

**HİPERSPEKTRAL VE LİDAR VERİLERİNİN ÖZNETELİK VE
KARAR SEVİYELERİNDE TÖMLEŐTİRİLMESİ VE DERİN
EVRIŐİMLİ SİNİR AĐLARIYLA SINIFLANDIRILMASI**

**FUSION OF HYPERSPECTRAL AND LİDAR DATASETS
WITH FEATURE AND DECISION BASED METHODS AND
CLASSIFICATION WITH DEEP CONVOLUTIONAL
NEURAL NETWORKS**

MESUT SALMAN

YRD. DOĐ. DR. SENİHA ESEN YÖKSEL

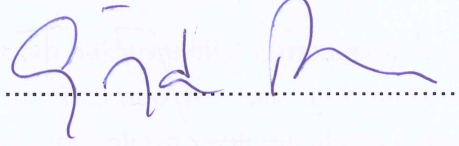
Tez DanıŐmanı

Hacettepe Üniversitesi
Lisansüstü Eğitim – Öğretim ve Sınav Yönetmeliğinin
Elektrik ve Elektronik Mühendisliđi Anabilim Dalı İçin Öngördüğü
YÖKSEK LİSANS TEZİ olarak hazırlanmıŐtır.

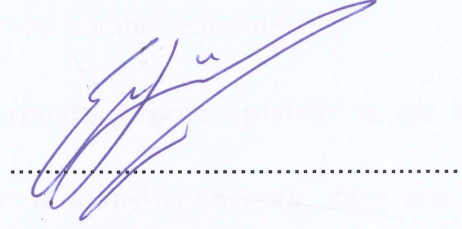
2018

MESUT SALMAN' nin hazırladığı "**HİPERSPEKTRAL VE LİDAR VERİLERİNİN ÖZİNİTELİK VE KARAR SEVİYELERİNDE TÖMLEŞTİRİLMESİ VE DERİN EVRİŞİMLİ SİNİR AĞLARIYLA SINIFLANDIRILMASI**" adlı bu çalışma aşağıdaki jüri tarafından **ELEKTRİK ve ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI'** nda **YÜKSEK LİSANS TEZİ** OLARAK olarak kabul edilmiştir.

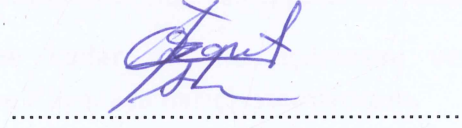
Prof. Dr. GÖZDE Bozdağı Akar
Başkan



Yrd. Doç. Dr. Seniha Esen Yüksel
Danışman



Prof. Dr. ÖZGÜL Salor Durna
Üye



Doç. Dr. Cenk Toker
Üye



Doç. Dr. Berkan Dölek
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**

29 / 03 / 2018



Mesut SALMAN

ETİK

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

- 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.

29/03/2018

Mesut SALMAN

ÖZET

HİPERSPEKTRAL VE LİDAR VERİLERİNİN ÖZNETELİK VE KARAR SEVİYELERİNDE TÜMLEŞTİRİLMESİ VE DERİN EVRİŞİMLİ SİNİR AĞLARIYLA SINIFLANDIRILMASI

Mesut SALMAN

Yüksek Lisans, Elektrik ve Elektronik Mühendisliği Bölümü

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

Mart 2018, 89 sayfa

Gelişen yeni nesil uzaktan algılama teknolojisi ile birlikte, elektromanyetik spektrumda yüzlerce farklı dalga boyunda görüntü alınabilmektedir. Bu verilere ek olarak ışık ile algılama teknolojisi ile uzaktaki nesnelere ile algılayıcı arasındaki mesafe tayin edilebilmektedir. İki farklı kaynaktan elde edilen bu bilgiler bir bölgeye ait anlamsal bölütleme çözümlemesine girdi oluşturmaktadır.

Bu tez çalışması ile HSG (Hiperspektral Görüntü) ve LiDAR (Light Detection and Ranging – Işık ile Algılama ve Menzil Tayini) verisi bulunan bölgelere ait iki farklı veri kümesinin anlamsal bölütlemesinin yüksek başarıyla gerçekleştirilmesi amaçlanmıştır. Özellikle Hiperspektral veri kümesinin sınıflandırılmasında kullanılan klasik yöntemlerin dışında olan ve son yıllarda görüntülerin anlamsal bölütlenmesinde etkileyici sonuçlar veren derin evrişimli sinir ağları (DESA) ile sınıflandırma işlemi gerçekleştirilmiştir.

Tez kapsamında gerçekleştirilen çalışmada problem iki basamakta ele alınmıştır. Öncelikle Hiperspektral ve LiDAR bilgilerinin tümleştirilmesi ardından sınıflandırmanın sonuçlandırılması gerçekleştirilmiştir. Spektral ve yükseklik bilgilerine ek bilgi sağlaması amacıyla farklı yapısal elemanlar ile morfolojik profil haritaları (EMAP – Extended Morphological Attribute Profiles), HSG ve LiDAR verilerine özel olarak oluşturulmuştur. İlk tümleştirme yöntemi olarak önerilen sınıflandırıcı kararlarının tümleştirilmesi kapsamında, spektral ve morfolojik profil haritalarına özel olarak DESA kurulumları gerçekleştirilmiş ve sınıflandırıcı sonuçları oluşturulmuştur. Sınıflandırıcı sonuçları ile sağlanan test verisinin hangi olasılıkla hangi sınıfta yer alabileceği bilgisi kullanılarak eş ağırlık katsayısı ile sınıflandırıcı sonuçları tümleştirilmiş ve genel bir sınıflandırıcı oluşturulmuştur. Bu yöntem ile Muufl veri kümesinin sınıflandırılmasında en iyi sonuçlar elde edilmiştir. İkinci yöntem olan ve özellikle yarışma verisi olan Houston veri kümesinde etkileyici sonuçlar elde edilmesini sağlayan boyutsal tümleştirmede ise, öncelikle farklı yükseklik, morfolojik ve spektral bilgilerin boyutsal olarak tümleştirilmesi sağlanmıştır. Sonrasında iyileştirilmiş AlexNet'in ilk evrişim katmanında yer alan filtreler ile bu tümleştirilmiş verinin öznetelikleri çıkarılmıştır. Öznetelikleri çıkarılmış bu veri kümesine özel DESA kurulumu gerçekleştirilmiş ve sınıflandırma sonuçlarının diğer çalışmalar ile karşılaştırılması gerçekleştirilmiştir. Houston veri kümesinde bulut kaynaklı gölgelemeye yönelik herhangi bir düzeltmenin yapılmadığı çalışmalar arasında en yüksek başarımlı değeri %93.97 bu yöntem ile elde edilmiştir.

