bir araştırmadan sonra bir yöntem geliştirilmiş ve olumlu sonuçlar alınmıştır. Verinin içerdiği gürültünün azaltılması için de farklı filtreler denenmiş ve *yön bağımlı nüfuz filtre* (YBNF) kullanımında karar kılınmıştır. LiDAR verisinin sınıflandırılması için öznitelik çıkarma işlemine ihtiyaç duyulmuştur. LiDAR verisinin sağladığı topoğrafya bilgisinin, sınıflandırma için faydalı uzamsal bilgiler sağlayabileceği düşünülmüş ve bu bilgilerin çıkarılması amacıyla *matematiksel biçim* (*mathematical morphology*) algoritmaları kullanılmıştır. Biçimsel algoritmaların kullanımı sonucu elde edilen verinin seyrek yapısı nedeniyle sınıflandırıcı olarak *tam bağlantılı sinir ağı* (*fully connected neural network*) kullanılması uygun görülmüştür. Sınıflandırma işleminden sonra sınıflandırma sonuçlarının birleştirilmesi ve düzenlenmesi görevleri yerine getirilmiştir. Nihai sonuçlar elde edildikten sonra sınıflandırma başarımları rakip çalışmalarla karşılaştırılmıştır. Bu tezde elde edilen en iyi sınıflandırma sonucuna ait harita, şekil 1.1’de gösterilmiştir.



Şekil 1.1: Bütün işlemler tamamlandığında elde edilen sınıflandırma haritası. Her renk farklı bir sınıfı işaret etmektedir. Renklerin karşılık geldiği sınıfların bilgisi şekil 1.4c’de gösterilmiştir.


1.4.1 Kullanılan Veri Kümesi

IEEE GRSS ¹ tarafından düzenlenen veri birleştirme yarışmaları kapsamında 2013 yılında yayınlanan veri kümesi, Houston üniversitesi (A.B.D.) üzerinden alınmış HSG ve LiDAR verisi içermektedir [5]. HSG, 380 – 1050nm dalgaboyu aralığında 144 banttan alınmıştır ve 2.5m uzamsal çözünürlüğe sahiptir. Bu görüntünün görünür ışık bandını kapsayan kısmından örnek bir kesit, şekil 1.2’de gösterilmiştir. LiDAR verisi, yükselti bilgisinin yanı sıra yansıma parlaklığı bilgisi de içermektedir ve verinin yoğunluğu, bir HSG pikseli başına ortalama 12 LiDAR noktasıdır. Şekil 1.3’te LiDAR verisinden alınmış örnek bir yükselti haritası gösterilmiştir. Görüntülenen bölgede toplam 15 farklı sınıf seçilmiş ve bu sınıflara ait pikseller eğitim ve test için ayrılmıştır. Eğitim ve test piksellerinin; sayılarının sınıflara göre dağılımı tablo 1.1’de, görüntülenen bölgedeki konumsal dağılımı ise şekil 1.4’te verilmiştir.


Tablo 1.1: Eğitim ve test için etiketlenen piksel sayıları.

#	Sınıf	Eğitim	Test
1	Sağlıklı Çimen	198	1053
2	Ezilmiş Çimen	190	1064
3	Yapay Çimen	192	505
4	Ağaç	188	1056
5	Toprak	186	1056
6	Su	182	143
7	Konut	196	1072
8	Ticari Bölge	191	1053
9	Asfalt Yol	193	1059
10	Otoban	191	1036
11	Tren Yolu	181	1054
12	Otopark-1	192	1041
13	Otopark-2	184	285
14	Tenis Kortu	181	247
15	Koşu Yolu	187	473


¹ Institute of Electrical and Electronics Engineers Geoscience and Remote Sensing Society




Şekil 1.2: Elektromanyetik tayfın görünür ışık bölgesinden alınmış kırmızı, yeşil ve mavi ışık dalgaboyundaki reflektans verileri birleştirilince KYM görüntü oluşmaktadır. Bu üç reflektans verisi, HSG'deki 144 reflektans verisinden 3 tanesidir.




Şekil 1.3: Veri kümesinin içerdiği LiDAR yükselti verisinden bir örnek.



(a) Eğitim verileri.



(b) Test verileri.



(c) Renk göstergesi.

Şekil 1.4: Veri kümesi ile verilen etiketli verilerin, görüntülenen bölgedeki dağılımı gösterilmektedir. Verinin içerdiği 15 sınıf haritalarda farklı renklerle gösterilmiştir. Her rengin karşılık geldiği sınıfa ait bilgiler tablo 1.1’de verilmiştir. 16 numara, etiketi olmayan boşluk bölgeleri göstermektedir.

1.4.2 Derin Öğrenme Hakkında

Sayılamayacak kadar çok çeşitli alanda faydalanılan Derin Öğrenme, özellikle görüntü sınıflandırma ve konuşma algılamada vazgeçilmez bir araç olmuştur. Terim olarak ilk defa 1986 yılında, makine öğrenmesi alanında bugünkü anlamından farklı bir anlamda kullanılmış olsa da [6], bugün çok katmanlı YSA'nın *derin* yapısıyla özdeşleşmiştir.

Makine öğrenmesi algoritmalarının başarısı, büyük oranda, verinin temsil biçimine bağlıdır [7]. Sınıflandırıcıya gelen temsîlî bilgiler ne kadar ayırt edici ise, sınıflandırma başarımı o kadar yüksek olur. Bu noktada ham veriden elde edilen temsil biçimlerinin kalitesi önem kazanmaktadır. Derin öğrenme, gücünü; YSA'nın çok katmanlı yapısı sayesinde ham verinin ayırt edici özelliklerinin basitten karmaşığa doğru çıkarılarak karmaşık özelliklerin, basit olanların kombinasyonu olarak temsil edilebilmesinden ve az mühendislik müdahalesi gerektirmesinden almaktadır [8].

1958'de sinir hücresinin matematiksel yaklaşık bir modeli olan *algılayıcının* tasarımı [9] ve 1962'de kedilerin görsel kortekslerindeki algılayıcı bölgelerin işlevinin incelenmesinin ardından [10], bu iki çalışmadan ilham alınarak evrimsel sinir ağlarının temelleri atılmıştır [11]. Bu gelişmelerle başlayan derin öğrenme yolculuğu, YSA'ların eğitimi için *Geri Yayılım* algoritmasının geliştirilmesiyle ivme kazanmıştır [12]. 1990'da evrimsel ağlar geri yayılım algoritmasıyla eğitilmiş ve el yazısı rakamlar algılanmıştır [13]. Bu tarihlerde, o günkü bilgisayar teknolojisinin yetersizliği ve çok katmanlı ağların eğitiminin gerektirdiği işlemsel yük nedeniyle araştırmalar oldukça yavaşlamıştır. 2006 yılı, çok katmanlı ağların eğitilmesi için önerilen algoritma sayesinde, derin öğrenmenin küllerinden yeniden doğduğu tarihtir [14]. Bilgisayar teknolojisinin gelişmesiyle görsel sınıflandırmada [15] ve konuşma algılamada [16] kaydedilen başarılar; hesaplama ve veri saklama kapasitesinin artmasıyla birlikte, derin öğrenmenin daha az mühendislik gerektirmesi de göz önünde bulundurulduğunda, yakın gelecekte çok daha üstün başarılarla imza atacağı öngörülmektedir [8].

1.5 Tezin Akışı

Tez, toplam 6 ana bölümden oluşmaktadır. Giriş bölümünden sonra; "Literatür Özeti", "Derin Öğrenme", "Önerilen Sınıflandırma Yöntemi", "Deneyler" ve "Sonuçlar" bölümleri, ya-

zıldığı sırayla gelmektedir. Literatür Özeti’nde; derin öğrenme kullanarak uzaktan algılama verisi sınıflandırma çalışmaları ve Houston University verisi kullanan sınıflandırma çalışmaları, iki ayrı alt bölümde özetlenmiştir. Üçüncü bölüm olan Derin Öğrenme bölümünde, derin öğrenmenin bu tezde kullanılan unsurları kısaca tanıtılmıştır. Dördüncü bölüm olan Önerilen Sınıflandırma Yöntemi bölümünde, yapılan tüm çalışmalar anlatılmış ve başlıklar işlem sırasına göre sıralanmıştır. Beşinci bölüm olan Deneyler bölümü, sınıflandırma yönteminin farklı aşamalarında farklı kurgularla yapılan deneyleri ve deneylerin çıktılarını içermektedir. Son olaran altıncı bölüm olan Sonuçlar bölümünde, yapılan deneyler ve çıktıları yorumlanmış, tez kapsamında literatüre yapılan katkılar özetlenmiştir.



2. LİTERATÜR ÖZETİ

2.1 Derin Öğrenme ile Sınıflandırmada Yapılmış Çalışmalar

Derin öğrenme kullanarak uzaktan algılama verisi sınıflandırma üzerine yapılan dikkat çekici çalışmalar, 2015 yılının başlarında kendini göstermeye başlamıştır. Önerilen yöntemler; iyi bilinen "Indian Pines", "Salinas", "Pavia Center", "University of Pavia" ve "Kennedy Space Center" HSG'leri üzerinde denenmiştir ve genellikle *Destek Vektör Makineleri (DVM)* ile kıyaslanmıştır. Çalışmalar, yayınlanma tarihine göre eskiden yeniye doğru sıralanmıştır.

Hu vd. 2015'te yaptıkları çalışmada, ilki bir boyutlu evrişim ve onu takip eden bir tam bağlantılı olmak üzere iki katmandan oluşan, pek derin sayılmayan bir yapı önermişlerdir. Bu yapıyı; Indian Pines, Salinas ve University of Pavia HSG'leri üzerinde denemişlerdir. Sonuçları, eğitim süresi ve sınıflandırma başarısı açısından, DVM ile karşılaştırmışlardır. Önerdikleri ESA mimarisi, destek vektör makinelerine bariz bir üstünlük sağlayamamıştır [17].

Chen vd. tarafından 2015'te yapılan çalışmada HSG, tam bağlantılı katmanlar kullanarak hem spektral hem de uzamsal anlamda sınıflandırılmıştır. Tam bağlantılı katman ile uzamsal sınıflandırma yapılabilmesi için öncelikle PCA (Principle Component Analysis - Asal Bileşen Analizi) algoritması ile HSG'nin boyutu düşürülmüş, sonrasında sınıflandırılacak pikselin çevresinden alınan veri küpü tek boyutlu bir vektör haline getirilerek önerilen YSA mimarisine verilmiştir. YSA mimarisi, farklı sayıda katmanlarla denenmiştir. Indian Pines ve University of Pavia üzerinde denenilen yöntem, DVM ile karşılaştırılmış ve başarı elde edilmiştir [18].

Slavkovikj vd. tarafından 2015'teki çalışmalarında önerilen YSA mimarisi, 3 evrişim ve 2 tam bağlantılı katmandan oluşmaktadır. İlk evrişim katmanı 3 boyutlu veri almakta, fakat uzamsal boyutlarda evrişim yapmamaktadır. Bunun yerine, test edilen pikselin komşulukları üzerinde spektral boyutta evrişim yapılmaktadır. Önerilen yöntem, Indian Pines verisi üzerinde denenmiştir. Başka bir sınıflandırıcı ile bir kıyaslama yapılmamış, ayrıca önerdikleri veri çoğaltma yönteminin başarısı üzerine yoğunlaşmışlardır [19].

Tao vd. tarafından 2015'teki çalışmalarında önerilen YSA mimarisi, bir *oto-kodlayıcı* ağıdır. *Gözetimsiz öğrenme* ile öznitelik çıkarımı yapan bu ağıın başarısı, farklı öznitelik çıkarma yöntemleri kullanarak birlikte DVM ile sınıflandırma yapan farklı ekiplerin sonuçları ile karşılaştırılmıştır. Önerilen oto-kodlayıcı, karşılaştırmalarda başarı göstermiştir [20].

Salman vd. tarafından 2016'da yapılan çalışmada 3 adet bir boyutlu evrişim ağından sonra bir tam bağlantılı ağı kullanılmıştır. University of Pavia verisi üzerinde çalıştırılan mimari, DVM ile karşılaştırılmış ve başarılı sonuçlar elde edilmiştir [21].

Lee vd. tarafından 2016'da yapılan çalışmada ilk katmanda bir 3 boyutlu evrişimsel ağı ve buna paralel bir boyutlu evrişimsel ağı kullanılmıştır. Paralel katmanların çıktıları, vektörel olarak uç uca eklenmiş ve sıralı 8 adet bir boyutlu evrişim katmanına aktarılmıştır. Derinliği toplamda 9 katman olan yapı, Indian Pines üzerinde test edilmiş ve DVM algoritmasına üstünlük sağlamıştır [22].

Zhao vd. tarafından 2016'da yapılan çalışma, Pavia Center ve University of Pavia üzerinde spektral ve uzamsal olarak çıkarılan özniteliklerin tek bir sınıflandırıcı ile sınıflandırılmasını önermektedir. Bu çalışmada, uzamsal özniteliklerin çıkarılmasında evrişimsel ağı kullanılmıştır. Önerilen öznitelik çıkarma yöntemleri, Asal Bileşen Analizi (Principle Component Analysis - PCA) ve Doğrusal Ayrımsayıcı Analizi (Linear Discriminant Analysis - LDA) gibi algoritmalar ile karşılaştırılmış ve başarılı sonuçlar elde etmiştir [23].

Ghamisi vd. tarafından 2016'da yapılan çalışma, Parçacık Sürü Eniyileme (PSO) algoritması ile HSG'den en uygun spektral bantları seçerek, 3 adet 3 boyutlu evrişimsel ağıdan oluşan mimarinin başarısını iyileştirmeyi hedeflemiştir. Indian Pines ve University of Pavia verileri üzerinde denenen model, önerilen ESA mimarisinin PSO kullanmayan haliyle ve DVM sınıflandırıcı ile karşılaştırılmıştır. Çalışmada başarılı sonuçlar elde edilmiştir [24].

Chen vd. tarafından 2016'da yapılan çalışmada, 1 boyutlu ve 3 boyutlu evrişimsel ağları karşılaştıran deneyler yapılmıştır. Ayrıca, önerdikleri bu tezde de kullanılan veri çoğaltma yöntemi başarıyı artırmıştır. Indian Pines, University of Pavia ve Kennedy Space Center verilerinde yapılan deneylerde önerilen modeller DVM ile karşılaştırılmış, en iyi sonuçlar 3 adet 3 boyutlu evrişim ağıyla elde edilmiştir [25].

2.2 Kullanılan Veri Kümesi Üzerinde Yapılmış Çalışmalar

2013 yılında Houston Üniversitesi üzerinden alınmış ve yarışma için yayınlanmış HSG ve LiDAR veri kümesi, uzaktan algılama uygulamalarında veri birleştirme ve sınıflandırma yöntemlerinin değerlendirilmesi için önemli bir ölçüt olmuştur [26]. Çeşitli zorluklar barındıran bu veri kümesi üzerinde yapılan belli başlı çalışmalar, bu başlık altında kısaca tanıtılmıştır. Çalışmalar, sınıflandırma başarıları dikkate alınarak, başarı oranı en düşükten en yükseğe doğru sıralanmıştır.

Aytaylan vd. tarafından 2016'da yapılan çalışma, Markov Rassal Alanlarını kullanan iki enerji denklemi (tekil terim ve çiftli terim) önermektedir. Fisher vektörleri ile LiDAR verisinden üretilen öznitelik vektörlerinin ve HSG'nin yüksek boyutu, Hysime algoritması ile düşürülmüştür. Boyutu düşürülmüş veriler, önerilen enerji denklemleri ile birleştirilmiş ve DVM ile sınıflandırılmıştır. Gölge bölge için özel bir uygulama yapılmamış olan bu çalışmanın başarı oranı %89.87'dir [27].

Ghamisi vd. tarafından 2017'de yapılan çalışmada, veri kümesinin sınıflandırılması için 3 adet 3 boyutlu evrişimsel ağ ve 1 tam bağlantılı katmandan oluşan derin mimari kullanılmıştır. Bu ağda sınıflandırılacak girdi; genişletilmiş çoklu sönüm profili (Multi-extinction Profile - MEP) ile HSG ve LiDAR verisinden çıkarılan özniteliklerin, çizge bazlı birleştirilmesiyle elde edilmiştir. Gölgesi haricen düzeltilmiş veri kullanıldığının belirtildiği bu çalışma, %91.02 başarı sağlamıştır [28].

Chen vd. tarafından 2017'de yapılan çalışmada; 2 adet 3 boyutlu evrişim ağları HSG'den, 2 adet 2 boyutlu evrişim ağları LiDAR verisinden öznitelik çıkarma amaçlı kullanılmıştır. Evrişim ağları ile elde edilen öznitelikler, 1 boyutlu vektör haline getirilip uç uca eklenmiş ve 1 tam bağlantılı katmandan geçmiştir. Son olarak lojistik regresyon ile yapılan sınıflandırmada %91.32 başarı elde edilmiştir. Fakat bu çalışmada eğitim sırasında, sadece eğitim için sağlanan verinin kullanıldığı açıkça belirtilmemiş olup test verisinin de eğitim için kullanılmış olabileceği düşünülmüş ve elde edilen sınıflandırma başarısına şüpheyle yaklaşılmıştır [29].

Aytaylan'ın 2017'de bitirdiği yüksek lisans tezinde; EMAP yöntemi ile LiDAR verisinden ve HySime algoritması ile HSG'den çıkarılan öznitelikler, DVM ile sınıflandırılmış, sınıflandırma sonuçları koşullu rassal alanlar ile birleştirilmiştir. Çalışma kapsamında önerilen

tekil terim ve çiftli terim enerji denklemleri, koşullu rassal alanlardaki birleştirme sırasında gölgenin durumuna HSG'ye ya da LiDAR verisine verilen ağırlık değişmektedir. Gölgenin varlığı pikselin toplam enerjisine göre kestirilmektedir. Bu çalışmalar neticesinde %91.55 başarı elde edilmiştir [30].

Khodadadzadeh vd. tarafından 2015'te yapılan çalışmada, HSG ve LiDAR verisinden EMAP yöntemi ile uzamsal öznitelikler çıkarılmıştır. Çıkarılan öznitelikler, Alt-uzay Çokterimli Lojistik Regresyon ile sınıflandırılmış, sınıflandırma sonuçları Markov Rassal Alanları ile birleştirilmiştir. Gölge bölge için özel bir yöntem önermeyen bu çalışmanın başarısı %92.05 olmuştur [31].

Rasti vd. tarafından 2017'de yapılan çalışmada, Sönüm Profilleri (Extinction Profiles - EP) kullanılarak HSG ve LiDAR verisinden uzamsal öznitelikler çıkarılmıştır. Dik Toplam Değişim Bileşen Analizi (Orthogonal Total Variation Component Analysis - OTVCA) kullanılarak, EP ile çıkarılan öznitelikler ve HSG'nin spektral bilgisi birleştirilmiş, DVM ve Rassal Orman ile sınıflandırılmıştır. Elde edilen en iyi başarı, Rassal Orman sınıflandırıcı ile %92.45 olmuştur [32].

Liao vd. tarafından 2015'te yapılan çalışmada, *genelleştirilmiş* çizge temelli birleştirme yapılmıştır. HSG'den ve LiDAR verisinden biçimsel yöntemlerle çıkarılan öznitelikler, çizge temelli yöntemlerle birleştirilmiştir. Çizgelerin düğümleri arasındaki kenarları, özniteliklerin öznitelik uzayında aralarındaki mesafeye göre ağırlıklandırılmıştır. Bu birleştirme stratejisiyle elde edilen birleşik veri, DVM ile sınıflandırılmış ve %94.00 başarı sağlamıştır [33].


Luo vd. tarafından 2017'de yapılan çalışmada, EMAP ile çıkarılan uzamsal öznitelikler kullanılarak yapılan bir ön sınıflandırma sonucuna göre HSG'deki gölge bölgeden eğitim örnekleri üreten yinelemeli bir algoritma önerilmiştir. Buradan toplanan örneklerle bir eğitim veri kümesi oluşturulmuş ve gölge bölgedeki test örneklerini sınıflandırmak için ayrı bir model eğitilmiştir. Sınıflandırıcı olarak DVM kullanan bu çalışmanın başarısı %95.92'dir [34].

3. DERİN ÖĞRENME

Hiyerarşik öğrenme de denen derin öğrenme, çok katmanlı yapılar kullanarak verinin yapısını basitten karmaşığa doğru çözümlemeyi amaçlar. Özellikle *Evrşimsel Sinir ağları* (Convolutional Neural Network - CNN) sayesinde elde edilen etkin öznitelikler, sınıflandırma işlemini oldukça kolaylaştırmaktadır.

Evrşimsel sinir ağlarını daha iyi anlamak için bilindik iki boyutlu görüntüler üzerinden örnek vermek gerekirse, evrşimsel ağdaki birinci katman, görüntünün içerdiği en basit yapıları tespit eder. Katmanda bulunan çok sayıda *filtrenin* her biri, verilen bir görüntüdeki ayrıtlardan birini bulmakla yükümlüdür. Yani görüntünün içerdiği bir kenar bilgisi göz önüne alınırsa, bir kenarın farklı açıları ya da başka kenarlar ile birleşim biçimleri için farklı filtreler görev yapar. Birinci katmanın çıktısı, bu filtrelerin tespit ettiği yapıların bilgisini içeren *öznitelik haritalarıdır*. Bu çıktılar, çeşitli kenar yapılarının görüntü ile olan ilintisel bilgilerini içerir. Bir sonraki evrşim katmanı, öznitelik haritaları üzerinde, bir önceki katmanda tespit edilmiş olan kenarların birbirleri ile olan ilişkilerini ortaya çıkarır. Her evrşim katmanı, bir önceki katmanda tespit edilmiş olan birleşimsel yapıların görüntüyle olan ilintilerini çözümler. Katman sayısıyla birlikte karmaşıklığın da arttığı bu akış, yapısal bilgilerden anlamsal bilgi elde edilmesini kolaylaştırır. Şekil 3.1’de gösterilen temsîlî yapı, evrşimsel sinir ağlarının genel yapılarını özetlemektedir. Birinci katmanda kedinin kulağının ana hatları tespit edildikten sonra ikinci katmanda, bir önceki katmanda tespit edilen kenarların birleşimi çözümlenir ve bu yapının bir kulak olduğu ortaya çıkar. Sonraki katmanlar ile kediye ait diğer yapıların birleşimlerinin de ortaya konmasıyla, kedinin hiyerarşik bir temsili elde edilmiş olur.

Bu bölümün devamı, derin öğrenmede kullanılan sinir ağlarının temelleriyle ilgili detayları içermektedir. Bölüm 3.1’de sinir ağlarının temel işlem birimi olan *algılayıcı* tanıtılmış, bölüm 3.2’de de algılayıcılardan oluşan basit bir sinir ağı yapısı gösterilmiştir. Bölüm 3.3’te, derin öğrenmeye çağ atlatan evrşimlel sinir ağı anlatılmıştır. Bölüm 3.4’te, sinir ağlarında en sık kullanılan etkinleşme fonksiyonları kısaca tanıtılmıştır. Bölüm 3.5’te, sinir ağının eğitimini hızlandıran bir yöntem olan *katman düzgeleme* verilmiştir. Sınıflandırma aşaması olan SoftMax regresyon bölüm 3.6’da verildikten sonra; son olarak eğitim aşamasında kul-



Şekil 3.1: Derin evrişimsel mimariler, yapısal bilgilerden anlamsal bilgiler çıkarabilir. Evrişim katmanları ile çıkarılan öznitelikler, tam bağlantılı katmanların gerçekleştirdiği dönüşümler ile sınıflandırılır.

lanılan algoritmalar olan *eğim düşümü* ve *geri yayılım* ile eğitim ölçütü olan *çapraz entropi* bölüm 3.7’de anlatılmıştır.

3.1 Algılayıcı (Perceptron)

Algılayıcı, YSA’nın temel işlem birimidir. Biyolojik sinir hücrelerinden esinlenilerek ortaya atılan bir fikir sayesinde oluşturulan bu birim, ikili sınıflandırma yapabilme becerisine sahiptir [9]. Algılayıcı; eğitim sırasında öğrendiği ve kendi hafızasında tuttuğu parametreler ile, girdi olarak verilen bir vektörün bulunduğu uzayı doğrusal olarak ikiye böler. Algılayıcıya verilen girdi vektörü, algılayıcının parametrelerinin tanımladığı bir hiper-düzem ile bölünmüş olan uzayın iki bölgesinden birine atanır.


D adet spektral banttıan oluşan HSG’nin bir pikseli, algılayıcının girdisi olsun. Piksel $\mathbf{x}_n = \begin{bmatrix} x_{n,1} & x_{n,2} & \cdots & x_{n,D} \end{bmatrix}^T$ şeklinde tanımlanırsa, şematik olarak şekil 3.2’de gösterilen algılayıcının matematiksel ifadesi;

$$y_n = f(w_0 + \sum_{j=1}^D x_{n,j}w_j) \quad (3.1)$$

şeklinde yazılabilir. Burada w_j ’ler, algılayıcının bağlantı ağırlıklarıdır ve çıktı olan y_n , bu ağırlık değerleri ile girdi değerlerinin çarpımlarının toplamının, bir $f(\cdot)$ fonksiyonundan geçirilmesiyle elde edilir. $f(\cdot)$ fonksiyonu, doğrusal olmayan bir etkinleşme fonksiyonudur.

Algılayıcının ağırlıkları bir vektör olarak $\mathbf{w} = [w_0 \ w_1 \ \dots \ w_D]^T$ şeklinde tanımlanırsa, girdi vektörünün başına 1 eklemek şartıyla, denklem 3.1 ifadesi denklem 3.2'deki gibi matris çarpımı şeklinde yazılabilir.


$$y_n = f\left(\mathbf{w}^T \begin{bmatrix} 1 \\ \mathbf{x}_n \end{bmatrix}\right) \quad (3.2)$$




Şekil 3.2: Şematik olarak algılayıcı.

3.2 Çok Katmanlı Algılayıcı (Multi Layer Perceptron – MLP)

İleri beslemeli sinir ağı ya da *tam bağlantılı sinir ağı* (TBSA) da denen çok katmanlı algılayıcı ağları, derin öğrenmede oldukça sık kullanılan yapılardır. Tek bir algılayıcı, doğrusal ikili bir sınıflandırma yapabilirken; çok sayıda algılayıcının katmanlı bir yapıda sıralanması ile elde edilen TBSA'ları, çok sınıflı ve doğrusal olmayan sınıflandırmalar yapılabilir. XOR problemi, doğrusal olmayan sınıflandırma problemlerinin en bilinenidir. Şekil 3.3'te gösterilen mavi ve turuncu daireler, farklı iki sınıfa ait örnekleri temsil etmektedirler ve bu iki sınıfı birbirinden ayırabilen bir doğru yoktur. Bu problem, bir algılayıcının öncesine şekil 3.4'te gösterildiği gibi en az iki birimli bir gizli katman yerleştirilerek çözülmektedir.




Şekil 3.3: XOR problemi doğrusal olmayan bir problemidir. Mavi daireleri turuncu olanlarından ayırabilen bir doğru yoktur. Dolayısıyla tek bir algılayıcı ile çözümlenemez.



Şekil 3.4: XOR problemini çözümleyebilen ileri beslemeli ağ.

XOR problemi örneğinden anlaşılacağı üzere TBSA'lar, *gizli katmanlar* sayesinde, birbirinden doğrusal olarak ayıramayan farklı sınıflara ait örneklerin bulunduğu öznitelik uzayı üzerinde *doğrusal olmayan dönüşümler* gerçekleştirir. Bu dönüşümler sayesinde, öznitelik uzayında bulunan farklı sınıf bölgeleri, doğrusal olarak birbirinden ayrılabilir duruma gelir. Bu dönüşüm, şekil 3.5'teki görsel ile örneklenmiştir.

XOR problemi, çok katmanlı algılayıcıyı anlamak için bilinen en basit ve temel örnek iken; HSG sınıflandırma problemi, XOR problemiyle karşılaştırıldığında daha karmaşıktır ve çözümü için daha *derin* bir ağ mimarisine ihtiyaç duyulmaktadır.



Şekil 3.5: Çok katmanlı sinir ağı girdi uzayını bozarak farklı sınıflara ait verilerin bulunduğu bölgeleri doğrusal olarak ayrılabilir hale getirir [8].

3.3 Evrişimsel Sinir Ağları (Convolutional Neural Networks)

Evrişimsel sinir ağları (ESA), çok katmanlı algılayıcı ağına özelleşmiş bir halidir ve görüntü işlemede geometrik şekilleri algılamak üzere tasarlanmıştır. Bilindik çok katmanlı algılayıcı ağına l 'inci katmandaki bir algılayıcı, $l - 1$ 'inci katmanda bulunan bütün algılayıcılarla bağlantı halinde iken; evrişimsel katman, bir önceki katmanın çıktısı üzerinde yerel bağlantılar kurmaktadır. Tam bağlantılı katman, bir matris çarpma işlemi gerçekleştirirken (denklem 3.2'de görüldüğü gibi); evrişimsel katman, doğrusal bir matematiksel işlem olan evrişim işlemini kullanır [3]. Evrişim işlemi $*$ ile gösterilir ve denklem 3.3'teki gibi yazılır:

$$y(t) = u(t) * x(t) = \int u(\tau)x(t - \tau)d\tau \quad (3.3)$$

Evrişim işleminin sürekli zaman ifadesi olan denklem 3.3, ayrık zamana uyarlanırsa denklem 3.4 elde edilir.

$$y[k] = \sum_j u[j]x[k - j] \quad (3.4)$$

Denklem 3.4'te toplam içinde nedensellik ilkesinden dolayı $x[k - j]$ şeklinde yazılan $x[k]$, sonucu değiştirmedikleri ve programlamada kolaylık sağladıkları için $x[k + j]$ şeklinde yazılmaktadır [3].

$$y[k] = \sum_j u[j]x[k + j] \quad (3.5)$$


YSA ile gerçekleştirilen evrişim işleminde w evrişim katmanındaki bir filtre, x bu katmanın girdisi ve $f(\cdot)$ de etkinleşme fonksiyonu olsun. Evrişim işleminde filtre penceresinin girdi üzerinde kayma miktarı olarak tanımlanan *atlama* (*stride* – ζ) parametresi de hesaba katıldığında, evrişim katmanında bir spektral vektör (HSG'nin n 'inci pikseli – $\mathbf{x}_n$) üzerinde evrişim katmanındaki nöronların ağırlık vektörü ($\mathbf{w}$) ile gerçekleştirilen matematiksel işlem denklem 3.6'daki gibi olur.

$$y_n[k] = f(\mathbf{w} * \mathbf{x}_n) = f\left(\sum_j \mathbf{w}[j] \mathbf{x}_n[\zeta k + j]\right) \quad (3.6)$$

Burada pozitif bir tamsayı olan ζ parametresinin kullanılmasının sebebi, evrişim işlemine örnek seyreltme işlevi ekleyerek evrişim esnasında büyük boyutlu girdilerin boyutunu küçültmektir. Sinyal işleme uygulamalarında, L_1 ve L_2 uzunluğundaki iki sinyalin denklem 3.4'e göre evrişimi sonucunda elde edilen sinyalin uzunluğu $L_1 + L_2 - 1$ olur. ESA'da gerçekleşen evrişim işlemi, sinyal işlemedekinden farklı olarak; sadece kısa olan sinyalin uzun olan üzerinde bütünüyle örtüştüğü yerleri dikkate alarak hesaplama yapar, evrişimin başladığı ve bittiği bölgelerdeki kısmî örtüşmeleri hesaba katmaz. Bunun neticesinde denklem 3.6'ya göreki çıktının uzunluğu, $L_1 > L_2$ olmak üzere $\lceil \frac{L_1 - L_2 + 1}{\zeta} \rceil$ ile bulunur. Bu ifadedeki $\lceil \cdot \rceil$ gösterimi, tavan fonksiyonunu ifade etmektedir. Evrişim işlemi şekil 3.6'da şematik olarak gösterilmiştir. Burada evrişim filtresinin ağırlıkları w ile, evrişimin girdisi ve çıktısı da sırasıyla x ve y ile gösterilmiştir. Bu örnekte filtrenin boyu 3, girdinin boyu 9 ve atlama parametresi de $\zeta = 2$ 'dir. Bu değerlere göre çıktının boyu $\lceil \frac{9-3+1}{2} \rceil = 4$ olur.

3.4 Etkinleşme Fonksiyonları (Activation Functions)

TBSA'da gerçekleştirilen matris çarpımı ve ESA'da gerçekleştirilen evrişim işlemi doğrusal işlemlerdir ve karmaşık çözümler gerektiren sınıflandırma problemlerinde yetersiz kalmaktadır. Bu yapılar, doğrusal olmayan etkinleşme fonksiyonları kullanılarak problemin doğrusal olmayan ve karmaşık doğasına uyarlanabilmektedir. Bir algılayıcının girdileri ve ağırlıkları ile hesapladığı değer, bu fonksiyonların argümanıdır ve algılayıcının çıktısı ve bir sonraki katmanın girdisi olan değeri belirler. Yine biyolojik sinir hücrelerinden esinlenilerek ortaya atılan bu fikrin en basit hali eşikleme fonksiyonudur. Eşiklemeye göre bir algılayıcının çıkışı, 1 ya da 0'dır. Bir algılayıcı ile ikili sınıflandırma, bu eşikleme fonksiyonu




Şekil 3.6: Evrişim işlemini gösteren bir şema. Evrişim filtresinin ağırlıkları w , evrişimin girdisi x ve çıktısı da y ile gösterilmiştir.

kullanılarak mümkün olur. Fakat derin ağların *eğim düşümü* (*gradient descent*) algoritması ile eğitimi sırasında eğimin hesaplanabilmesi için türevlenebilir etkinleşme fonksiyonlarının kullanılması gerekmektedir. Bu sebeple, derin ağlarda eşikleme yerine en sık kullanılan etkinleşme fonksiyonları *sigmoid*, *tanh* ve *ReLU*'dur. Bu fonksiyonların çizimleri Şekil 3.7'te verilmiştir.