Derin evrişimsel sinir ağlarının son yıllarda oldukça popüler olması sonucunda, bu ağların birçok yeni alanda uygulanabilirliği sorgulanmaktadır. Hiperspektral veri kümelerinin sınıflandırılmasında da oldukça etkili sonuçlar verebildiği bu tez kapsamında çıkarılan önemli sonuçlardan bir tanesidir. Ancak spektral bilgileri destekleyecek biçimsel ve uzamsal bilgilerin DESA'ya girdi olarak verilmesini sağlamak gerekliliği çalışmadan çıkarılan en önemli sonuçlardan bir tanesidir. Buna ek olarak DESA ile sınıflandırma AlexNet modelinin ilk evrişim katmanında yer alan filtrelerin HSG'lerde kullanılabilirliği gösterilmiştir.

Anahtar Kelimeler: Hiperspektral Görüntüleme, LiDAR, Anlamsal Bölütleme, LiDAR ve Hiperspektral Görüntülerin Tümleştirilmesi, Derin Evrişimsel Sinir Ağı,

ABSTRACT

FUSION OF HYPERSPECTRAL AND LiDAR DATASETS WITH FEATURE AND DECISION BASED METHODS AND CLASSIFICATION WITH DEEP CONVOLUTIONAL NEURAL NETWORKS

Mesut SALMAN

**Master of Science, Department of Electrical and Electronics
Engineering**

Supervisor: Assist. Prof. Dr. Seniha Esen YÜKSEL

March 2018, 89 pages

With the evolving next generation remote sensing technology, hundreds of different wavelength images can be captured in the electromagnetic spectrum. In addition to this, light sensing technology can be used to determine distances between objects and distant objects. This information obtained from two different sources constitutes an input to the analysis of the semantic segmentation of a region.

In this thesis study, it is aimed to realize the semantic segmentation of two different data sets belonging to the region with HSI (Hyperspectral Image) and LiDAR (Light Detection and Ranging) data with high performance. In particular, classification with deep convolutional neural networks (CNN) has been performed in recent years, except for the classical methods used for classifying hyperspectral datasets, which have had impressive results in the semantic segmentation of images.

In the study carried out within the scope of the thesis, the problem is addressed in two steps. First, integration of the hyperspectral and LiDAR information was followed

by finalization of the classification. In order to provide additional information on spectral and height information, different structural elements and extended morphological attribute profiles (EMAP) have been specially created for HSI and LiDAR data. Within the scope of integrating the classifier decisions recommended as the first integration method, CNN installations were made specifically for the spectral and morphological profile maps and the results of the classifiers were established. Using the knowledge that the test data provided by the classifier results could be included possibility result in which class, the classifier results were integrated and a general classifier was created. With this method, the best results were obtained in classifying the Muufl dataset. In the dimensional integration, which provides impressive results in the Houston dataset, which is the second method, and in particular the competition dataset, the dimensional integration of different height, morphological and spectral information is provided first. Subsequently, attributes of this integrated data were extracted with filters in AlexNet's first convolution layer. A special CNN setup was performed on this dataset, from which the features were extracted, and the results of the classification were compared with other studies. In the Houston dataset, the highest performance was 93.97% for the cloud-based shadows. Among the studies that did not make any correction to the cloud-based shadowing in the Houston dataset, the highest achievement value of 93.97% was obtained with this method.

As deep convolutional neural networks have become very popular in recent years, the feasibility of these networks in many new areas is being questioned. It is one of the important results of this thesis that it can give very effective results in the classification of hyperspectral datasets. However, the need to ensure that formal and spatial information to support spectral information is given as input to CNN is one of the most important results that have been drawn from the study. In addition, the use of filters in the first convolution layer of the AlexNet model classification with CNN has been demonstrated in HSI's.

Keywords: Hyperspectral Imaging, LiDAR, Semantic segmentation, Fusion of LiDAR and Hyperspectral Images, Deep Convolutional Neural Network

TEŐEKKÜR

Tez boyunca akademik bilgi ve tecrübelerinden fazlasıyla yararlandığım, her anlamda yol gösterici olan değerli tez danışmanım Yrd. Doç. Dr. Seniha Esen YÜKSEL'e teşekkürü bir borç bilirim

Tez çalışmalarım boyunca manevi desteğini hiçbir zaman esirgemeyen, her türlü kahrımı çeken eşim Mehtap SALMAN'a, sevgilerini ve desteklerini sürekli arkamda hissettiğim annem Filiz SALMAN'a, babam Ahmet SALMAN'a, her zaman değerli görüş ve yol göstericiliğiyle yanımda olan ağabeyim Murat SALMAN'a ve ailemin tüm fertlerine sonsuz teşekkürlerimi sunarım. Çalışanlarının akademik ve kişisel gelişimine verdiği destekten ötürü ASELSAN A.Ş.'ye, orada birlikte çalıştığım tüm amirlerim ve çalışma arkadaşlarıma teşekkürü borç bilirim.