Sigmoid fonksiyonunun matematiksel ifadesi $f(x) = 1/(1 + e^{-x})$ şeklindedir. Argümanını $[0, 1]$ aralığına eşleyen sigmoid fonksiyonunun çıkışı, sıfırdan uzaklaşan x değerleri için Şekil 3.7a'da görüldüğü gibi doyuma ulaşır. Sıfır merkezli olmadığı ve doyuma ulaştığı için nadiren tercih edilmektedir.

Hiperbolik tanjant fonksiyonu, argümanını $[-1, 1]$ aralığına eşleyen bir aktivasyon fonksiyonudur. Matematiksel ifadesi $f(x) = \tanh(x) = (1 - e^{-2x})/(1 + e^{-2x})$ olan bu fonksiyon, sigmoid fonksiyonundan farklı olarak, argümanını eşlediği aralık gereği, çıktısı sıfır merkezlidir ve bu sebeple sigmoid fonksiyonuna göre daha sık kullanılmaktadır. Fakat, Şekil 3.7b'de görüldüğü gibi argümanı sıfırdan uzaklaştıkça doyuma ulaşması, en önemli dezavantajdır.


ReLU (Rectified Linear Unit) fonksiyonu, bilgisayarlı görüde, özellikle nesne tespiti ve sınıflandırma uygulamalarında en çok kullanılan fonksiyondur ve bu tip uygulamalarda yapay sinir ağlarına çağ atlatmıştır. Matematiksel olarak $f(x) = \max(0, x)$ şeklinde ifade edilebi-



(a) Sigmoid fonksiyonu: $f(x) = 1/(1 + e^{-x})$.



(b) Hiperbolik tanjant fonksiyonu: $f(x) = \tanh(x) = (1 - e^{-2x})/(1 + e^{-2x})$.



(c) ReLU (Rectified Linear Unit): $f(x) = \max(0, x)$.

Şekil 3.7: Sık kullanılan etkinleşme fonksiyonlarının grafikleri.

len ReLU fonksiyonunun, pozitif argümanlar için türevi her zaman sıfırdan farklıdır. Şekil 3.7c’de görüldüğü gibi negatif argümanlar için her zaman sıfırdır ve dolayısıyla türevi de sıfırdır ve en önemli dezavantajı budur.

3.5 Katman Düzgeleme (Layer Normalization)

Derin sinir ağların eğitimi, hesaplama yükü açısından oldukça maliyetlidir. Bunun sebeplerinden birisi, *dahili eşdeğişken kayması (internal covariate shift)* adı verilen bir durumdur [35]. Bir katmanın girdilerinin istatistiksel dağılımı, eğitim sırasında önceki katmanın bağlantı ağırlıklarının değişmesi sonucu değişir. Bu da öğrenme sürecini yavaşlatan bir etkindir ve eğitim için gerekli döngü sayısını artırır. Katman düzgeleme, bu etkiyi azaltarak derin sinir ağlarının eğitimi hızlandırmak amacıyla önerilmiştir [36].

Katman düzgeleme; ağıdaki bir katmana giren veri yığını ile bağlantı ağırlıkları kullanılarak yapılan matris çarpımı ya da evrişim işlemi sonucu elde edilen değerlerin, bu değerlerin istatistiksel dağılımı (ortalama değer ve değişim) kullanılarak düzgelemesidir. $a_{l,j}$, ağı l ’inci katmanındaki j ’inci birimin, bağlantı ağırlıkları ($w_{l,j}$) ve $l - 1$ ’inci katmanın çıktısını (q_{l-1}) kullanarak hesapladığı değer; $f(\cdot)$, birimin etkinleşme fonksiyonu ve $b_{l,j}$ de yanlılık değeri olmak üzere bu birimde gerçekleşen işlemler denklem 3.7’deki gibidir.

$$a_{l,j} = \mathbf{w}_{l,j}^T \mathbf{q}_{l-1} \quad q_{l,j} = f(a_{l,j}, b_{l,j}) \quad (3.7)$$

Düzgeleme işlemi için kullanılacak istatistiksel bilgiler denklem 3.8’de verilmiştir. Burada J_l , l ’inci katmandaki nöron sayısı; μ_l , bu katmana giren veri yığınının ortalama değeri ve σ_l de değişimdir. Bu istatistikler, katmana giren tüm veri ve tüm nöronlar üzerinden her döngü için hesaplanmaktadır.

$$\mu_l = \frac{1}{J_l} \sum_{j=1}^{J_l} a_{l,j} \quad \sigma_l = \sqrt{\frac{1}{J_l} \sum_{j=1}^{J_l} (a_{l,j} - \mu_l)^2} \quad (3.8)$$

Düzgeleme işlemi denklem 3.9’daki gibi yapılmaktadır. Burada $\bar{a}_{l,j}$, l ’inci katmanın j ’inci nöronunun düzgelemiş değeri ve $\eta_{l,j}$ da aynı nöron için eğitim sırasında öğrenilen bir kazanç değeridir.

$$\bar{a}_{l,j} = \frac{\eta_{l,j}}{\sigma_l} (a_{l,j} - \mu_l) \quad (3.9)$$

3.6 SoftMax Regresyon

YSA'nın bu bölüme kadar anlatılan bileşenleri, veriden öznitelik çıkarmak ve veri akışını düzenlemek için kullanılmaktadır. SoftMax Regresyon, bir derin ağın son katmanı olup sınıflandırma görevinin tamamlandığı yerdir. Önceki katmanların gerçeklediği fonksiyonlar sayesinde elde edilen öznitelik vektörü, SoftMax Regresyon katmanının girdisidir.

SoftMax Regresyon, lojistik regresyonun genellenmiş halidir ve çok sınıflı sınıflandırma problemlerinde kullanılır. Sınıflandırma problemimizde 15 adet sınıf bulunmaktadır. HSG'nin n 'inci pikseli olan $\mathbf{x}_n$ 'nin, YSA ile elde edilen öznitelik vektörü $\hat{\mathbf{x}}_n$ için regresyon ifadesi denklem 3.10'daki gibidir:

$$\mathbf{q}_n = \mathbf{W}^T \hat{\mathbf{x}}_n + \mathbf{w}_0 = \begin{bmatrix} q_{n,1} & q_{n,2} & \cdots & q_{n,15} \end{bmatrix}^T \quad (3.10)$$

Sınıflar arası eş dağılımlı regresyon değerleri elde edebilmek için *SoftMax fonksiyonu* kullanılır [37]:

$$P(y_n = c | \mathbf{x}_n) = \frac{\exp(q_{n,c})}{\sum_{j=1}^{15} \exp(q_{n,j})} \quad (3.11)$$

SoftMax regresyon sonucunda $\mathbf{x}_n$ 'nin atandığı sınıf, denklem 3.12 ile verilir.

$$y_n = \arg \max_c \{P(y_n = c | \mathbf{x}_n)\}, \quad c \in \{1, 2, \dots, 15\} \quad (3.12)$$

3.7 Çapraz Entropi, Eğim Düşümü ve Geri Yayılım Algoritması

YSA'nın eğitimi, bir eniyileme problemidir. Bu eniyileme problemi için kullanılan ve eniyilenecek olan fonksiyon ise Çapraz Entropi (Cross Entropy) fonksiyonu, başka bir isimle

Kullback-Leibler uzaklığıdır. Hata miktarını ölçen bu fonksiyon, YSA'nın parametrelerinin doğruluğu hakkında bilgi sağlamaktadır. y_n' , eğitim kümesinde bulunan n 'inci pikselin doğru etiketi olsun. Burada çapraz entropi, ya da Kullback-Leibler uzaklığı denklem 3.13'teki gibi tanımlanır:

$$D_{KL}(y_n' || y_n) = \sum_{j=1}^{15} u_{n,j} [\log(P(y_n = j | \mathbf{x}_n)) - \log(u_{n,j})], \quad u_{n,j} = \begin{cases} 1, & j = y_n' \\ 0, & j \neq y_n' \end{cases} \quad (3.13)$$

Çapraz entropi, SoftMax regresyon sonucunun istenen sonuca olan uzaklığını verir. YSA'daki çok sayıda parametreye bağlı olan bu uzaklık iteratif eniyileme algoritmaları ile küçültülür. Eğim Düşümü (Gradient Descent) algoritması, çapraz entropiyi küçültmek için kullanılan algoritmadır. Bu algoritma, küçültülecek fonksiyonun gradyan (eğim) yüzeyi üzerinde iteratif olarak, önceden belirlenmiş adım boyu mesafesinde, artan gradyanın tersi yönünde ilerleyerek fonksiyonun en küçük değerini arar. w YSA'daki parametreler, η adım boyu olmak üzere, gradyan yüzeyi denklem 3.14 şeklinde yazılır:

$$\nabla_{\mathbf{w}} \Psi = \left[\frac{\partial \Psi}{\partial w_1} \quad \frac{\partial \Psi}{\partial w_2} \quad \dots \right]^T, \quad \Psi_n = D_{KL}(y_n' || y_n) \quad (3.14)$$

Gradyan hesaplandıktan sonra YSA'daki her bir parametre, denklem 3.15 kullanılarak, yinelemeli şekilde güncellenir:

$$w_j = w_j - \eta \frac{\partial \Psi_n}{\partial w_j}, \quad \forall j \quad (3.15)$$

Gradyanın, YSA'daki tüm parametreler üzerinden bir defada hesaplanması mümkün değildir. Burada *Geri Yayılım (Back-Propagation)* algoritması devreye girmektedir [12]. Bu algoritma, en üst katmandan başlayarak (SoftMax Regresyon), her katmanda, sadece katmanın ağırlıklarını kullanarak gradyan hesaplar ve buradaki hatayı bir alt katmana aktarır. Bu işlem, *zincir kuralı* ile yapılır.


4. ÖNERİLEN SINIFLANDIRMA YÖNTEMİ

HSG ve LiDAR verilerini sınıflandırmak için uygulanan yöntemler, bu bölümde dört ana başlıkta anlatılmıştır. Bölüm 4.1’de, ham HSG ve LiDAR verisine uygulanan, sınıflandırma öncesi işlemler sıralanmıştır. HSG sınıflandırma ve LiDAR sınıflandırma yöntemleri, sırasıyla bölüm 4.2 ve 4.3’te anlatılmıştır. Sınıflandırma sonrası uygulanan işlemlere ise bölüm 4.4’te yer verilmiştir. Tezde önerilen sınıflandırma yöntemini özetleyen iş akışı şeması şekil 4.1’de gösterilmiştir.

İşe ilk olarak, önerilen ESA modelinin eğitimi ile başlanmıştır. Veri çoğaltma yöntemi ile, mevcut eğitim verilerinin kullanılarak yapay eğitim verileri oluşturulmuş ve veri kümesi genişletilmiş, ardından oluşturulan yeni veri kümesi ile ESA modeli eğitilmiştir. Eğitilen ESA modeli ile sınıflandırılacak olan HSG’nin gölgesinin düzeltilmesi ve gürültüsünün azaltılması bir sonraki aşamadır. Bu aşamada LiDAR yansıma parlaklığı verisi kullanılarak HSG’deki gölge bölge tespit edilmiş ve düzeltilmiştir. Sonrasında Yön Bağımlı Nüfuz Filtre kullanılarak HSG’nin gürültüsü azaltılmıştır. Düzeltilmiş gürültüsüz HSG, ESA modeli ile sınıflandırılmış ve olasılıksal çıktılar elde edilmiştir.

LiDAR yükselti bilgisi üzerinden sınıflandırma yapılması için EMAP yöntemi ile uzamsal bilgi çıkarımı yapılmıştır. 1 boyuttan 280 boyuta çıkarılan LiDAR verisi içinden, eğitim veri kümesine ait etiket bilgisi kullanılarak eğitim veri kümesi oluşturulmuş ve bu veri kümesi ile, önerilen TBSA modeli eğitilmiştir. Eğitilmiş TBSA modeli kullanılarak, uzamsal bilgi çıkarımı ile oluşturulan yeni veri kümesi sınıflandırılmış ve olasılıksal çıktılar elde edilmiştir.

Sınıflandırma işlemlerinin ardından birleştirme işlemi gerçekleştirilmiştir. Tez kapsamında önerilen ve detayları bölüm 4.4.1’de verilen yöntem ile, sınıflandırma sonucu elde edilen olasılıksal çıktılar kullanılarak veriler birleştirilmiş ve bir sınıflandırma haritası elde edilmiştir. Bu sınıflandırma haritası üzerinden, sınıflandırılan bölgelerin konumsal bilgilerinin kullanıldığı çoğunluk oylaması ile sınıflandırma sonucu düzenlenmiştir ve nihai sınıflandırma sonucu elde edilmiştir.



Şekil 4.1: Sınıflandırma yönteminin iş akışı şeması. **Y** (sarı) eğitim verisinin sınıf bilgisini, **X** (mavi) hyperspektral verisini, **I** (turuncu) LiDAR yansımaya parlaklığı verisini, **Z** (yeşil) LiDAR yükselti verisini temsil etmektedir. Siyah çerçeveli beyaz kutular, işlemlerin gerçekleştirildiği düğümlerdir. Beyaz fontlu gri kutular, önceki işlem kutusunun çıktısının bulunduğu veri düğümleridir.

4.1 Veri Kümesi Üzerinde Ön İşlemler

HSG ve LiDAR verileri sınıflandırılmadan önce bir takım ön işlemlerden geçmektedir. Bu işlemlerin uygulanmasının sebebi, sınıflandırma başarımının verideki düzensizliklerden dolayı düşüşünün önüne geçmektir. HSG üzerinde yapılan ön işlemler; gölge kestirimi ve düzeltme, YBNF ile gürültü azaltma, evrişim işlemi ile öznitelik çıkarımı şeklinde sıralanabilir. LiDAR üzerinde ise sadece EMAP ile uzamsal bilgi çıkarımı yapılmıştır. HSG’de gölge kestirimi ve düzeltme işlemi için ayrıca LiDAR yansıma parlaklık verisi kullanılmıştır.

4.1.1 Eğitim Verisi Çoğaltma

Eğitim sırasında kullanılan verinin miktarı ve çeşitliliği, derin öğrenme mimarilerinin başarısını doğrudan etkileyen unsurlardan birisidir. Veri miktarındaki ve çeşitliliğindeki artış, eğitilen modelin, öğrendiği öznitelikleri daha isabetli şekilde genelleyebilmesine yardımcı olur. Bu sebeple, kullanılan veri kümesinin az miktardaki eğitim verisinin çoğaltılması için Chen vd. tarafından önerilen karışım temelli veri çoğaltma yöntemi kullanılmıştır [25].

$$\mathbf{x}' = \frac{\gamma_{j1}\mathbf{x}_{j1} + \gamma_{j2}\mathbf{x}_{j2}}{\gamma_{j1} + \gamma_{j2}} + \gamma_N\mathcal{N} \quad (4.1)$$

Denklem 4.1’de $\mathbf{x}_{j1}$ ve $\mathbf{x}_{j2}$ aynı sınıfa ait olmak şartıyla eğitim veri kümesi içinden rasgele seçilmiş iki pikselin spektral imzaları olmak üzere; bu iki pikselin γ_{j1} ve γ_{j2} oranlarında karıştırılıp γ_N gücünde Gauss dağılımlı gürültü ($\mathcal{N}$) eklenmesiyle, yeni veriler üretmek mümkündür.

4.1.2 Gölge Kestirimi ve Düzeltme

Daha önce bahsedildiği üzere, havadan yapılan hiperspektral görüntülemenin en zayıf noktası, havaküresel değişimlere karşı aşırı duyarlı olmasıdır. Görüntülenen bölgede bulunan, yüksek yapılardan ya da buluttan kaynaklı gölgeler, spektral bilginin bozulmasına neden olmaktadır. Bu yüzden kullanılan veride gölge bulunması ciddi bir sorundur ve sınıflandırma işleminde başarımı kayda değer oranda düşürmektedir.

HSG’lerde gölgeyi tespit etmek için doğrudan eşikleme kullanmak sağlıklı sonuçlar vermektedir. Doğrudan eşikleme yapmanın iki temel dezavantajı vardır. Birincisi; gölge altında bulunan parlak bölgeler, kullanılan eşik değerinin üzerinde kalarak aydınlık bölgedeymiş gibi algılanabilir ve tam tersi olarak, aydınlıkta bulunan koyu renkli bölgeler de eşik değerinin altında kalarak gölgedeymiş gibi algılanabilir. İkincisi, eşik değerini elle belirlemek gerekir.