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

İÇİNDEKİLER DİZİNİ

ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER DİZİNİ	vi
ŞEKİLLER	viii
ÇİZELGELER	xi
KISALTMALAR DİZİNİ	xii
1. GİRİŞ	1
1.1 Tezin Amacı	2
1.2 Tezin Akışı	2
1.3 Hiperspektral Görüntüleme	3
1.4 LiDAR	5
1.5 Tez Kapsamında Kullanılan Veri Kümeleri	6
1.5.1 Houston Üniversitesi Veri Kümesi	6
1.5.2 Muş Gulfort Bölgesi Veri Kümesi	11
1.5.3 Anlamsal Bölütleme Problemi ve Mevcut Çözüm Yöntemleri	13
2. YAPAY SİNİR AĞLARI	18
2.1 Yapay Sinir Ağı Modeline Giriş	18
2.2 Biyolojik Sinir Ağı Matematiksel Modeli	18
2.3 Yapay Sinir Ağları	19
2.4 Derin Evrişimsel Sinir Ağlarına Genel Bir Bakış	20
2.5 Derin Evrişimsel Sinir Ağı Mimarisi	22
2.5.1 Evrişim Katmanı	23
2.5.2 Aktivasyon Fonksiyonu	24
2.5.3 Havuzlama Katmanı (Pooling Layers)	27
2.5.4 Tam Bağlı Sinir Ağı Katmanı (Fully-Connected Layer)	27
2.5.5 Aşırı Uyum (Overfitting)	27
2.5.6 Yığın Normalizasyonu (Batch Normalization)	28
2.5.7 Çıktı Katmanı (Output Layer)	29
2.6 Derin Evrişimsel Sinir Ağı Eğitimi ve Geri Yayılım (Backpropagation)	30
2.6.1 Maliyet Fonksiyonları	33
2.6.2 SGD Methodu	36
2.7 Hiperparametrelerin Ayarlanması	37

3. HİPERSPEKTRAL VE LİDAR VERİLERİNDE ÖN İŞLEME VE BİÇİMSEL PROFİL HARİTALARININ ÇIKARIMI.....	38
3.1 EMAP Yöntemi ile Biçimsel Profil Haritalarının Oluşturulması.....	39
3.2 Veri Normalizasyonu.....	41
4. ÖNERİLEN HSG VE LİDAR TÜMLEŞTİRME YÖNTEMLERİ.....	42
4.1 Olasılıksal Karar Tabanlı Tümleştirme	43
4.2 Öznitelik Tabanlı Tümleştirme	44
4.2.1 Piksel Seviyesinde Tümleştirme	44
4.2.2 Boyutsal Tümleştirme	45
5. DESA SINIFLANDIRICI KURULUMLARI	48
5.1 Karar Tabanlı Tümleştirme Yöntemine Özel DESA Kurulumları.....	49
5.1.1 Spektral Verilere Özel DESA Sınıflandırıcı Kurulumu	49
5.1.2 Biçimsel Haritalara Özel DESA Sınıflandırıcı Kurulumu	50
5.2 Öznitelik Seviyesi Tümleştirme DESA Sınıflandırıcı Kurulumu.....	52
5.2.1 Piksel Seviyesinde Tümleştirilerek Oluşturulan Veri Kümesine Özel DESA Sınıflandırıcı Kurulumu	52
5.2.2 Boyutsal Tümleştirme ve Alexnet İlk Evrişim Katmanı Filtrelenmiş Veri Kümesine Özel DESA Sınıflandırıcı Kurulumu	53
6. DENEYSEL SONUÇLAR.....	55
6.1 Genel Karşılaştırma Parametreleri ve Karşılaştırma Sınıfları	55
6.2 Karar Tabanlı Tümleştirme Sonuçları.....	56
6.2.1 Spektral Verilere Özel DESA Sınıflandırıcı Sonuçları.....	56
6.2.2 Biçimsel Haritalara Özel DESA Sınıflandırıcı Sonuçları	58
6.2.3 Sınıflandırıcı Sonuçlarının Tümleştirilmesi	63
6.2.4 Öznitelik Seviyesi Tümleştirme DESA Sınıflandırma Sonuçları.....	68
6.2.5 Piksel Seviyesi Tümleştirme Veri	68
6.2.6 Boyutsal Tümleştirme ve Alexnet İlk Evrişim Katmanı ile Filtreleme ile Oluşturulmuş Veri Kümesi Sınıflandırıcı Sonuçları	72
6.3 Karşılaştırma Sonuçları	75
7. SONUÇLAR VE DEĞERLENDİRME	80
KAYNAKLAR (REFERENCES).....	83