Tezde, bu iki dezavantajı ortadan kaldıran, gölge bölgenin tespiti ve gölgenin düzeltilmesine yönelik basit bir yöntem önerilmiştir. Bu yöntemde yardımcı veri olarak LiDAR yansıma parlaklık verisi kullanılmıştır. Yöntem, iki temel bilgi ve bir varsayıma dayanmaktadır.

Bilgi:

- Hiperspektral görüntülemelerde gölgenin zayıflatma etkisi, dalgaboyuna göre değişiklik gösterir. Yani gölge altındaki bir pikselin parlaklığı, güneş ışığı altındaki durumuna göre, farklı dalga boylarında farklı oranlarda zayıflar [38].
- LiDAR’ın aktif bir görüntüleme tekniği olması sayesinde, elde edilen yükseklik ve yansıma parlaklık verileri gölgeden etkilenmez.

Varsayım:

- Kullanılan HSG, görüntülenen bölgedeki yüzey maddelerinin homojen dağılmış olduğu varsayılabilir kadar geniş bir bölgeyi kapsamaktadır.

Önerilen yöntem, HSG ve LiDAR verisi arasındaki; hiperspektral görüntülemenin pasif, LiDAR ile görüntülemenin ise aktif bir görüntüleme tekniği olmasından kaynaklanan farklılıklardan yararlanmaktadır ve üç aşamadan oluşmaktadır:

1. Gölge bölgenin tespiti,
2. Her dalgaboyu için *zayıflama katsayısının* belirlenmesi,
3. Gölgenin düzeltilmesi.

HSG’de gölge bölgedeki benzer maddelere ait piksellerin enerjisi, aydınlık bölgedeki piksellere göre daha düşük iken, LiDAR yansıma parlaklığı görüntüsünde benzer maddelere

ait olan gölge ve aydınlık bölgelerdeki pikseller arasında böyle bir fark bulunmamaktadır. Bu bilgiden yola çıkılarak; bir pikselin HSG'deki enerjisinin LiDAR yansımaya parlaklığı değerine oranının, o pikselin gölge bölgede bulunma durumu hakkında bilgi sağlayacağı öngörülmüştür.

HSG'deki n 'inci pikselin enerjisi aşağıdaki gibi tanımlanmış olsun:

$$E_n = \sum_{m=1}^D x_{n,m} = ||\mathbf{x}_n||_1, \quad \mathbf{E} = \begin{bmatrix} E_1 & E_2 & \dots & E_N \end{bmatrix}. \quad (4.2)$$

LiDAR yansımaya parlaklığı verisi $\mathbf{I} = \begin{bmatrix} i_1 & i_2 & \dots & i_N \end{bmatrix}$ iken, n 'inci piksel için HSG enerjisinin (E_n) LiDAR yansımaya parlaklık değerlerine (i_n) oranı aşağıdaki gibi yazılsın:


$$r_n = \frac{E_n}{i_n}, \quad \mathbf{R} = \begin{bmatrix} r_1 & r_2 & \dots & r_N \end{bmatrix} \quad (4.3)$$

$\mathbf{R}$ matrisinin $[0, 1]$ aralığına ölçeklendirilmiş hali, görüntüde piksellerin aydınlık olma olasılıkları haritası gibi düşünülebilir. Elde edilen bu olasılık haritası şekil 4.3d'deki gibi görülmektedir. En iyi sonucun elde edilmesi için $\mathbf{R}$ matrisi hesaplanmadan önce HSG enerji verisi $\mathbf{E}$ ve LiDAR yansımaya verisi $\mathbf{I}$, aykırı değerlerin temizlenmesi amacıyla Gauss filtre ile filtrelenmiştir.

Şekil 4.3d'deki harita bir eşik değeri ile eşiklenirse, gölge ve aydınlık bölgeleri gösteren, ikili değer alan bir harita elde edilebilir. Eşiklemde kullanılacak eşik değerini belirlemek için ise bir yöntem önerilmiştir. $\mathbf{R}$ matrisinin, hesaplanma biçimi gereğince (spektral enerjinin LiDAR yansımaya değerine oranı) gölge bölgeler ile aydınlık bölgeler arasında yüksek bir kontrast göstereceği, ve buna bağlı olarak, histogramı hesaplandığında da değerlerin yüksek ve düşük bölgelerde iki ayrı öbek oluşturacağı öngörülmüştür. Bu öbekler, k-Ortalama Kümeleme (k-Means Clustering) algoritması kullanılarak birbirinden ayrılmıştır. $k = 2$ için (aydınlık ve gölge olmak üzere iki küme) k-Ortalama algoritmasının verdiği küme ortalama değerleri öbeklerin merkezi kabul edilirse; histogramda bu iki öbek arasındaki en çukur noktaya denk gelen değer, görüntünün eşik değeri olarak kullanılabilir. Söz konusu histogram şekil 4.2'de gösterilmiş ve yöntemin hesapladığı eşik değeri, $\epsilon_g = 0.27$ olarak bulunmuştur.

$$\mathbf{G} = \begin{bmatrix} g_1 & g_2 & \dots & g_N \end{bmatrix} \quad g_n = \begin{cases} 1, & r_n < \epsilon_g \\ 0, & r_n > \epsilon_g \end{cases} \quad (4.4)$$

Tespit edilen gölgenin sınırları şekil 4.3e’de görülmektedir.



Şekil 4.2: $\mathbf{R}$ matrisi üzerinden hesaplanan histogram. Gölgenin kestirimi için bulunan eşik değeri, histogram üzerinde kesikli çizgi ile gösterilmiştir. Kesikli çizginin sol tarafı gölge bölgede kalan pikselleri, sağ tarafı da aydınlık bölgedeki pikselleri temsil etmektedir.

Gölge düzeltme işleminde, bu bölümün başında verilen bilgi gereğince, öncelikle ışığın zayıflama katsayısının her spektral bant için hesaplanması gerekmektedir. Bunun için, yine bu bölümün başında belirtilen homojen dağılım varsayımı kullanılmıştır. Homojen dağılım varsayımına göre, aydınlıkta ve gölgede bulunan pikseller için ayrı ortalama değerler belirlenebilir. $\mathbf{X}_{ayd}$ ve $\mathbf{X}_{glg}$ sırasıyla aydınlık bölgedeki N_{ayd} adet ve gölge bölgedeki N_{glg} adet pikseli içeren matrisler olmak üzere; d 'inci bantta aydınlık ve gölge bölgelerdeki piksellerin ortalama enerjileri, denklem 4.5 ve 4.6'daki gibi hesaplanabilir.

$$E_{ayd}^{(d)} = \frac{1}{N_{ayd}} \sum_{\mathbf{x}_n \in \mathbf{X}_{ayd}} x_{n,d} \quad (4.5)$$

$$E_{glg}^{(d)} = \frac{1}{N_{glg}} \sum_{\mathbf{x}_n \in \mathbf{X}_{glg}} x_{n,d} \quad (4.6)$$



(a) İşlenmemiş verinin KYM görseli.



(b) HSG enerji verisi.




(c) LiDAR parlaklık verisi.



(d) Aydınlık olma olasılık haritası.



(e) Tespit edilen gölge bölge.




(f) Düzeltilmiş verinin KYM görüntüsü.

Şekil 4.3: Gölge tespiti ve düzeltme işlemi aşamalarında elde edilen haritalar.


Aydınlık bölgedeki ortalama enerjinin gölge bölgedeki ortalama enerjiye oranı ise zayıflama katsayısını verir. Zayıflama katsayıları bulunduğundan sonra, gölge bölgede bulunan pikseller bu katsayılarla çarpılarak düzeltilir. HSG'nin gölge altında bulunan kısmı, düzeltilmiş olarak denklem 4.7'deki gibi ifade edilebilir.

$$\mathbf{X}_{glg}^{(d)'} = \alpha_d \mathbf{X}_{glg}^{(d)}, \quad \alpha_d = \frac{E_{ayd}^{(d)}}{E_{glg}^{(d)}} \quad (4.7)$$

Elde edilen zayıflama katsayıları (α_d) şekil 4.4'te grafiksel olarak görülmektedir. Hiç bir etiket bilgisi kullanılmadan elde edilen bu değerlerin doğruluğunu sağlamak için; gölgede bulunan 9 sınıfa ait etiketli test verileri ve yine aynı sınıflara ait aydınlık bölgedeki etiketli veriler kullanılarak zayıflama oranları hesaplanmış ve şekil 4.5'teki grafikler elde edilmiştir. Her bir grafik incelendiğinde; hesaplanan değerler ile etiketli veriler üzerinden elde edilen gerçek değerler arasında fark bulunsada, değişim oranlarının benzerlik gösterdiği görülmektedir. Zayıflama katsayılarının çizdirilmesiyle elde edilen bu grafiklerdeki benzerlikler, hesaplanan zayıflama katsayılarının gerçeğe yakın olduğunu göstermektedir. Hesaplanan değerler ile yapılan gölge düzeltme işlemi sonucunda elde edilen verinin KYM görüntüsü şekil 4.3f'deki gibi elde edilmiştir.



Şekil 4.4: Kestirilen zayıflama katsayılarının ($\alpha^{(d)}$) dalgaboyuna göre grafiği.



Şekil 4.5: Etiket bilgisi kullanmadan kestirilen zayıflama katsayılarının, etiketli verilerle elde edilen gerçek zayıflamayla katsayılarıyla kıyaslanması. Karşılaştırmalar sınıf bazında yapılmıştır. Kırmızı kesikli çizim, aydınlık bölgedeki test verileri ile gölge bölgedeki test verileri kıyaslanarak elde edilmiştir. Yeşil çizim, önerilen yöntemle hesaplanmış değerlerdir ve bütün grafiklerde aynıdır. Gölge bölgede 3, 5, 6, 12, 14 ve 15’inci sınıflara ait etiketli veri olmadığı için bu sınıflarda karşılaştırma yapılamamıştır.

4.1.3 HSG’de YBNF ile Gürültü Azaltma

Gürültü, tespit ve sınıflandırma problemlerinde başarıyı düşüren etkenlerden biridir. Bu sebeple, veriyi sınıflandırmadan önce gürültüden arındırmak, sınıflandırma öncesi işlemlerin başında gelir. Gauss filtresi, standart sapması düşük gürültüyü azaltmak için kullanılan en temel filtre olmakla birlikte, kenar ve keskin ayrıntılar içeren görüntülerde bu özellikleri koruyamadığı için yetersiz kalmaktadır. Medyan filtresi, standart sapması yüksek gürültülerini temizlemede başarılı olmakla birlikte; kenar koruma yeteneği olsa da başarıyı pencere genişliğine aşırı duyarlıdır ve filtreleme başarıyı, ayrıntı seviyesine göre görüntünün farklı yerlerinde değişiklik göstermektedir. Pikselleri, enerji havuzları gibi düşünecek olursak; Gauss filtrelemede komşu havuzlar arasındaki enerji farkı ne kadar yüksek ise, enerjisi yüksek olan havuzdan düşük olana aktarılacak olan enerji miktarı o kadar fazladır. Medyan filtresinde, eğer filtrelenen havuzdaki enerji seviyesi komşu havuzlardaki enerji seviyesinden çok farklı ise, bu havuzdaki enerji azaltılmakta ve komşu havuzlara benzetilmektedir.

Yön Bağımlı Nüfuz Filtre (YBNF), ayrıntıları koruyarak gürültüyü azaltma işleminde oldukça başarılı bir filtrelemedir ve yukarıda bahsedilen filtrelerden farklı olarak zamana bağlıdır [39]. Her pikselin bir enerji havuzunu temsil etmesi şeklinde örneklendirilecek olursa; iki komşu havuz arasındaki enerji farkı ne kadar düşük ise havuzlar arasındaki enerji akış hızı o kadar yüksektir ve iki havuz kısa sürede dengeye ulaşır. Havuzlar arasındaki enerji fark arttıkça geçiş azalır ve havuzların dengeye ulaşması çok uzun zaman alır. Ayrıntı içeren bölgelerde bu enerji farkı yüksek, havuzlar arası geçiş az olacaktır. Dolayısıyla YBNF kullanıldığında homojen bölgelerdeki pikseller hemen dengeye ulaşırken ayrıntı içeren bölgeler çok az değişecek ve ayrıntılar korunmuş olacaktır. Filtrenin zaman parametresi ise pikseller arası geçişin ne kadar süreceğini belirtmektedir. Süre uzadıkça filtrenin etkisi artmaktadır. Filtrenin temel mekanizmasını oluşturan *Perona-Malik denkleminin*, HSG’nün d ’inci bandındaki gri ölçekli görüntüye uygulandığı denklem 4.8’deki gibidir.


$$\frac{\partial \Omega^{(d)}}{\partial t} = \nabla \cdot (g(\|\nabla \Omega^{(d)}\|) \nabla \Omega^{(d)}) \quad (4.8)$$

$\mathbf{X}^{(d)}$ bu tezde HSG’nün d ’inci bandını piksel dizisi olarak ifade ederken, $\Omega^{(d)}$ bu görüntünün iki boyutlu olan, yani uzamsal özellikleri içeren ifadesi olarak kullanılmıştır. $g(\cdot)$ fonksiyonu, pikseller arası nüfuzu denetleyen bir fonksiyon olup denklem 4.9’daki gibi ta-

nımlanmıştır.

$$g(||\nabla\Omega^{(d)}||) = e^{-(\frac{||\nabla\Omega^{(d)}||}{\kappa})^2} \quad (4.9)$$

Denklem 4.9'daki κ parametresinin gürültü kestirici ile belirlenmesi ve algoritmanın nümerik olarak uygulaması [39]'da verilmiştir. Filtrelemenin etkisi, şekil 4.6'da karşılaştırmalı olarak görülmektedir. Bu görselde, gürültü olma ihtimali yüksek olan küçük değişimlerin düzleştirildiği, bu sırada gürültü olma ihtimali olmayan güçlü ayrıtların korunduğu görülmektedir.



Şekil 4.6: YBNF ile gürültü azaltmanın etkisi.

4.1.4 HSG'de Evrişim İşlemi ile Öznitelik Çıkarımı

Evrişim katmanının bilgisayarlı görüdeki temel işlevi, girdi olarak verilen veride bulunan belirgin örüntüleri ortaya çıkarmaktır. Bu katmana girdi olarak verilen HSG'nin her bir pikseline ait spektral vektör, komşu ya da birbirine yakın olan bantları arasındaki ilintilere bağlı olarak her bir sınıf için belirleyici örüntüler ihtiva eder. Evrişimsel sinir ağlarının başarısı da bu örüntüleri tespit edebilme yeteneğinden gelmektedir.

Evrişimsel katmanda bulunan çok sayıda filtre, girdi olarak verilen verinin çeşitli niteliklerini tespit etmektedir. Birinci katmandaki filtreler, spektral vektörde ard arda gelen 5-6

bant arasındaki basit ilintileri çözümler. Bu katmanın çıktısı, filtrelerin bu ilintilere verdiği tepkilerden oluşan bir *öznitelik haritası*dır. İkinci evrişim katmanı, bu basit özniteliklerin birbiriyle olan ilintilerini inceler ve daha üst seviye öznitelikler üretir. Üst seviye bir öznitelik, alt seviye özniteliklerin kombinasyonlarından birinin permütasyonlarından biridir.

Evrişimsel katman ile ortaya çıkarılan söz konusu örüntüler, bölüm 4.2’de yapısı anlatılan derin YSA mimarisinin evrişim katmanlarının çıktısı olup sonrasında gelen TBSA katmanının öğrendiği fonksiyona girerek, ağa girdi olarak verilen verinin ait olduğu sınıfı belirleyecektir.


4.1.5 LiDAR’da EMAP ile Uzamsal Bilgi Çıkarımı

Kentsel bölgeler üzerinden alınan uzaktan algılama verilerinin sınıflandırılmasında uzamsal özniteliklerin kullanımı, başarıma önemli ölçüde etki etmektedir. Bu öznitelikler, görüntülenen bölgedeki yapıların geometrik şekilleri, boyutları ve konumları gibi oldukça faydalı bilgiler ihtiva etmektedir. Genişletilmiş Biçimsel Özellik Profilleri (Extended Morphological Attribute Profiles), matematiksel biçim algoritmaları ile çıkarılan ve söz konusu bilgileri içeren öznitelik vektörlerinin adıdır [40]. Matematiksel biçim algoritmaları, *yapısal eleman* (*structuring element*) adı verilen boyut ve şekil bilgisini kullanarak, verilen gri ölçekli (tek bant) bir görüntünün içerdiği, yapısal elemana benzer şekil ve boyuttaki yapıları parlatmak (açma–opening), baskılamak (kapama–closing), büyütme (yayma–dilation) ya da küçültme (aşındırma–erosion) için kullanılır. Bu algoritmaların LiDAR yükselti verisinde kullanılmasının sebebi, verinin tek bantlı olması nedeniyle ham halinde sınıflandırma için elverişli olmaması ancak görüntülenen bölgedeki biçimsel bilgiyi ayrıntılı şekilde içermesidir.