ŞEKİLLER

Şekil 1-1: Temsili bir Hiperspektral Veri Küpü ve Farklı Piksellerde Yer Alan Farklı Nesnelerin Spektral İmzaları	4
Şekil 1-2: a) Google haritalardan elde edilmiş Muufl görüntüsü, b) Muufl LiDAR yükseklik değerlerini gösteren yükseklik haritası	5
Şekil 1-3: (a) Houston verisinin sahte KYM ile gösterimi (Bantlar:683.60-550.24-473.9 nm). (b) Eğitim Veri Kümesi Noktaları ve Sınıf-Renk İlişkisi. (c) Test Veri Kümesi Noktaları ve Sınıf – Renk İlişkisi. (d) Eğitim ve Test Verilerinin Birlikte Gösterimi (Yeşil: Eğitim Kümesi, Kırmızı: Test Kümesi). (e) Renk Sınıf İlişkisi.	8
Şekil 1-4: Houston Üniversitesi LiDAR yoğunluk değerleri görseli.	9
Şekil 1-5: Houston Veri Kümesine ait örnek 3 farklı sınıfın eğitim-test verilerine ait örnek yansıma değerleri. (Sol grafikler: eğitim verileri, Sağ grafikler: test verileri).....	10
Şekil 1-6 : Muufl Veri Kümesi Bilgileri – (a) Muufl Gulport verisi Google Haritalar görseli. (b) Muufl HSG’lerden elde edilmiş KYM gösterimi. (c) Muufl LiDAR yükseklik verisi. (d) Muufl LiDAR yoğunluk verisi. (e) Muufl Veri Kümesi Doğruluk Görseli (f) Sınıf-Renk İlişkisi	12
Şekil 2-1: Biyolojik Sinir Ağı Modeli Elemanları	19
Şekil 2-2: İki Gizli Katmanlı Yapay Sinir Ağı	20
Şekil 2-3: AlexNet DESA Mimarisi [37].....	21
Şekil 2-4: Yerel Alıcı Alan Gösterimi	22
Şekil 2-5: Evrişim Katmanı Operasyonu ve Öznitelik Haritası Oluşumu	23
Şekil 2-6: Aktivasyon fonksiyonları ve Türevleri ((a) Sigmoid –(b) tanh – (c)ReLU).....	26
Şekil 2-7: Havuzlama Katmanı Örneği	27
Şekil 2-8: Birakma katmanı öncesi ve sonrası sinir ağı yapısı	28
Şekil 2-9: YSA ve softmax fonksiyonu ile çok sınıflı sınıflandırma	30
Şekil 2-10: Basit tek gizli katmanlı YSA.....	32
Şekil 2-11: Çapraz entropi maliyet fonksiyonu geri yayılımı	34
Şekil 2-12: Öğrenme Oranını Maliyet Fonksiyonuna Etkisi.....	37
Şekil 3-1: Morfolojik Profil Oluşturma Basamakları – Houston Veri Kümesi.....	40
Şekil 3-2: Houston LiDAR verisine yönelik disk şekilli yapısal elemanlı açılış işlemi sonucu oluşan profiller (a) Disk yarıçapı 1 olan yapısal eleman ile açılış işlemi. (b) Disk yarıçapı 3 olan yapısal eleman ile açılış işlemi. (c) Disk yarıçapı 5 olan yapısal eleman ile açılış işlemi.	41
Şekil 4-1: Hiperspektral ve LiDAR Verilerinin Sınıflandırma Sonuçlarının Karar Seviyesinde Tümlleştirme Basamakları	43
Şekil 4-2: Piksel seviyesinde EMAP_HSG ve EMAP_LiDAR Verilerinin Tümlleştirilmesi ..	45
Şekil 4-3: MatConvNet_alexNet İlk Evrişim Katmanının Öğrendiği Filtreler (64 adet) ([37],[45])	46
Şekil 4-4: AlexNet Girdisi Oluşturacak Şekilde Hiperspektral ve LiDAR Özniteliklerinin Tümlleştirilmesi.....	47
Şekil 4-5: İyileştirilmiş AlexNet İlk Evrişim Katmanı ve Havuzlama Katmanı Sonrası Girdi Verisi Boyut Değişimi	48
Şekil 5-1: Tümlleştirme Yöntemine Özel DESA Kurulum Genel Bilgilendirmesi	48
Şekil 5-2: Houston- Muufl Spektral Veri Kümelerine Özel DESA Modeli	50
Şekil 5-3: Houston- Muufl EMAP_HSG Veri Kümelerine Özel DESA Modeli	51
Şekil 5-4: Houston- Muufl EMAP_LiDAR Veri Kümelerine Özel DESA Modeli	52