Önerilen yöntemde dört farklı algoritma, dört farklı şekildeki yapısal elemanın farklı boyutları ile kullanılmıştır. Uygulanan yöntemin isminde "genişletilmiş (extended)" ifadesinin kullanılmasının sebebi, çeşitli algoritmaların çeşitli yapısal elemanlarla uygulanarak çok sayıda öznitelik çıkararak –genişletilmiş– öznitelik vektörleri elde edilmesindendir. Kullanılan yapısal elemanlar şekil 4.7’de gösterilmiştir. Şekil 4.8’deki görüntüler ise, EMAP yönteminin çıktısının örnekleridir.

Yapısal elemanlar çeşitli boyutlarda üretilerek oldukça geniş özellik profilleri oluşturulmuştur. Karo ve daire şeklindeki yapısal elemanların yarıçapı ve karenin kenar uzunluğu 5’ten


50'ye kadar 5'er artırılarak toplam 10'ar karo, daire ve kare; uzunluęu 5'ten 25'e 5'er artırılarak 0, 30, 45, 60, 90, 120, 135 ve 150 derece açılarda toplam 40 çizgi yapısal eleman üretilmiştir. Üretilen yapısal elemanların toplam sayısı 70'tir. Yapısal elemanların tamamı, dört biçimsel algoritma ile kullanılmıştır. Sonuçta, LiDAR yükselti verisinden üretilen öz-nitelik vektörlerinin boyu 280 olmuştur.




Şekil 4.7: EMAP üretiminde kullanılan yapısal elemanlar: Soldan sağa doğru karo, daire, kare ve çizgi.



(a) İşlenmemiş yükselti verisi.



(b) Yarıçapı 5 piksel olan daire ile kapama işlemi sonucu.



(c) Bir kenarı 10 piksel olan kare ile açma işlemi sonucu.

Şekil 4.8: EMAP yöntemi ile elde edilen örnek sonuçlar.

4.2 Hiperspektral Veri Sınıflandırma için ESA

Sadece spektral bilgiyi kullanan 1 boyutlu evrişimsel mimarideki en kritik nokta, evrişim katmanının sayısıdır. Yapılan deneyler neticesinde 3 adet evrişim katmanı ve 1 adet tam bağlantılı katman kullanılmasına karar verilmiştir. Evrişim katmanlarındaki filtrelerin sayısı sırasıyla 16, 32 ve 64'tür. Bu filtrelerin boyutları ise sırasıyla 15, 13 ve 11'dir. Evrişim işleminin atlama boyu ise 3 katman için sırasıyla 2, 2 ve 1'dir. Her evrişimsel katmanın çıktısı, bölüm 3.5'te anlatılan katman düzgeleme yöntemi ile düzgelenmiş ve $\tanh(\cdot)$ fonksiyonuna verilmiştir. Evrişim katmanlarından sonra gelen tam bağlantılı katmanın çıktısı da katman düzgeleme ile düzgelenmiş ve sonrasında *sigmoid* fonksiyonuna verilmiştir. TBSA katmanının çıktısı ise, SoftMax regresyon ile sınıflandırılmaktadır. Önerilen bu sınıflandırıcı ESA yapısı, şematik olarak şekil 4.9'da gösterilmiştir.


4.3 LiDAR Verisi Sınıflandırma için TBSA

LiDAR sınıflandırma öncesinde yapılan öznetelik çıkarma işleminde, bölüm 4.1.5'te anlatılan EMAP vektörleri elde edilmektedir. Hiperspektral verinin aksine, EMAP vektörlerinde birbirine yakın girdiler arasında pek fazla ilinti olmamakla birlikte, vektörün bütün girdileri arasında benzer yoğunlukta ilintiler vardır. Bu sebeple, yerel ilintileri çözümleyen evrişim işleminin kullanılması gereksiz görülmüş ve derin bir TBSA mimarisine karar verilmiştir.


Yapılan deneyler neticesinde karar verilen 3 katmanlı yapının şeması, şekil 4.10'da gösterilmiştir. Ağa verilen girdinin boyu 280'dir. Her birinde 32 nöron bulunan 3 TBSA katmanının çıkışı, katman düzgeleme ile düzgelenmiş ve sonrasında da $\tanh(\cdot)$ fonksiyonuna verilmiştir. Bu 3 katmanın çıkışında SoftMax regresyon yer almaktadır. 15 birimli regresyon çıktısı, SoftMax fonksiyonu sayesinde sınıf olasılıkları olarak düşünülebilecek değerler üretmektedir. En yüksek olasılıksal değer, sınıflandırma sonucundaki sınıfı belirlemektedir.

4.4 Sınıflandırma Sonrası İşlemler

Kullanılan veri kümesinin iki ayrı tipte veri içermesi, iki ayrı sınıflandırma yapılmasını gerekli kılmıştır. İki ayrı sınıflandırma yapılması, verideki bir piksel için iki farklı karar anla-



Şekil 4.9: HSG sınıflandırma için önerilen ESA mimarisi.



Şekil 4.10: LiDAR sınıflandırma için önerilen TBSA mimarisi.

mına gelmektedir. Her bir pikselin tek bir sınıfa ait olması nedeniyle sınıflandırma sonucu elde edilen kararların birleştirilmesi gerekmektedir. Bu görevin yerine getirilmesi için önerilen yöntem, bölüm 4.4.1’de verilmiştir.

Kullanılan veri kümesindeki her bir piksel, taşıdığı spektral ve şekilsel özelliklerin yanında, komşulukları sayesinde belirli bir sınıfa ait olmasıyla ilgili olasılık bilgisini de taşımaktadır. Bu bilgi sayesinde, yanlış sınıflandırılrsa da nihayetinde düzeltilebilmektedir. Bu düzeltme işlemi için önerilen *Çoğunluk Oylaması*, bölüm 4.4.2’de verilmiştir.

4.4.1 Karar Birleştirme Yöntemi

Farklı veri tipleriyle yapılan sınıflandırma işlemlerinde, veri birleştirmenin yapıldığı üç farklı aşama vardır. Bunlar; gözlem aşamasında birleştirme (observation-level fusion), özni-telik aşamasında birleştirme (feature-level fusion) ve karar aşamasında birleştirme (decision-level fusion) şeklinde sıralanabilir [41]. Bu bölümde önerilen yöntem, karar aşamasında bir-leştirme gerçekleştirmektedir.

SoftMax Regresyon ile yapılan sınıflandırma sonucunda, hem HSG hem de LiDAR için, sı-nıflandırılan verinin sınıflara ait olma olasılıklarını içeren birer vektör elde edilir. Bu vektör-ler, n ’inci pikselin sınıflandırılması sonucunda, HSG ($\mathbf{X}$) ve LiDAR ($\mathbf{Z}$) verisi için sırasıyla denklem 4.10 ve 4.11’de tanımlandığı gibidir.

$$\mathbf{P}_n^{\mathbf{X}} = \begin{bmatrix} P(y_n = 1|\mathbf{x}_n) & P(y_n = 2|\mathbf{x}_n) & \cdots & P(y_n = 15|\mathbf{x}_n) \end{bmatrix}^T \quad (4.10)$$

$$\mathbf{P}_n^{\mathbf{Z}} = \begin{bmatrix} P(y_n = 1|\mathbf{z}_n) & P(y_n = 2|\mathbf{z}_n) & \cdots & P(y_n = 15|\mathbf{z}_n) \end{bmatrix}^T \quad (4.11)$$

Vektörlerin c ’inci elemanları, ilgili sınıflandırma sonucunda n ’inci pikselin c ’inci sınıfa ait olma olasılığı olarak kabul edilir. Dolayısıyla bu olasılıkların en büyüğü, sınıflandırılan pik-selin muhtemelen ait olduğu sınıfı gösterir ve bu sınıf aşağıdaki gibi yazılabilir:

$$y_n^{\mathbf{X}} = \arg \max_c \{P(y_n = c|\mathbf{x}_n)\}, \quad c \in \{1, 2, \cdots, 15\} \quad (4.12)$$

$$y_n^Z = \arg \max_c \{P(y_n = c | \mathbf{z}_n)\}, \quad c \in \{1, 2, \dots, 15\} \quad (4.13)$$

İki ayrı sınıflandırmaya ait bu bilgiler, önerilen *birleşik karar dağılımını* oluşturmak için kullanılır. Önerilen birleşik karar dağılımı denklem 4.14'te de verilmiştir.

$$\mathbf{P}_n^K = \begin{cases} \left[P(y_n^X | \mathbf{x}_n) + P(y_n^Z | \mathbf{z}_n) \right]^{-1} \left[P(y_n^X | \mathbf{x}_n) \mathbf{P}_n^X + P(y_n^Z | \mathbf{z}_n) \mathbf{P}_n^Z \right], & g_n = 1 \\ \frac{1}{2} \mathbf{P}_n^X + \frac{1}{2} \mathbf{P}_n^Z, & g_n = 0 \end{cases} \quad (4.14)$$

g_n , denklem 4.4'te n 'inci pikselin gölge bilgisi olarak olarak tanımlanmıştı ($g_n = 1$: gölge var, $g_n = 0$: gölge yok). Denklem 4.14'e göre karar birleştirme işlemi, aydınlık ve gölge bölgelerde farklı şekilde yapılmaktadır. Aydınlık bölgede HSG ve LiDAR sınıflandırma sonuçlarına eşit ağırlık verilirken, gölge bölgede SoftMax regresyon ile elde edilen olasılık değerleri (denklem 4.10 ve 4.11) *güvenirlik katsayısı (confidence coefficient)* olarak kullanılmıştır [42]. $g_n = 0$ iken, yani aydınlık bölgede, güvenilirlik katsayısı toplamı en yüksek olan sınıf, sınıflandırma sonucudur. Fakat gölge bölgede ($g_n = 1$ için), sınıflandırıcılardan birisi yüksek bir güvenilirlik katsayısı ile belli bir sınıfta ısrarcı olabilir. Diğer sınıflara verilen güvenilirlik katsayıları toplamı daha yüksek olsa bile, tek bir sınıflandırıcıdan alınan yüksek bir güvenilirlik katsayısı daha belirleyicidir. Örneğin bir piksel için, HSG sınıflandırıcısının verdiği güvenilirlik katsayıları 1. sınıf için 0.70, 2. sınıf için 0.30 olsun. LiDAR sınıflandırıcısının güvenilirlik katsayıları da 1. sınıf için 0.00 ve 2. sınıf için 0.50 olsun. Bu değerlerin sonucu denklem 4.14 ile hesaplandığında; aydınlık bölgede 1. sınıf için 0.35 ve 2. sınıf için 0.40 iken gölge bölgede 1. sınıf için 0.41 ve 2. sınıf için 0.38'dir. Bu durumda, sınıflandırılan piksel aydınlık bölgede ise 2. sınıfa, gölgede ise 1. sınıfa atanacaktır.


$$\mathbf{P}_n^K = \begin{bmatrix} p_{n,1}^K & p_{n,2}^K & \dots & p_{n,15}^K \end{bmatrix} \quad (4.15)$$

$$y_n = \arg \max_c \{p_{n,c}^K\}, \quad c \in \{1, 2, \dots, 15\} \quad (4.16)$$

4.4.2 Çoğunluk Oylaması ile Düzenleştirme

Piksellerin komşuluklarını kullanan *çoğunluk oylaması* (*majority voting*), sınıflandırma sonucunda yapılan azınlık hataları düzeltmeyi amaçlar. Birbirine komşu olan ya da uzamsal olarak görece yakın bulunan piksellerden oluşan bir piksel kümesi, sınıflandırma sonucunda bu kümede bulunan piksellerin en fazla sayıda aldığı sınıfın etiketini alır. Örneğin; 10 pikselin bulunduğu bir grupta, 7 adet piksel birinci sınıfın ve 3 adet piksel ikinci sınıfın etiketini almış ise, bu kümedeki 10 pikselin tamamı birinci sınıfın etiketini alır. Şekil 4.11’de soldaki resimde görüldüğü gibi sınıflandırma sonucunda 7 adet piksel yeşil, 3 adet piksel sarı renkle gösterilen sınıfa atanmıştır. Çoğunluk oylamasının dayandığı varsayıma göre, birbirine çok yakın ya da komşu olan bu piksellerin aynı sınıfa ait olması gerekmektedir. Uygulama sonrasında bütün pikseller, Şekil 4.11’de sağdaki resimdeki gibi yeşil renkle gösterilen sınıfa atanmıştır. Bu teknik HSG’ye uygulandığında; şekil 4.12a’da görülen sınıflandırma sonucu, şekil 4.12b’deki gibi düzenlenir.


Çoğunluk oylamasının en büyük dezavantajı, yanlış sınıflandırmanın çoğunluk olduğu bölgelerde hatayı artırması durumudur. Şekil 4.12a’daki haritada üst kısımda bir piksel grubunun büyük kısmı yanlış sınıflandırılmıştır. Çoğunluk oylaması neticesinde, doğru sınıflandırılmış olan az sayıdaki piksel de çoğunluk olan yanlış sınıfa atanmıştır. Bu bölgenin ayrıntıları şekil 4.13’te gösterilmiştir.



Şekil 4.11: Çoğunluk oylamasını gösteren bir örnek.




(a) Çoğunluk oylaması öncesi.



(b) Çoğunluk oylaması sonrası.

Şekil 4.12: Çoğunluk oylamasını gösteren bir örnek. Yeşiller doğru, kırmızılar yanlış sınıflandırmayı göstermektedir.



Şekil 4.13: Doğru sınıfı *ticari alan* (yeşil) olan piksellerin büyük bir kısmı *park yeri 2* (turuncu) sınıfı ile etiketlenmiş ve sınıflandırma sonucunda ticari alan etiketi alan az sayıdaki piksel de park yeri 2 etiketi ile etiketlenmiştir.

5. DENEYLER

Yapılan deneylerin anlatıldığı bu bölümde, öncelikle deneylerin yürütüldüğü donanımsal ve yazılımsal ortam kısaca belirtilmiş; ardından, HSG ve LiDAR verisinin sınıflandırıldığı çalışmalar, çıktıları ile birlikte verilmiştir. Devamında ise; bu çıktıların, daha iyi sonuçlar elde etmek için kullanıldığı karar birleştirme ve çoğunluk oylaması yöntemleri ve çıktıları verilmiştir. Son olarak, sınıflandırma için gerekli işlemlerin tamamlanmasıyla elde edilen sınıflandırma sonuçları, bölüm 2.2’de bahsedilen rakip çalışmalarla karşılaştırmalı olarak, tablo halinde verilmiştir.

5.1 Deney Kurulumu

Yapılan YSA eğitim ve test işlemleri için Python programlama dilinin 3.6.2 sürümü kullanılmıştır. Önerilen yapay sinir ağı modelleri; Google’ın geliştirdiği, 2015’te kodları açık kaynak haline getirilen, TensorFlow adı verilen makine öğrenmesi kütüphanesinin r1.4 sürümünde programlanmıştır [43]. Ham verilerin okunması, hazırlanması, ön işlemlerden geçirilmesi ve dosyalara aktarılmasında MATLAB® R2016a kullanılmıştır. Python’da yapılan eğitim ve sınıflandırma sonucu elde edilen çıktılar yine MATLAB®’a aktarılmış ve sınıflandırma sonrası işlemler de MATLAB®’da yürütülmüştür. Deneylerin yürütüldüğü bilgisayar ortamında; iki adet Intel® Xeon® E5-2620 işlemci (2.40 GHz hızında toplam 12 fiziksel çekirdek, 24 izlek), 64 GB DDR4 bellek ve 2 GB belleği bulunan nVidia® GeForce™ GTX 960 grafik işlemcisi (GPU) bulunmaktadır. Bilgisayarda bulunan ve CUDA® (Compute Unified Device Architecture) mimarisine sahip bu grafik işlemcisi sayesinde; TensorFlow kütüphanesinin, GPU üzerinde çalışarak paralel hesaplamaya olanak tanıyan CUDA® destekli sürümünden faydalanılabilmüş ve GPU üzerindeki 1024 adet CUDA® çekirdeği ile YSA deneyleri hızlandırılmıştır. Kullanılan CUDA® sürücüsünün sürüm numarası 8.0’dır.


5.2 HSG Sınıflandırma Deneyleri

Kullanılan HSG, sınıflandırma öncesinde gürültü azaltma ve gölge düzeltme gibi işlemlerden geçmektedir. Bu işlemlerin her birinin sınıflandırma başarımına etkisi tek başına %2–4 aralığında değişirken, birlikte kullanıldıklarında nihaî başarımlar tatminkâr seviyelere ulaşmaktadır. Hiç bir işlem görmemiş HSG sınıflandırıldığında başarımlar %76.90'dır. Gölge düzeltme işlemi sonucu başarımlar %80,89'a, gürültü azaltma işlemi de uygulanınca %82.45'e çıkmaktadır. Çoğunluk oylaması ile düzenlenileştirilen sınıflandırma başarımları %86.80 olmaktadır. Bu sonuçlar, sonraki başlıklarda ayrıntılı biçimde incelenmiştir.