Şekil 5-5: Houston- Muufl EMAP_HSG-EMAP_ LiDAR Pksel Seviyesinde Tümleştirilmiş Veri Kümelerine Özel DESA Modeli	53
Şekil 5-6: Houston- Muufl, Spektral-EMAP_HSG-EMAP_ LiDAR Boyutsal Tümleştirilmiş ve AlexNet İlk Evrişim katmanı Filtreleri ile Oluşturulmuş Veri Kümelerine Özel DESA Modeli Şekilsel Anlatımı	54
Şekil 5-7: Houston- Muufl, Spektral-EMAP_HSG-EMAP_ LiDAR Boyutsal Tümleştirilmiş ve AlexNet İlk Evrişim katmanı Filtreleri ile Oluşturulmuş Veri Kümelerine Özel DESA Modeli	54
Şekil 6-1: Houston HSG spektral verilerine özel DESA Eğitim Grafikleri –a) Kayıp Fonksiyon Değişimini – b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) – c) Top-5 Hatalı Sınıflandırma Oranı Değişimini (Olasılıksal olarak en yüksek 5 değer doğru sınıfla eşleşmeme durumu) göstermektedir.	57
Şekil 6-2: Muufl HSG spektral verilerine özel DESA Eğitim Grafikleri – a) Kayıp Fonksiyon Değişimi –b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) –c) Top-5 Hatalı Sınıflandırma Oranı Değişimini (Olasılıksal olarak en yüksek 5 değer doğru sınıfla eşleşmeme durumu) göstermektedir.	57
Şekil 6-3: Houston EMAP_HSG Haritalarına özel DESA Eğitim Grafikleri – a) Kayıp Fonksiyon Değişimini – b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) – c) Top-5 Hatalı Sınıflandırma Oranı Değişimini (Olasılıksal olarak en yüksek 5 değer doğru sınıfla eşleşmeme durumu) göstermektedir.	59
Şekil 6-4: Muufl EMAP Haritalarına özel DESA Eğitim Grafikleri – a) Kayıp Fonksiyon Değişimini – b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) – c) Top-5 Hatalı Sınıflandırma Oranı Değişimini (Olasılıksal olarak en yüksek 5 değer doğru sınıfla eşleşmeme durumu) göstermektedir.	60
Şekil 6-5: Houston EMAP_ LiDAR Haritalarına özel DESA Eğitim Grafikleri – a) Kayıp Fonksiyon Değişimi – b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) – c) Top-5 Hatalı Sınıflandırma Oranı Değişimini (Olasılıksal olarak en yüksek 5 değer doğru sınıfla eşleşmeme durumu) göstermektedir.	62
Şekil 6-6: Muufl EMAP_ LiDAR Haritalarına özel DESA Eğitim Grafikleri – a) Kayıp Fonksiyon Değişimi – b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) – c) Top-5 Hatalı Sınıflandırma Oranı Değişimini (Olasılıksal olarak en yüksek 5 değer doğru sınıfla eşleşmeme durumu) göstermektedir.	62
Şekil 6-7: Houston Veri Kümesinin DESA ile piksellerin tamamının sınıflandırılması sonuçları – (a) Spektral Sınıflandırıcı Sonucu – (b) EMAP_HSG Sınıflandırıcı Sonucu – (c) EMAP_ LiDAR Sınıflandırıcı Sonucu – (d) Olasılıksal Karar Birleştirme Sonrası Sınıflandırma Sonucu	65
Şekil 6-8: : Houston Veri Kümesinin DESA ile test piksellerin sınıflandırılması sonuçları (Kırmızı: Hatalı sınıflandırma, Yeşil: Doğru Sınıflandırma)– (a) Spektral Sınıflandırıcı Sonucu – (b) EMAP_HSG Sınıflandırıcı Sonucu – (c) EMAP_ LiDAR Sınıflandırıcı Sonucu – (d) Olasılıksal Karar Birleştirme Sonrası Sınıflandırma Sonucu.....	66
Şekil 6-9: Muufl Veri Kümesinin DESA ile test piksellerin sınıflandırılması sonuçları– (a) Spektral Sınıflandırıcı Sonucu – (b) EMAP_HSG Sınıflandırıcı Sonucu – (c) EMAP_ LiDAR Sınıflandırıcı Sonucu – (d) Olasılıksal Karar Birleştirme Sonrası Sınıflandırma Sonucu – (e) Mutlak Doğruluk Haritası (Ground Truth)	67
Şekil 6-10: Houston EMAP_ LiDAR ve EMAP_HSG piksel seviyesinde tümleştirilmiş veri kümesine özel DESA Eğitim Grafikleri – a) Hata Fonksiyonu Değişimini – b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) – c) Top-5 Hatalı Sınıflandırma	

Oranı Değişimini (Olasılıksal olarak en yüksek 5 değerin doğru sınıfla eşleşmeme durumu) göstermektedir.....	69
Şekil 6-11: Muufl EMAP_ LiDAR ve EMAP_HSG piksel seviyesinde tümleştirilmiş veri kümesine özel DESA Eğitim Grafikleri – a) Hata Fonksiyonu Değişimini – b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) – c) Top-5 Hatalı Sınıflandırma Oranı Değişimini (Olasılıksal olarak en yüksek 5 değerin doğru sınıfla eşleşmeme durumu) göstermektedir.....	69
Şekil 6-12: Houston_EMAP ve Houston_ LiDAR Piksel Seviyesinde Tümleştirilmiş Veri Kümesinin DESA ile Sınıflandırılması – (a) piksellerin tamamının sınıflandırılması sonuçları –(b) Test piksellerin sınıflandırılması sonuçları (Kırmızı: Hatalı sınıflandırma, Yeşil: Doğru Sınıflandırma).....	71
Şekil 6-13: Muufl_EMAP ve Houston_ LiDAR Piksel Seviyesinde Tümleştirilmiş Veri Kümesinin DESA ile Sınıflandırılması – (a) Sınıflandırıcı Sonucu (b) Mutlak Doğruluk Haritası (Ground Truth).....	71
Şekil 6-14: Houston boyutsal tümleştirilmiş ve AlexNet İlk Evrişim Katmanı ile filtrelenmiş veri kümesine özel DESA Eğitim Grafikleri – a) Hata Fonksiyonu Değişimini – b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) – c) Top-5 Hatalı Sınıflandırma Oranı Değişimini (Olasılıksal olarak en yüksek 5 değerin doğru sınıfla eşleşmeme durumu) göstermektedir.....	73
Şekil 6-15: Muufl boyutsal tümleştirilmiş ve AlexNet İlk Evrişim Katmanı ile filtrelenmiş veri kümesine özel DESA Eğitim Grafikleri – a) Hata Fonksiyonu Değişimini – b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) – c) Top-5 Hatalı Sınıflandırma Oranı Değişimini (Olasılıksal olarak en yüksek 5 değerin doğru sınıfla eşleşmeme durumu) göstermektedir.....	73
Şekil 6-16: Houston, Spektral-EMAP_HSG-EMAP_ LiDAR Boyutsal Tümleştirilmiş ve AlexNet İlk Evrişim katmanı Filtreleri ile Oluşturulmuş Veri Kümesinin DESA ile Sınıflandırılması – (a) piksellerin tamamının sınıflandırılması sonuçları –(b) Test piksellerin sınıflandırılması sonuçları (Kırmızı: Hatalı sınıflandırma, Yeşil: Doğru Sınıflandırma).....	74
Şekil 6-17: Muufl, Spektral-EMAP_HSG-EMAP_ LiDAR Boyutsal Tümleştirilmiş ve AlexNet İlk Evrişim katmanı Filtreleri ile Oluşturulmuş Veri Kümesinin DESA ile Sınıflandırılması – (a) Sınıflandırıcı Sonucu (b) Mutlak Doğruluk Haritası (Ground Truth).....	75

ÇİZELGELER

Tablo 1-1: Houston Üniversitesi Veri Kümesi İçeriği.....	6
Tablo 1-2: Mufl Veri Kümesi İçeriği.....	11
Tablo 2-1: Biyolojik Sinir Ağı – Matematiksel Model Eşleştirme Tablosu	19
Tablo 2-2: Yaygın olarak kullanılan Aktivasyon Fonksiyonları ve Türevleri	25
Tablo 2-3: Yaygın Kullanılan Maliyet Fonksiyonları Matematiksel İfadeleri	34
Tablo 6-1: Yalnızca Spektral Veriye Özel DESA Sınıflandırıcı Test Başarımları ve Kappa İstatistik Değerleri	58
Tablo 6-2: Yalnızca Spektral Verilerin DVM ve Rastgele Orman Sınıflandırıcısı Test Başarımı ve Kappa İstatistik Değerleri	58
Tablo 6-3: EMAP_HSG DESA Sınıflandırıcı Test Başarımı ve Kappa İstatistik Değeri.....	60
Tablo 6-4: EMAP_HSG Piksel Verilerinin DVM ve Rastgele Orman sınıflandırıcı Test Başarımı ve Kappa İstatistik Değerleri	61
Tablo 6-5: EMAP_LiDAR DESA Sınıflandırıcı Test Başarımı ve Kappa İstatistik Değeri .	63
Tablo 6-6: EMAP_HSG Piksel Verilerinin DVM ve Rastgele Orman sınıflandırıcı Test Başarımı ve Kappa istatistik Değerleri	63
Tablo 6-7: Olasıksal Eş Ağırlıklı Karar Seviyesinde Tümleştirme Sonuçları.....	64
Tablo 6-8: EMAP_LiDAR ve EMAP_HSG Piksel Seviyesinde Tümleştirilmiş Veri Kümesine Özel DESA sınıflandırıcı Test Başarımı ve Kappa istatistik Değeri.....	70
Tablo 6-9 EMAP_LiDAR ve EMAP_HSG Piksel Seviyesinde Tümleştirilmiş Veri Kümelerinin Piksel Seviyesinde DVM ve Rastgele Orman Sınıflandırıcısı Test Başarımı ve Kappa istatistik Değerleri.....	70
Tablo 6-10: Houston- Mufl Spektral--EMAP_HSG--EMAP_LiDAR Boyutsal Tümleştirilmiş ve AlexNet İlk Evrişim katmanı Filtreleri ile Oluşturulmuş Veri Kümelerine DESA sınıflandırıcı Test Başarımı ve Kappa istatistik Değeri	74
Tablo 6-11: Houston ve Mufl Sınıf Numarası ve Sınıf Adı	75
Tablo 6-12: Houston Veri Kümesine Özel Tez Kapsamında Önerilen Yöntemlerin Sonuç Karşılaştırması	76
Tablo 6-13: Houston En Başarılı Sınıflandırıcı (Boyutsal Tümleştirilmiş AlexNet ilk Evrişim Katmanı ile Filtrelenmiş DESA Sınıflandırıcısı) Karışıklık Matrisi	77
Tablo 6-14: Houston Veri kümesine Özel Önerilen Boyutsal Tümleştirilmiş AlexNet ilk Evrişim Katmanı ile Filtrelenmiş DESA Sınıflandırıcı Yönteminin Mevcut Sonuçlar ile Karşılaştırılması	78
Tablo 6-15: Mufl Veri Kümesine Özel Tez Kapsamında Önerilen Yöntemlerin Sonuç Karşılaştırması	79
Tablo 6-16: Mufl En Başarılı Sınıflandırıcı (Olasıksal Kararları Tümleştirilmesi ile Oluşan Sınıflandırıcı) Karışıklık Matrisi.....	80

KISALTMALAR DİZİNİ

Kısaltmalar

CNN	Convolutional Neural Networks
DESA	Derin Evrişimsel Sinir Ağları
DVM	Destek Vektör Makineleri
EMAP	Extended Morphological Attribute Profiles (Genişletilmiş Biçimsel Özellik Profilleri)
EO/IR	Electro Optic / Infrared (Elektro Optik / Kızılötesi)
GPS	Global Positioning System (Küresel Konum Belirleme Sistemi)
IMU	Inertial Measurement Unit (Ataletsel Ölçüm Ünitesi)
INS	Inertial Navigation System (Ataletsel Seyrüsefer Sistemi)
HSG	Hiperspektral Görüntüleme
LiDAR	Light Detection and Ranging (Işık Tespiti ve Mesafe Ölçme)
RO	Rastgele Orman
YSA	Yapay Sinir Ağları

1. GİRİŞ

Uzaktan algılama (UA); atmosferde, uzayda ya da yeryüzünden belli uzaklıktaki platformalara konumlandırılmış ölçüm aletleri aracılığıyla, nesnelere ve yeryüzü ile fiziksel bir temasta bulunmadan herhangi bir uzaklıktan yapılan ölçümler ile bilgi toplama ardından toplanılan bu bilgileri yorumlama ve anlamlandırma olarak tanımlanabilmektedir. UA tarihçesine yönelik olarak, ilk bilinen hava fotoğrafı 1858'de Gaspard Felix Tournachon'un Paris'i yaklaşık 2296 metre yükseklikten çekmesiyle oluşmuştur. Soğuk savaş dönemiyle birlikte uydulara dayalı UA çalışmaları başlamış, 2000'li yıllarda ise yüksek mekânsal ve spektral çözünürlüklü uydu görüntüleri her amaçlı kullanılabilir hale gelmiştir. Farklı sensör teknolojileri ile birlikte özellikle insan duyu organlarıyla algılanması zor olan bilgiler elde edilmekle birlikte evren ve evrende yer alan materyallere yönelik yeni bilgilere erişebilme imkanı doğmuştur. UA sistemleri temel olarak yer, hava ve uzay platformlarına yerleştirilir. Örneğin; uçak, helikopter veya jet gibi hava araçlarına monte edilen UA sensörleri ile hava platformundan yeryüzüne yönelik bilgi toplanır. UA sistemleri bulunduğu platforma ve kullanılma amacına yönelik özelleştirilmiş özelliklere sahiptir.