Sınıflandırma için kullanılan model, veri çoğaltma dışında herhangi bir ön işlemden geçmemiş veri ile eğitilmiştir. Chen vd. tarafından önerilen ve detayları bölüm 4.1.1'de verilen *karişim temelli* veri çoğaltma yöntemi kullanılarak, her sınıf için ortalama 190 adet olan eğitim örneği sayısı 1000'e çıkarılmıştır [25]. Ayrıca sayısı her sınıf için ortalama 200 adet olan asıl eğitim verisinin 160 adedi eğitim ve veri çoğaltma işlemi için kullanılmış olup, geri kalan kısmı *geçerleme* amaçlı kullanılmıştır.

Eğitime başlamadan önce, ağdaki bütün ağırlıklar $N \sim (0, 0.05)$ dağılımına göre ilklendirilmiştir. Modelin eniyilenmesinde kullanılan rassal eğim düşümü algoritması için öğrenme oranı başlangıçta 0.1 olarak tanımlanmıştır. 8000 yineleme ile yapılan deneylerde 20 yinelemede bir geçerleme yapılarak eğitilen modelin başarısı takip edilmiştir. Eğitimin başlangıcında, öğrenme oranının uygunluğu nedeniyle isabet oranında hızlı bir yükseliş ve kayıp fonksiyonunda da hızlı bir düşüş görülürken, ilerleyen yinelemelerde öğrenme oranı büyük gelmiştir. Büyük öğrenme oranı, yaklaşılmak istenen en uygun nokta etrafında zikzaklar yapılmasına neden olmuştur. Bu, şekil 5.1 ve 5.2'de gösterilen grafiklerde %80 seviyelerinden sonraki aşırı değişimlerden anlaşılmaktadır. Bu durumu düzeltmek için uyarlamalı öğrenme oranı uygulanmıştır. Geçerleme yapılan yinelemelerde, isabet oranı önceden belirlenmiş değerleri aştığında öğrenme oranı, önceden belirlenmiş oranlarda küçültülmüştür. Güncelleme barajlarına göre öğrenme oranları; %85 aşıldığında $\eta = 0.05$, %90 aşıldığında $\eta = 0.01$, %93 aşıldığında $\eta = 0.001$ ve %95 aşıldığında $\eta = 0.0001$ olarak güncellenmektedir. Uyarlanan öğrenme oranlarının eğitime etkisi şekil 5.3 ve 5.4'teki grafiklerde görülmektedir. Bu grafiklerde isabet ve kayıp değerlerinin yaptığı zikzaklar, dikey kesik çizgi ile gösterilen yineleme anlarında yapılan öğrenme oranı güncellemesi sonrasında azalmaktadır. Bu şekillerde mavi noktalı çizgi, eğitim için kullanılan veri yığını ile elde edilen isabet ve kaybı


göstermektedir. Kırmızı düz çizgi ise, geçerleme için ayrılmış olan ve eğitime hiç bir etkisi olmayan veriler üzerinden hesaplanan isabet ve kaybı göstermektedir. İsabet oranı, geçerleme esnasında eğitim veri yığını ya da geçerleme veri kümesi ile yapılan sınıflandırmada, doğru sınıflandırılan piksel sayısının yığındaki toplam piksel sayısına oranıdır. Kayıp grafikleri ise bölüm 3.7’de bahsedilen ve denklem 3.13 ile verilen Kullback-Leibler uzaklığı kullanılarak elde edilmiştir.




Şekil 5.1: Sabit öğrenme oranı ile isabet oranı ($\eta = 0.1$).



Şekil 5.2: Sabit öğrenme oranı ile kayıp fonksiyonu ($\eta = 0.1$).




Şekil 5.3: Uyarlı öğrenme oranı ile isabet oranı. Öğrenme oranı değişimleri, kesik çizgi ile gösterilen yinelemelerde gerçekleşmiştir.




Şekil 5.4: Uyarlı öğrenme oranı ile kayıp fonksiyonu. Öğrenme oranı değişimleri, kesik çizgi ile gösterilen yinelemelerde gerçekleşmiştir.

5.2.1 Gölge Düzeltmenin Etkisi


Bölüm 4.1.2’de, HSG’de bulunan gölgenin veriyi zayıflattığından ve spektral imzadaki bilgiyi bozduğundan bahsedilmişti. Bu zayıflama ve bozulma, düşük sınıflandırma başarımına neden olmaktadır. Başarımı iyileştirmek için geliştirilen ve detayları bölüm 4.1.2’de verilen yöntem, önerilen HSG sınıflandırma yöntemi ile gürültüsü azaltılmış veride isabet oranını %3.83 oranında artırmaktadır. Gölge düzeltmenin, aydınlık bölgedeki sınıflandırma sonuçlarına herhangi bir etkisi olmazken; gölge bölgedeki sınıflandırma başarımını %14.39’dan %50.07’ye çıkararak bu zorlu işte %35.68’lik iyileştirme sağlamıştır. Gölge bölgedeki iyileştirme, şekil 5.5a ve 5.5b incelendiğinde görülmektedir. Şekil 5.5a’daki yanlış sınıflandırılan kırmızı işaretli bölgelerin bir kısmı, şekil 5.5b’de yeşile dönmüş, yani doğru sınıflandırılmıştır.




(a) Gölgesi düzeltilmemiş HSG sınıflandırma sonucu (%14.39).



(b) Gölgesi düzeltilmiş HSG sınıflandırma sonucu (%50.07).



(c) Gölgesi düzeltilmemiş HSG ile LiDAR birleştirme sonucu (%28.13).



(d) Gölgesi düzeltilmiş HSG ile LiDAR birleştirme sonucu (%74.87).

Şekil 5.5: Gölge düzeltme yönteminin etkileri. Yeşiller doğru, kırmızılar yanlış sınıflandırılan pikselleri göstermektedir.

Gölge içeren HSG ile yapılan sınıflandırma sonucu LiDAR ile birleştirip çoğunluk oylaması ile düzenlenileştirildiğinde gölge bölgede elde edilen sınıflandırma başarımları %28.13 iken, gölgesi düzeltilmiş HSG kullanıldığında %74.87'ye çıkarak %46.74'lük bir artış elde edilmiştir. Sonuçlar şekil 5.5c ve 5.5d'de görülmektedir. Şekil 5.5c'de kırmızı işaretli bölgelerin sayısının yeşil işaretlerden oldukça fazla olduğu görülmüyorken, gölgesi düzeltilmiş veri ile elde edilen sınıflandırma sonucu olan şekil 5.5d'de işaretli bölgelerin yarısından fazlasının yeşil işaretli, yani doğru sınıflandırılmış olduğu görülmektedir.

5.2.2 YBNF ile Gürültü Azaltmanın Etkisi

Gürültü azaltma, HSG'deki gölge bölge düzeltildikten sonraki işlemdir. Ayrıntıları bölüm 4.1.3'te verilen YBNF, sınıflandırma başarımlarının artırılmasına yardımcı olmuştur. 3 katmanlı 1 boyutlu ESA mimarisi ile kullanıldığında oldukça etkili olan YBNF ile, tek parametresi olan zamanın (nüfuz süreci) farklı miktarları için deneyler yapılmıştır. Zaman parametresinin 1, 2 ve 3 saniye değerleri için elde edilen sonuçlar tablo 5.1'de verilmiştir. Test verisi ile yapılan sınıflandırmalarda en iyi sonuç, T=2 için %83.56 olmuştur.

Tablo 5.1: YBNF'nin gölge düzeltmeli ve düzeltilmesiz kullanımlarının sonuçları.

Gölge Düzeltme	YBNF			
	Yok	T=1	T=2	T=3
Yok	%77.71	%79.37	%79.73	%79.50
Var	%81.49	%83.09	%83.56	%83.26

5.2.3 Katman Sayısının Etkisi

HSG sınıflandırma için kurulan derin ESA mimarilerinde en iyi sonuçlar 3 tek boyutlu evrişimsel ve 1 tam bağlantılı katman ile elde edilmiştir. Bu yapıya karar vermek için farklı yapılar denenmiştir. 1 boyutlu evrişim katmanları sayısı 1'den 4'e kadar değiştirilmiş ve her kurguda, ağın devamına 1 ve 2 tam bağlantılı katman eklenmiştir. Deneyler, gölgesi düzeltilmiş ve gürültüsü azaltılmış HSG üzerinde yapılmış olup her kurgu 5 kere tekrar edilmiş ve elde edilen sonuçların ortalaması alınmıştır. Yapılan deneylerin sonuçları ile LiDAR sonuçları birleştirilince tablo 5.2'deki *ortalama* isabet oranları elde edilmiştir. Sınıflandırma deneylerinde test verileri kullanılmıştır.

Tablo 5.2: Derin mimaride bulunan ESA ve TBSA katmanlarının sayısına göre ortalama isabet oranları.

	$1 \times ESA$	$2 \times ESA$	$3 \times ESA$	$4 \times ESA$
$1 \times TBSA$	%88.08	%91.29	%93.38	%92.26
$2 \times TBSA$	%86.43	%89.99	%91.99	%91.44

Evrişim katmanının, HSG’de öznitelik çıkarma işlevini yerine getirdiği, bölüm 4.1.4’te anlatılmıştı. Bu kısımda elde edilen sonuçlara bakılırsa; 3 evrişim katmanının, HSG’den spektral öznitelikleri çıkarmak için uygun olduğu düşünülebilir. Aynı zamanda evrişim katmanı, verinin boyutunu düşürme işlevine de sahiptir. 3 evrişim katmanı ile veri, spektral olarak 144 boyuttan 17 boyuta indirilirken; dördüncü katman eklendiğinde 9 boyuta düşmektedir. Bu noktadan sonra düşen sınıflandırma başarımı, verinin azalan boyutuyla birlikte bilgi kaybının da olduğunun göstergesidir.

Bir ve iki tam bağlantılı katman arasında çok büyük bir başarımlık farkı bulunmamakta, fakat tek katmanlı yapı az bir farkla daha iyi sonuç vermektedir. İkinci katman eklendiğinde eğitilmesi gereken parametre sayısı artmakta ve sınırlı miktardaki eğitim verisi bu fazla sayıdaki parametre tarafından ezberlenmektedir. Derin öğrenmenin kullanım amacının, veriyi ezberlemek yerine verinin içerdiği örüntüleri öğrenmek ve genelleştirmek olduğu göz önünde bulundurulduğunda, fazla sayıdaki tam bağlantılı ağına fayda getirmediği görülmüştür.

5.2.4 Çoğunluk Oylamasının HSG Sınıflandırmadaki Etkisi

HSG görüntü sınıflandırma sonuçları, çoğunluk oylaması ile düzenlenildiğinde barışımın arttığı gözlemlenmiştir. HSG üzerinde uygulanan ön işlemlerden sonra yapılan sınıflandırma sonucu %83.56’dır. Yani piksellerin oldukça büyük bir kısmı doğru sınıflandırılmıştır. Sınıflandırma sonucunda yanlış sınıflandırılan pikseller, doğru sınıflandırılanların yanında azınlık olarak kalmaktadır. Yanlış sınıflandırılan bu azınlık kesimin, çoğunluk olan komşuluklarına göre düzeltilebileceği öngörülmüştür. Önerilen asıl yöntemde çoğunluk oylaması ile düzenleme, HSG ve LiDAR verisi sınıflandırma sonuçlarının birleştirilmesinden sonra uygulanmaktadır. Ancak çoğunluk oylamasının, her türlü sınıflandırma sonucunu iyileştirebilen genellenebilir bir yöntem olarak kabul edilmesi için gerekli deneyler yapılmıştır. Yapılan deneyler neticesinde gölge düzeltme ve gürültü azaltmadan sonra elde edilen başarımlık %83.56 iken, çoğunluk oylaması neticesinde sınıfı düzeltilen piksellerle birlikte

başarım %87.44 olmaktadır.

5.3 LiDAR Sınıflandırma Deneyleri


LiDAR verisi, eğitim ve sınıflandırma öncesinde öznitelik çıkarma işleminden geçmektedir. Bölüm 4.1.5'te anlatılan EMAP ile elde edilen 280 boyutlu öznitelik vektörleri, başka bir işlemden geçmemekte, doğrudan eğitim ve sınıflandırma için kullanılmaktadır. LiDAR verisi için kurulan şekil 4.10'daki TBSA mimarisindeki ağırlıklar, HSG eğitimine benzer şekilde, $N \sim (0, 0.05)$ dağılımıyla ilklendirilmiştir. Eğitim, 2000 yineleme ile yapılmış ve her 10 yinelemede bir geçerleme yapılmıştır. HSG deneylerinde uygulanan uyarlamalı öğrenme oranı LiDAR için de uygulanmıştır. Öğrenme oranı başlangıçta $\eta = 0.1$ olarak seçilmiş, güncelleme barajları ve değerleri; %85 aşıldığında $\eta = 0.01$, %90 aşıldığında $\eta = 0.001$, %93 aşıldığında $\eta = 0.0001$ ve %95 aşıldığında $\eta = 0.00001$ olarak belirlenmiştir.

5.3.1 Katman Sayısının Etkisi


Önerilen asıl sınıflandırma yönteminde LiDAR verisi, 3 tam bağlantılı katmandan oluşan bir YSA yapısı ile sınıflandırılmaktadır. Bu yapıya karar vermek için 1'den 5'e kadar katman sayısı artırılmış ve her bir yapı için deneyler 10 kere tekrar edilmiştir. Bu deneylerde test verileri ile sınıflandırma yapılmış ve elde edilen sonuçlar şekil 5.6 ve 5.7'deki grafiklerde gösterilmiştir. Tablo 5.3'te, şekil 5.7'de kırmızı yuvarlaklar ile gösterilen ortalama isabet oranları verilmiştir. Bu verilerden anlaşılacağı üzere, LiDAR verisinin sınıflandırılmasında elde edilen ilk sonuçlar kayda değer biçimde değişmemekle birlikte, HSG sonuçları ile birleştirildiğinde 3 katmanlı yapının daha iyi olduğu görülmektedir. Buradan, 3 katmanlı yapının, HSG ile birleştirme esnasında algoritmaya daha faydalı bilgiler sağlayabildiği düşünülebilir. 1 ve 2 katmanlı yapı, bu bilgiyi elde edebilmek için yetersiz kalırken; 4 ve 5 katmanlı yapı, az sayıda olan eğitim verisini ezberleme yoluna gitmesi neticesinde faydalı bir bilgi sağlayamamıştır.

Tablo 5.3: LiDAR sınıflandırmada TBSA katman sayısına göre ortalama isabet oranları.

	1 × TBSA	2 × TBSA	3 × TBSA	4 × TBSA	5 × TBSA
İsabet	%92.42	%92.30	%93.15	%92.40	%91.91



Şekil 5.6: LiDAR sınıflandırma ortalama sonuçları: Çarpılar her bir deneyin sonucunu, kırmızı yuvarlaklar ve çizgiler de deneylerin ortalama başarısını göstermektedir.



Şekil 5.7: LiDAR sınıflandırmanın HSG ile birleştirme ortalama sonuçları: Çarpılar her bir deneyin sonucunu, kırmızı yuvarlaklar ve çizgiler de deneylerin ortalama başarısını göstermektedir.

5.3.2 Uzamsal Bilgi Çıkarma Yönteminin Etkisi

LiDAR verisi sınıflandırmada yükselti bilgisinin kullanıldığından, ve ayrıca bölüm 4.1.5'te yükseklik bilgisinin tek bantlı bir veri olması sebebiyle sınıflandırma için tek başına uygun olmadığından bahsedilmişti. Bölüm 4.1.5'te anlatılan yöntem kullanılarak elde edilen EMAP vektörleri oldukça büyük boyutludur (280). Uzaktan algılama uygulamalarında etiketli verilerin kısıtlı miktarda olması, sınıflandırma problemlerinde önemli bir sorundur ve verilerin yüksek boyutta olması bu sorunu daha ciddi bir hale getirmektedir ve bu duruma *Boyutsallık belası (curse of dimensionality)* denmektedir [44, 45].

Bölüm 4.1.5'te anlatılan öznitelik çıkarma yöntemi ile elde edilen özniteliklerin çeşitliliği ve bölüm 4.4.1'de karar birleştirme amaçlı önerilen denklem 4.14, söz konusu olumsuzlukları tersine çevirmektedir. LiDAR verisinin EMAP kullanılarak tek başına sınıflandırılmasıyla elde edilen sonuçlar (şekil 5.6, en yüksek %62), Aytaylan vd. tarafından elde edilen sonuçlarla karşılaştırıldığında (%73.73) geride kalmaktadır [30]. Fakat sonuçlar HSG sonuçları ile denklem 4.14 kullanılarak birleştirildiğinde, şekil 5.7'de görüldüğü gibi oldukça rekabetçi sonuçlar elde edilmiştir. Buradan, dört çeşit yapısal eleman ve dört çeşit biçim algoritması kullanarak birleştirme yöntemine yararlı bilgiler aktarıldığı çıkarılabilir.

5.4 Karar Birleştirme Yönteminin Etkisi


Tezde önerilen sınıflandırma yönteminin en önemli aşamalarından birisi, kararların birleştirildiği aşamadır. Aynı sınıflandırıcılar ile sınıflandırılan HSG ve LiDAR verisinin sonuçların birleştirilmesinde, ağların sonunda bulunan SoftMax regresyonun sağladığı bilgi kullanılmıştır. Bu bilgi, her bir pikselin sınıflandırılması sonucunda bir *güvenirlik* değeri vermektedir ve yaptığı sınıflandırmada daha "kararlı" olan (güvenirlik değeri yüksek) sınıflandırıcının verdiği karar baskın gelmektedir. Yöntemin başarımı, harita üzerinde farklı bölgelerde değerlendirilmiştir. İncelenen bölgeler beyaz çemberler ile şekil 5.8'deki harita üzerinde gösterilmiştir.

Sınıflandırma sonucu elde edilen şekil 5.8'deki haritada gösterilen birinci bölge (soldaki beyaz çember) incelendiğinde, şekil 5.9'daki görsele göre burada HSG sınıflandırma sonucunun baskın geldiği görülmektedir. Yeşil ve kırmızı işaretlerin parlaklığı, regresyon sonu-



Şekil 5.8: Karar birleştirme sonucu elde edilen doğru/yanlış haritası. Yeşil renk doğru sınıflandırmayı, kırmızı renk yanlış sınıflandırmayı göstermektedir. İncelenen bölgeler; soldan sağa doğru 1, 2 ve 3 numaralı bölge olarak ifade edilmiştir.

cunda SoftMax fonksiyonu ile elde edilen güvenilirlik değeriyle artmaktadır. Şekil 5.9d’de verilen ve %0–%100 aralığına ölçeklendirilen renk göstergesi, güvenilirlik değerinin anlaşılmasına yardımcı olabilir. Şekil 5.9’a bakılacak olursa, HSG sınıflandırma sonucunda yeşil rengin kırmızıya göre oldukça parlak olduğu görülmektedir. Yeşil renkle gösterilen bölgede en düşük güvenilirlik değeri %98 iken, LiDAR sınıflandırma sonucunda yanlış sınıflandırılmış kırmızı bölgelerde en yüksek güvenilirlik değeri %96 olmakla birlikte, bu değer %30’lara kadar düşmüştür. Burada, kesin sonuç veren HSG sınıflandırıcısı, daha kararsız sonuçlar veren LiDAR sınıflandırıcısına baskın gelmiştir.




Şekil 5.9: İncelenen birinci bölgenin yakınlaştırılmış görüntüleri. HSG sınıflandırma sonucu (a) ile LiDAR sınıflandırma sonucunun (b) birleştirilmesi sonucunda c’de gösterilen sınıflandırma elde edilmiştir. (Yeşil: doğru, Kırmızı: yanlış)

İkinci bölge incelenecek olursa, gölge etkisinde bulunan bu bölgede LiDAR sonucunun baskın geldiği görülecektir. Şekil 5.10’daki sonuçlar incelenecek olursa, bu görsellerde en üstte bulunan piksel grubunun, HSG ile kararsız bir şekilde yanlış (koyu kırmızı), LiDAR ile kararsız bir şekilde doğru (koyu yeşil) sınıflandırıldığı görülmektedir. Bu bölgede HSG’nin güvenilirlik değeri %42 ile %59 arasında değişirken, LiDAR’ın güvenilirlik değeri %56 ile %75 arasında değişmekte ve HSG’ye baskın gelmektedir.

Üçüncü bölgedeki doğru ama güvenilirlik değeri düşük HSG sonucu ile yanlış ve güvenilirlik



Şekil 5.10: İncelenen ikinci bölgenin yakınlaştırılmış görüntüleri. HSG sınıflandırma sonucu (a) ile LiDAR sınıflandırma sonucunun (b) birleştirilmesi sonucunda c’de gösterilen sınıflandırma elde edilmiştir. (Yeşil: doğru, Kırmızı: yanlış)



Şekil 5.11: İncelenen üçüncü bölgenin yakınlaştırılmış görüntüleri. HSG sınıflandırma sonucu (a) ile LiDAR sınıflandırma sonucunun (b) birleştirilmesi sonucunda c’de gösterilen sınıflandırma elde edilmiştir. (Yeşil: doğru, Kırmızı: yanlış)

değeri yüksek LiDAR sonucu birleştirildiğinde, yanlış bir sınıflandırma elde edilmiştir. Şekil 5.11’de HSG en düşük %92 güvenilirlik değeri ile yanlış sınıflandırma yaparken, LiDAR doğru sınıflandırma ile en yüksek %75 güvenilirlik değeri sağlayabilmiş ve karar birleştirme neticesinde pikseller yanlış sınıflandırılmıştır.

5.5 Çoğunluk Oylamasının Etkisi

HSG ve LiDAR verisi sınıflandırma görevinin son aşaması çoğunluk oylamasıdır. Bu aşamaya kadar yapılan işlemlerde, %89.12 oranında isabetli sınıflandırma başarısı elde edilmiştir. Verinin yanlış sınıflandırılmış %10.88’lik kısmının, bulundukları yerde azınlık olacak şekilde uzamsal olarak dağılmış olabileceği göz önüne alınarak isabet oranını önemli ölçüde artıracak tahmin edilmiştir. Yanlış sınıflandırılmış olan piksellerin belirli bölgelerde yoğunluk olacak şekilde yoğunlaşması durumunda başarının düşmesi ihtimali bulunsada, olumlu etki yapması ihtimali daha yüksektir. Çoğunluk oylaması sonucunda isabet oranında

%4.76 artışla %93.88 başarı elde edilmiştir.

5.6 Karşılaştırmalar

Tez kapsamında yapılan çalışmalarda elde edilen en iyi sınıflandırma başarısı (genel isabet oranı) %93.88 olmuştur. Tablo 5.4'te, bu değerin rakip yöntemlerle karşılaştırılması verilmiştir. Elde edilen başarı, Liao vd. ile Luo vd. tarafından yapılan çalışmaların gerisinde kalmıştır. Bu çalışmalar incelendiğinde; LiDAR verisinin yanısıra HSG'den de biçimsel özellik profilleri çıkarıldığı görülmüştür ve başarılarının buna bağlı olduğu düşünülmektedir. Luo vd. tarafından yapılan çalışmada ayrıca; gölge bölgeden, etiket bilgisi kullanılmadan HSG için eğitim verisi seçilmektedir. Bu sayede gölge bölge içinde %81.15 gibi oldukça yüksek bir sınıflandırma başarısı elde etmişlerdir.

Tablo 5.4'te sınıf başarıları incelendiğinde, önerilen derin öğrenme mimarileri ve karar birleştirme stratejisinin, belirli sınıfları üstün derecede ayırabildiği görülmektedir. 6 tane sınıfı (3, 5, 6, 7, 14 ve 15) %100 başarıyla sınıflandıran yöntem; 8, 10 ve 13. sınıflarda rakip çalışmaların bir kısmının başarısının altında kalmıştır. Tablo 5.7 incelendiğinde, 10 ve 13. sınıflardaki düşük başarının sebebinin, bu sınıfların gölge bölgede doğru sınıflandırılması olduğu görülmektedir. Tabloda numaralar ile gösterilen sınıflara karşılık gelen sınıf isimleri, etiketli veri sayısı ile birlikte tablo 1.1'de verilmiştir.

Tablo 5.4: Sınıflandırma sonuçlarının rakip yöntemlerle karşılaştırılması.

	dSVM MRF [27]	GBFF CNN [28]	dSVM α KRA [30]	MLRsub MRF [31]	OTCVA RF [32]	GGF SVM [33]	MFC SVM [34]	ESA-TBSA Denklemler 4.14
#1	%83.1	%78.7	%83.1	%83.1	%80.6	%82.9	%97.3	%92.2
#2	%91.4	%94.9	%85.2	%83.1	%99.6	%99.3	%97.0	%98.5
#3	%99.8	%100.0	%100.0	%100.0	%100.0	%100.0	%100.0	%100.0
#4	%97.3	%99.3	%98.8	%95.9	%96.0	%99.3	%97.4	%92.7
#5	%100.0	%99.6	%100.0	%100.0	%99.4	%100.0	%99.8	%100.0
#6	%90.9	%95.8	%91.6	%95.8	%95.8	%95.1	%95.8	%100.0
#7	%91.0	%87.9	%88.6	%84.8	%86.0	%90.9	%97.4	%100.0
#8	%78.2	%95.2	%91.5	%83.6	%93.5	%95.6	%91.5	%85.6
#9	%94.6	%89.7	%96.0	%96.5	%97.1	%89.3	%93.9	%96.5
#10	%66.2	%81.2	%85.3	%86.8	%68.5	%92.8	%90.1	%75.2
#11	%93.5	%86.3	%90.4	%99.7	%98.9	%96.6	%98.6	%96.9
#12	%93.7	%92.7	%92.6	%99.8	%100.0	%91.9	%97.7	%93.8
#13	%87.7	%87.0	%70.5	%85.3	%74.7	%74.4	%82.5	%90.2
#14	%98.4	%99.2	%100.0	%100.0	%100.0	%100.0	%100.0	%100.0
#15	%96.6	%89.6	%99.4	%98.7	%100.0	%98.7	%98.7	%100.0
Ortalama İisabet	%91.0	%91.8	%91.5	%92.9	%92.7	%93.8	%95.6	%94.8
Genel İisabet	%89.9	%91.0	%91.5	%92.0	%92.4	%94.0	%95.9	%93.9
κ	0.89	0.90	0.91	0.91	0.92	0.93	0.96	0.93

Tablo 5.5: Karışıklık matrisi: Tüm haritada sınıflandırma sonucu. Değerler yüzde cinsindendir.

	#1	#2	#3	#4	#5	#6	#7	#8	#9	#10	#11	#12	#13	#14	#15
#1	92.2	0.0	0.0	7.8	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#2	1.5	98.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#3	0.0	0.0	100.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#4	5.8	0.0	0.0	92.7	0.0	0.0	1.5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#5	0.0	0.0	0.0	0.0	100.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#6	0.0	0.0	0.0	0.0	0.0	100.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#7	0.0	0.0	0.0	0.0	0.0	0.0	100.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#8	0.0	0.0	0.0	0.0	0.0	0.0	3.7	85.6	0.0	0.0	0.0	0.0	6.3	4.5	0.0
#9	0.0	0.0	0.0	0.0	2.0	0.0	0.0	0.0	96.5	0.0	1.4	0.1	0.0	0.0	0.0
#10	0.0	0.0	0.0	0.0	0.0	0.0	24.8	0.0	0.0	75.2	0.0	0.0	0.0	0.0	0.0
#11	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	3.1	96.9	0.0	0.0	0.0	0.0
#12	0.0	0.0	0.0	0.0	0.0	0.0	6.2	0.0	0.0	0.0	0.0	93.8	0.0	0.0	0.0
#13	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	2.8	90.2	7.0	0.0
#14	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	100.0	0.0
#15	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	100.0

Tablo 5.6: Karışıklık matrisi: Aydınlık bölgede sınıflandırma sonucu. Değerler yüzde cinsindendir.

	#1	#2	#3	#4	#5	#6	#7	#8	#9	#10	#11	#12	#13	#14	#15
#1	100.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#2	1.9	98.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#3	0.0	0.0	100.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#4	6.2	0.0	0.0	92.2	0.0	0.0	1.6	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#5	0.0	0.0	0.0	0.0	100.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#6	0.0	0.0	0.0	0.0	0.0	100.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#7	0.0	0.0	0.0	0.0	0.0	0.0	100.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#8	0.0	0.0	0.0	0.0	0.0	0.0	6.3	79.7	0.0	0.0	0.0	0.0	10.7	3.3	0.0
#9	0.0	0.0	0.0	0.0	2.0	0.0	0.0	0.0	96.4	0.0	1.5	0.1	0.0	0.0	0.0
#10	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	100.0	0.0	0.0	0.0	0.0	0.0
#11	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	3.8	96.2	0.0	0.0	0.0	0.0
#12	0.0	0.0	0.0	0.0	0.0	0.0	6.2	0.0	0.0	0.0	0.0	93.8	0.0	0.0	0.0
#13	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	3.0	97.0	0.0	0.0
#14	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	100.0	0.0
#15	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	100.0

Tablo 5.7: Karışıklık matrisi: Gölge bölgede sınıflandırma sonucu. Değerler yüzde cinsindendir.

	#1	#2	#3	#4	#5	#6	#7	#8	#9	#10	#11	#12	#13	#14	#15
#1	53.9	0.0	0.0	46.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#2	0.0	100.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#4	0.0	0.0	0.0	100.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#6	0.0	0.0	0.0	0.0	0.0	100.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#7	0.0	0.0	0.0	0.0	0.0	0.0	100.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
#8	0.0	0.0	0.0	0.0	0.0	0.0	0.0	93.8	0.0	0.0	0.0	0.0	0.0	6.2	0.0
#9	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	100.0	0.0	0.0	0.0	0.0	0.0	0.0
#10	0.0	0.0	0.0	0.0	0.0	0.0	78.8	0.0	0.0	21.2	0.0	0.0	0.0	0.0	0.0
#11	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	100.0	0.0	0.0	0.0	0.0
#13	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	100.0	0.0

6. SONUÇLAR

Bu tezde, HSG ve LiDAR verilerinin sınıflandırılması için yapay sinir ağı modelleri önerilmiştir. Önerilen bu modellerin yanında, ham veri üzerinde ön işlem olarak uygulanmak üzere düzeltme yöntemi ve ard işlem olarak sınıflandırma sonuçlarını birleştiren bir yöntem de tezde önerilen yardımcı yöntemlerdir. Önerilen yöntemler, farklı tipteki iki verinin güçlü yanlarını birleştirirken diğer taraftan da birbirlerinin eksiklerini kapatmalarına yöneliktir. Örneğin; yüzey materyallerinin ayırt edici özellikleri HSG’de bulunurken, LiDAR verisinin sağladığı yükseklik bilgisi, aynı rakımda bulunan farklı materyalleri ayırt edememektedir. Öte yandan hiperspektral görüntünün gölge altında kalan bölgesinde materyal bilgisi bozulmuştur ve LiDAR verisinin sağladığı yansıma parlaklığı verisi ile düzeltme yapılarak doğru bilgi geri getirilmeye çalışılmıştır. LiDAR verisinin sağladığı yükseklik bilgisi de, içerdiği biçimsel ve konumsal bilgi sayesinde, çeşitli bozulma ve yanlış sınıflandırmaları düzeltmekte katkı sağlamıştır.

İşlenmemiş HSG ile yapılan sınıflandırma deneylerinde, HSG sınıflandırmada kullanılacak olan YSA modeli için en uygun ağ ve eğitim parametreleri belirlenmeye çalışılmıştır. Bu ağ ve eğitim parametreleri kabaca; katman çeşidi ve sayısı, nöron sayısı, eğitim yineleme sayısı ve öğrenme oranıdır. Bu deneylerde elde edilen en yüksek sınıflandırma başarımları incelendiğinde, görüntünün aydınlık bölgesinde bulunan piksellerin neredeyse tamamının doğru sınıflandırıldığı ve gölge altında kalan piksellerin de neredeyse tamamının yanlış sınıflandırıldığı gözlemlenmiştir. Bölüm 4.1.3’de anlatılan YBNF kullanıldığında sınıflandırma başarımları %2 civarında iyileşmiş fakat gölge bölgede bir iyileşme görülmemiştir.

Test piksellerinin %12.6’sının gölge altında bulunduğu göz önünde alınarak, burada yapılacak iyileştirmelerin genel sınıflandırma başarımına önemli ölçüde katkı yapacağı düşünülmüştür. Bu bağlamda önerilen ve bölüm 4.1.2’de anlatılan gölge düzeltme yöntemi, tahmin edildiği gibi gölge bölgedeki sınıflandırma başarımında ciddi bir iyileşme sağlamıştır. Gölge kısımla ilgili yapılan deneylerde; gölgenin spektral bilgiyi önemli derecede bozduğu, fakat bozulan bilginin LiDAR verisi ile kısmen de olsa düzeltilebildiği gösterilmiştir.