Uzaktan algılamaya yönelik olarak; elektromanyetik spektrumda kendine has ışınım karakteristiği bulunan enerji kaynağı algılamasının en temel elemanıdır. Kaynaktan yansıyan elektromanyetik enerji yeryüzündeki objeler ve atmosferik etkiler ile etkileşim halinde bulunur. Sensörler ile yeryüzündeki objelerden yansıma, emilme ve iletilme sonrasında geri yansıyan elektromanyetik enerjiler kaydedilir. Kullanılan enerji tipine bağlı olarak UA sistemleri pasif ve aktif UA sistemleri olarak iki ayrı sınıfta incelenmektedir. Pasif algılamada sensörler güneş ışığının etkisiyle nesneden yansıyan enerjiyi kullanmaktadır. Aktif algılamada ise öncelikle nesneye bir enerji gönderimi gerçekleştirilir ve enerjinin geri dönüşü ölçülür [1]. En popüler pasif UA sensörleri; görünür bantta çalışan kameralar, hiperspektral kameralar, kızılötesi-morötesi sensörler ve radyometrelerdir. Radar, LiDAR ve ultrason ise aktif UA sensörlerine örnek olarak verilebilir.

Hiperspektral verilerin anlamsal bölütlenmesi UA alanında gerçekleştirilen en yaygın uygulama alanı olup sınıflandırma işleminin başarımını artırmak için temel olarak yükseklik bilgisi içeren LiDAR verileri ile hiperspektral veri kümesinin sağladığı bilgilerin tümleştirilmesi önemli bir araştırma konusudur. Bu problemin

çözümünden önce veri kümeleri tarafından sağlanan bilgileri anlamak ve doğru bir şekilde yorumlamak öncelikli işlemdir. Hiperspektral ve LiDAR bilgilerinin tümleştirilmesi problemine ek olarak bu iki farklı kaynaktan elde edilen verilerin anlamsal bölütlemesinde kullanılan birçok yöntem bulunmaktadır. Son yıllarda özellikle görünür bantta elde edilmiş görüntülerin sınıflandırılmasında önemli gelişim gösteren Derin evrimsel sinir ağlarının (DESA) Hiperspektral ve LiDAR verilerinin sınıflandırılması problemi için kullanımı önemli bir araştırma konusudur.

1.1 Tezin Amacı

Hiperspektral verilerin anlamsal bölütlemesi araştırmacıların üzerinde çalıştığı çok popüler bir problemdir. Özellikle yüzlerce farklı bantta görüntülerin alınmasıyla birlikte bölge veya sahne hakkında birçok bilgi elde edilebilmektedir. Bu verilere ek olarak özellikle aynı yapıtaşından üretilen ve spektral karakteristiği birbirine oldukça benzeyen farklı sınıfları ayırabilmek ve spektral bilgiye ek olarak yükseklik haritası bilgisini sağlayabilmek amacıyla LiDAR verileri de elde edilmektedir. Tez kapsamında elde edilen bu iki veri kümesinin en iyi şekilde değerlendirilmesi ve anlamsal bölütleme probleminin çözülmesinde kullanılması amaçlanmıştır. Hiperspektral verilerin sınıflandırılmasında karşılaşılan boyutsallık ve eğitim örnek sayısının azlığı sınıflandırma için önemli bir problem oluşturmaktadır. Bu problemin üstesinden gelmek amacıyla veri kümelerinden uzamsal ve biçimsel özelliklerin çıkarımı gerçekleştirilmiş buna ek olarak farklı tümleştirme yöntemleri ile birlikte uygun DESA tabanlı sınıflandırıcı kurulması amaçlanmıştır. Özellikle piksellere ait spektral ve uzamsal bilgiler ile tez kapsamında önerilen yöntem ile 3 boyulu görüntüler oluşturulup AlexNet'in ilk katmanında yer alan filtreler yardımıyla verilerin modellenmesi gerçekleştirilmiştir. Özellikle Houston veri kümesi üzerinde oluşturulan eğitim ve test örnekleri üzerinden kurulan DESA'nın başarımının etkileyici sonuçlar verdiği görülmüştür.

1.2 Tezin Akışı


Bölüm 1'de bu çalışmada kullanılan tezin amacı, tez kapsamında kullanılan veri kümeleri içeriği ve bilgilendirmesi, hiperspektral görüntüleme kapsamında kullanılan temel kavramlar, anlamsal bölütleme problemi ve probleme yönelik mevcut çalışmalar anlatılmaktadır. Bölüm 2'de yapay sinir ağları ve derin evrimsel sinir ağlarına yönelik teorik bilgiler verilmiştir. Derin evrimsel sinir ağlarında yer

alan katmanların özellikleri, iyi bir ağ kurulması için gerekli bilgiler bu bölümde detaylandırılmıştır. Bölüm 3'te hiperspektral ve LiDAR verilerinden üretilen biçimsel ve uzamsal özellikleri içeren profillerin oluşturulması anlatılmıştır. Spektral bilgilere ek olarak sağlanan bu bilgilerin çıkarılma adımları detaylandırılmıştır. Veri kümelerinden elde edilen farklı bilgilerin tümleştirilmesine yönelik gerçekleştirilen çalışmalar ise Bölüm 4'te anlatılmıştır. Bölüm 5'te kurulan DESA sınıflandırıcı yapılarının detayları, Bölüm 6'da ise sınıflandırıcı sonuçları ve farklı tümleştirme yöntemlerinin sınıflandırma başarımına olan etkisinin karşılaştırma sonuçları detaylandırılmıştır. Son bölümde ise tezde sunulan yöntemin sağladığı katkılar ve önerilerin aktarımı gerçekleştirilmiştir.