Gölgesi düzeltilmiş HSG verisinin sınıflandırılması sonucu elde edilen başarımlar, LiDAR ve-

risinin sağladığı yükseklik bilgisi daha da iyileştirilmiştir. LiDAR verisinin içerdiği biçimsel özellikler, bölüm 4.1.5'te anlatılan EMAP yöntemi ile çıkarılmış ve sınıflandırılmıştır. Sınıflandırıcının geliştirilmesi süreci, HSG için tasarlanan sınıflandırıcının geliştirme sürecine benzer bir şekilde ilerlemiştir. Önerilen model; yapılan deneylerde EMAP kullanılarak çıkarılan çok sayıda özneteliğin sağladığı %60 seviyelerinde sınıflandırma ile rakip yöntemlerin LiDAR sınıflandırma sonuçlarının gerisinde kalmış olsa da, HSG sınıflandırma sonuçları ile birleştirildiğinde rakiplerin başarılarının üzerine çıkılmasına büyük katkı sağlamıştır. HSG ve LiDAR sınıflandırma sonucu elde edilen olasılıksal çıktılar incelendiğinde, LiDAR sınıflandırma sonuçlarının HSG sınıflandırma sonuçlarına göre daha kararsız bir yapıya sahip olduğu görülmüştür. Karar aşamasında genel olarak iki sınıflandırma sonucuna eşit ağırlık verilmiş ve yüksek olasılık değeri veren sınıflandırıcı, sonucu tayin etmiştir. Fakat gölge bölgede karar kriteri, olasılıksal değerlerden çok, bu değerlerin farklı sınıflara dağılım biçimiyle belirlenmiştir. Bölüm 4.4.1'de önerilen denklem 4.14 ile sınıflandırıcıların kararsızlıkları değerlendirilmiş ve yüksek olasılık değeri veren sınıflandırıcı değil, daha az çelişkide kalan sınıflandırıcı baskın gelmiştir. Bu bölümde yapılan deneyler, HSG ve LiDAR verisinin oldukça güçlü bir ikili olduğunu ve bir verideki bozulmanın diğeri ile düzeltilebileceğini göstermiştir.

Tez kapsamında yapılan çalışmalarda isabet oranı her adımda artmaktadır. HSG hiç bir işlem görmeden sınıflandırıldığında isabet oranı %77.71 olmaktadır. HSG'deki gölgenin önerilen yöntemle düzeltildikten sonra yapılan sınıflandırmada isabet oranı %81.49'dur. Gölgesi düzeltilmiş HSG'nin içerdiği gürültü, YBNF ile azaltılmış ve isabet oranı %83.56'ya çıkmıştır. LiDAR verisinden EMAP ile elde edilen özneteliklerin sınıflandırma sonucu %56.87'dir. Önerilen karar birleştirme yöntemi sayesinde LiDAR verisi, kendi başına oldukça düşük bir isabet oranıyla sınıflandırılmış olmasına rağmen, genel başarıma oldukça önemli katkı sağlamış ve HSG sonucu ile birleştirildiğinde isabet oranını %89.12'ye çıkarmıştır. Karar birleştirme ile elde edilen sınıflandırma sonucu, çoğunluk oylaması ile düzenlenleştirilmiş ve nihai sınıflandırma başarımı %93.88 olmuştur.

Tezin literatüre yaptığı katkılar kısaca özetlenecek olursa, sınıflandırıcı olarak tercih edilen derin sinir ağlarının etkin performansı en başta sayılabilir. Rakip yöntemlerde de görüldüğü üzere 3 ya da 4 katmanlı sinir ağları, uzaktan algılama verilerinin sınıflandırılması için genellikle en iyi sonuçları vermektedir. Ağların sonunda bulunan SoftMax regresyon, farklı tipteki verilerin sınıflandırılma sonuçlarının birleştirilmesi için oldukça faydalı olasılıksal

bilgiler sağlamaktadır. Bu tezde önerilen gölge düzeltme yöntemi, varsayımlara dayanılarak geliştirilmiştir ve genellenebilirliği test edilmemiştir. Kullanılan veri kümesindeki gölgeyi düzeltmek için kullanılan yöntem, önemli bir iyileştirme sağlayarak; gölgenin HSG’de ciddi bilgi kayıplarına yol açtığını ispatlamış ve gölge sebebiyle kaybolan bilginin LiDAR verisi sayesinde geri kazanılabileceğini göstermiştir.



KAYNAKLAR

- [1] J. B. Campbell, *Introduction to Remote Sensing*. The Guilford Press, 3 ed., **2002**.
- [2] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern Classification*. Wiley-Interscience, 2 ed., **2001**.
- [3] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, **2016**. <http://www.deeplearningbook.org>.
- [4] P. Ghamisi, J. Plaza, Y. Chen, J. Li, and A. J. Plaza, "Advanced spectral classifiers for hyperspectral images: A review," *IEEE Geoscience and Remote Sensing Magazine*, vol. 5, pp. 8–32, March **2017**.
- [5] "2013 ieee grss data fusion contest, <http://www.grss-ieee.org/community/technical-committees/data-fusion/2013-ieee-grss-data-fusion-contest/>," **2013**.
- [6] R. Dechter, "Learning while searching in constraint-satisfaction-problems.," in *Proceedings of the 5th National Conference on Artificial Intelligence*, pp. 178–185, January **1986**.
- [7] Y. Bengio, A. Courville, and P. Vincent, "Representation learning: A review and new perspectives," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 35, pp. 1798–1828, August **2013**.
- [8] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, pp. 436–444, May **2013**.
- [9] F. Rosenblatt, "The perceptron: A probabilistic model for information storage and organization in the brain," *Psychological Review*, vol. 65, no. 6, pp. 386–408, **1958**.
- [10] D. H. Hubel and T. N. Wiesel, "Receptive fields, binocular interaction and functional architecture in the cat's visual cortex," *The Journal of Physiology*, vol. 160, pp. 106–154, **1962**.
- [11] K. Fukushima, "Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position," *Biological Cybernetics*, vol. 36, pp. 193–202, April **1980**.
- [12] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Parallel distributed processing: Explorations in the microstructure of cognition, vol. 1," ch. Learning Internal Representations by Error Propagation, pp. 318–362, Cambridge, MA, USA: MIT Press, **1986**.

- [13] Y. LeCun, B. Boser, J. S. Denker, R. E. Howard, W. Hubbard, L. D. Jackel, and D. Henderson, "Handwritten digit recognition with a back-propagation network," in *Advances in Neural Information Processing Systems 2*, pp. 396–404, **1990**.
- [14] G. E. Hinton, S. Osindero, and Y.-W. Teh, "A fast learning algorithm for deep belief nets," *Neural Computation*, vol. 18, pp. 1527–1554, July **1990**.
- [15] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in *Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1*, pp. 1097–1105, **2012**.
- [16] O. Abdel-Hamid, A.-R. Mohamed, H. Jiang, L. Deng, G. Penn, and D. Yu, "Convolutional neural networks for speech recognition," *IEEE/ACM Transactions on Audio, Speech and Language Processing*, vol. 22, pp. 1533–1545, October **2014**.
- [17] W. Hu, Y. Huang, L. Wei, F. Zhang, and H. Li, "Deep convolutional neural networks for hyperspectral image classification," *Journal of Sensors*, vol. 2015, January **2015**.
- [18] Y. Chen, X. Zhao, and X. Jia, "Spectral–spatial classification of hyperspectral data based on deep belief network," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 8, pp. 2381–2392, June **2015**.
- [19] V. Slavkovikj, S. Verstockett, W. D. Neve, S. V. Hoecke, and R. V. de Walle, "Hyperspectral image classification with convolutional neural networks," in *Proceedings of the 23rd ACM international conference on Multimedia*, pp. 1159–1162, October **2015**.
- [20] C. Tao, H. Pan, Y. Li, and Z. Zou, "Unsupervised spectral–spatial feature learning with stacked sparse autoencoder for hyperspectral imagery classification," *IEEE Geoscience and Remote Sensing Letters*, vol. 12, pp. 2438–2442, December **2015**.
- [21] M. Salman and S. E. Yüksel, "Hyperspectral data classification using deep convolutional neural networks," in *Proceedings of Signal Processing and Communication Application Conference (SIU), 2016 24th*, May **2016**.
- [22] H. Lee and H. Kwon, "Contextual deep cnn based hyperspectral classification," in *Proceedings of 2016 IEEE International Geoscience and Remote Sensing Symposium*, pp. 2153–2003, July **2016**.
- [23] W. Zhao and S. Du, "Spectral–spatial feature extraction for hyperspectral image classification: A dimension reduction and deep learning approach," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 54, pp. 4544–4554, August **2016**.
- [24] P. Ghamisi, Y. Chen, and X. X. Zhu, "A self-improving convolution neural network for the classification of hyperspectral data," *IEEE Geoscience and Remote Sensing Letters*, vol. 13, pp. 1537–1541, October **2010**.
- [25] Y. Chen, H. Jiang, C. Li, X. Jia, and P. Ghamisi, "Deep feature extraction and classification of hyperspectral images based on convolutional neural networks," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 54, pp. 6232–6251, **2016**.

- [26] C. Debes, A. Merentitis, R. Heremans, J. Hahn, N. Frangiadakis, T. van Kasteren, W. Liao, R. Bellens, A. Pižurica, S. Gautama, W. Philips, S. Prasad, Q. Du, and F. Pacifici, “An analysis of shadow effects on spectral vegetation indexes using a ground-based imaging spectrometer,” *IEEE Geoscience and Remote Sensing Letters*, vol. 12, no. 11, pp. 2188–2192, **2015**.
- [27] H. Aytaylan and S. E. Yüksel, “Semantic segmentation of hyperspectral images with the fusion of lidar data,” in *Proceedings of 2016 IEEE International Geoscience and Remote Sensing Symposium*, pp. 2522–2525, Jul **2016**.
- [28] P. Ghamisi, B. Höfle, and X. X. Zhu, “Hyperspectral and lidar data fusion using extinction profiles and deep convolutional neural network,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 10, pp. 3011–3024, June **2017**.
- [29] Y. Chen, C. Li, P. Ghamisi, X. Jia, and Y. Gu, “Deep fusion of remote sensing data for accurate classification,” *IEEE Geoscience and Remote Sensing Letters*, vol. 14, pp. 1253–1257, August **2017**.
- [30] H. Aytaylan, “Hiperspektral görüntüler ile lidar verisinin koşullu rastgele alanlar yöntemi ile birleştirilmesi ve sınıflandırılması,” Master’s thesis, Hacettepe Üniversitesi, Ankara, Türkiye, **2017**.
- [31] M. Khodadadzadeh, J. Li, S. Prasad, and A. Plaza, “Fusion of hyperspectral and lidar remote sensing data using multiple feature learning,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 8, no. 6, pp. 2971–2983, **2015**.
- [32] B. Rasti, P. Ghamisi, and R. Gloaguen, “Hyperspectral and lidar fusion using extinction profiles and total variation component analysis,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 55, pp. 3997–4007, July **2017**.
- [33] W. Liao, A. Pižurica, R. Bellens, S. Gautama, and W. Philips, “Generalized graph-based fusion of hyperspectral and lidar data using morphological features,” *IEEE Geoscience and Remote Sensing Letters*, vol. 12, pp. 552–556, March **2015**.
- [34] R. Luo, W. Liao, H. Zhang, L. Zhang, P. Scheunders, Y. Pi, and W. Philips, “Fusion of hyperspectral and lidar data for classification of cloud-shadow mixed remote sensed scene,” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 10, no. 8, pp. 3768–3781, **2017**.
- [35] S. Ioffe and C. Szegedy, “Batch normalization: Accelerating deep network training by reducing internal covariate shift,” *Proceedings of The 32nd International Conference on Machine Learning*, **2015**.
- [36] J. Ba, R. Kiros, and G. E. Hinton, “Layer normalization,” *Computing Research Repository*, **2016**.

- [37] E. Alpaydm, *Introduction to Machine Learning*. The MIT Press, 3 ed., **2014**.
- [38] L. Zhang, X. Sun, T. Wu, and H. Zhang, “An analysis of shadow effects on spectral vegetation indexes using a ground-based imaging spectrometer,” *IEEE Geoscience and Remote Sensing Letters*, vol. 12, no. 11, pp. 2188–2192, **2015**.
- [39] P. Perona and J. Malik, “Scale-space and edge detection using anisotropic diffusion,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 12, no. 7, pp. 629–639, **1990**.
- [40] M. D. Mura, A. Villa, J. A. Benediktsson, J. Chanussot, and L. Bruzzone, “Classification of hyperspectral images by using extended morphological attribute profiles and independent component analysis,” *IEEE Geoscience and Remote Sensing Letters*, vol. 8, pp. 542–546, May **2011**.
- [41] M. Schmitt and X. X. Zhu, “Data fusion and remote sensing: An ever-growing relationship,” *IEEE Geoscience and Remote Sensing Magazine*, vol. 4, no. 4, pp. 6–23, **2016**.
- [42] H. Zaragoza and F. d’Alché Buc, “Confidence measures for neural network classifiers,” in *Proceedings of the Seventh Int. Conf. Information Processing and Management of Uncertainty in Knowledge-Based Systems (IPMU)*, pp. 886–893, January **1998**.
- [43] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin, S. Ghemawat, I. Goodfellow, A. Harp, G. Irving, M. Isard, Y. Jia, R. Jozefowicz, L. Kaiser, M. Kudlur, J. Levenberg, D. Mané, R. Monga, S. Moore, D. Murray, C. Olah, M. Schuster, J. Shlens, B. Steiner, I. Sutskever, K. Talwar, P. Tucker, V. Vanhoucke, V. Vasudevan, F. Viégas, O. Vinyals, P. Warden, M. Wattenberg, M. Wicke, Y. Yu, and X. Zheng, “TensorFlow: Large-scale machine learning on heterogeneous systems,” **2015**. <https://www.tensorflow.org/>.
- [44] G. F. Hughes, “On the mean accuracy of statistical pattern recognizers,” *IEEE Transactions on Information Theory*, vol. 14, no. 1, pp. 55–63, **1968**.
- [45] J. H. Friedman, “On bias, variance, 0/1—loss, and the curse-of-dimensionality,” *Data Mining and Knowledge Discovery*, vol. 1, no. 1, pp. 55–77, **1997**.

ÖZGEÇMİŞ

Kimlik Bilgileri

Adı Soyadı: Hüseyin Emre MUTLU

Doğum Yeri: Bucak, Burdur, Türkiye

Medeni Hali: Bekar

E-Posta: emre.mutlu@hacettepe.edu.tr

Adresi: Hacettepe Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü Beytepe Yerleşkesi 06800 Ankara / Türkiye

Eğitim

Lise: Burdur Bucak Anadolu Lisesi - 2007

Lisans: Hacettepe Üniversitesi - 2014

Y. Lisans: Hacettepe Üniversitesi - 2018

Yabancı Dil ve Düzeyi

İngilizce: İleri

İş Deneyimi

Kasım 2016 - Devam Ediyor Hacettepe Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü Araştırma Görevlisi

Eylül 2015 - Kasım 2016 Hacettepe Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü Proje Araştırmacısı

Deneyim Alanları

İşaret ve Görüntü İşleme

Makine Öğrenmesi

Uzaktan Algılama

Algoritma Geliştirme

Tezden Üretilmiş Projeler ve Bütçesi

-

Tezden Üretilmiş Yayınlar

H. E. Mutlu and S. E. Yüksel, “Hyperspectral image classification via Support Vector Data Description,” in Proceedings of Signal Processing and Communication Application Conference (SIU), 2016 24th, May 2016.

Tezden Üretilmiş Tebliğ ve Poster Sunumu ile Katıldığı Toplantılar



HACETTEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS/DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU

HACETTEPE ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ
ELEKTRİK VE ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI BAŞKANLIĞI'NA

Tarih: 03/01/2018

Tez Başlığı / Konusu: Hiperspektral Görüntü ve LiDAR Verisinin Derin Öğrenme ile Sınıflandırılması

Yukarıda başlığı/konusu gösterilen tez çalışmamın a) Kapak sayfası, b) Giriş, c) Ana bölümler d) Sonuç kısımlarından oluşan toplam 68 sayfalık kısmına ilişkin, 03/01/2018 tarihinde şahsım/tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 2 'dir.

Uygulanan filtrelemeler:

- 1- Kaynakça hariç
- 2- Alıntılar hariç/dâhil
- 3- 5 kelimedenden daha az örtüşme içeren metin kısımları hariç

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü Tez Çalışması Orjinallik Raporu Alınması ve Kullanılması Uygulama Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini saygılarımla arz ederim.

Tarih ve İmza

Adı Soyadı: Hüseyin Emre Mutlu
Öğrenci No: N14226918
Anabilim Dalı: Elektrik ve Elektronik Mühendisliği
Programı: Elektrik ve Elektronik Mühendisliği - Yüksek Lisans
Statüsü: ☒ Y.Lisans ☐ Doktora ☐ Bütünleşik Dr.

03/01/2018

DANIŞMAN ONAYI

UYGUNDUR.

Yrd. Doç. Dr. Seniha Esen Yüksel

(Unvan, Ad Soyad, İmza)