1.3 Hiperspektral Görüntüleme

Uzaktan algılama alanında yaşanan en önemli gelişmelerden biri olan hiperspektral görüntülemenin popülerliği gün geçtikçe artmaktadır. Hiperspektral görüntüleme; digital görüntüleme ve spektroskopinin gücünü birleştirmektedir. Aynı zamanda 'Görüntü spektrometresi' olarak da adlandırılan hiperspektral görüntüleme, spektrometre olarak adlandırılan cihaz ile yapılmaktadır. Elde edilen görüntüler ile sahnede yer alan nesne kompozisyonunun ve alan kaplamasının doğru ve güvenilir bir şekilde belirlenebilmesi için, geniş ve kesintisiz bir şekilde elektromanyetik spektrumda yüzlerce farklı dalga boyunda veri toplanılır.

'Hiper' ve 'spektral' kelimelerinden oluşan 'hiperspektral' çok sayıda spektral banttıan oluşan anlamına gelmektedir. Multispektral görüntülemeden temel farkı ise çok daha fazla bantta ölçüm alınması ve buna ek olarak bantların aralığının dar ve birbirine yakın olmasıdır. Hiperspektral kameralar ile alınan ölçümlerde, her bir materyalin farklı dalga boylarında ışığı farklı şekilde yansıtmasına bağlı olarak, o materyallere ait spektral imzalar çıkartılır ve görüntü içerisinde yer alan her bir pikselin hangi materyali içerdiği tespit edilir. Hiperspektral görüntüler "hiperküp" olarak adlandırılan yapılarda tutulmaktadır. Temsili bir hiperküp ve görüntüde yer alan pikselin içerdiği materyal ve materyalin spektral imzası Şekil 1-1 ile verilmektedir.



Şekil 1-1: Temsili bir Hiperspektral Veri Küpü ve Farklı Piksellerde Yer Alan Farklı Nesnelerin Spektral İmzaları

Optik pasif uzaktan algılama yöntemiyle hiperspektral görüntüler elde edilir. Pasif algılama ile güneşten gelen ışınların yüzeydeki nesnelere değişik dalga boylarında yansımalarından elde edilen bilgiler toplanılır. Böylece farklı nesnelerin spektral düzlemde kendine has ışması hiperspektral görüntüleme ile elde edilebilmektedir. Elektromanyetik spektrumun optik bölgesi olan 0.4 μm ile 14 μm bant aralığında uzaktan algılama ile görüntüler elde edilebilmektedir ve temel olarak dört dalga boyu aralığında hiperspektral görüntüler toplanmaktadır [3].

- 400-1000 nm bant aralığını kapsayan Görünür ve Yakın Kızılötesi Bant (VNIR)
- 1000-2500 nm bant aralığını kapsayan Kısa Dalga Kızılötesi Bant (SWIR)
- 3000-5000 nm bant aralığını kapsayan Orta Dalga Kızılötesi Bant (MWIR)
- 8000-12000 nm bant aralığını kapsayan Uzun Dalga Kızılötesi Bant (LWIR)

Hiperspektral görüntüleme; yerbilim, gıda, tarım, tıp ve savunma gibi birçok alanda kullanılmaktadır. Örneğin yerbilim alanında maden ve mineral tespiti; gıda alanında besinlerin kalitesinin tespiti, tarım alanında ürün türlerinin sınıflandırılması; askeri

alanda mayınların tespiti hiperspektral görüntüleme yönteminin kullanıldığı alanlardır ([4],[5],[6]).


1.4 LiDAR

Aktif bir uzaktan algılama tekniği olan LiDAR (Light Detection and Ranging) günümüzde farklı amaçlar için çok sık kullanılan bir teknolojidir. Genelde kaynak olarak lazer kullanılmaktadır. Sensörden gönderilen lazer ışınının gidiş-dönüş süresini kaydederek yer objeleri ile algılayıcı arasındaki mesafenin ölçülmesi sağlanır. Sistem dahilinde bulunan INS, GPS gibi ataletsel ölçüm birimleri ile konum ve dönüklük verisi ile yükseklik verisinin yüksek doğrulukta ilişkilendirilmesi sağlanır. LiDAR verileri; jeolojiden hidrolojiye, haritacılıktan askeri uygulamalara kadar birçok alanda kullanılmaktadır.

Hiperspektral görüntülere ek bilgi sağlaması nedeniyle LiDAR verilerinin anlamlandırılması büyük önem taşımaktadır. Örneğin asfalt yol ve kiremit çatı malzemelerinin spektral veri bilgisi materyal yapıtaşlarının benzerliğinden dolayı büyük benzerlik göstermektedir. Ancak iki farklı sınıfta yer alan bu nesnelerin LiDAR verileri incelendiğinde, bu veriler yeryüzünde buldukları konum itibarıyla farklılık göstermekte ve hiperspektral verilere ek bir girdi sağlamaktadır. Şekil 1-2 ile örnek bir LiDAR yükseklik haritası görseli sağlanmıştır. Bölgeye ait görünür bantta elde edilmiş görsel de Şekil 1-2(a)'da bulunmaktadır.



(a)



(b)

Şekil 1-2: a) Google haritalardan elde edilmiş Muufi görüntüsü, b) Muufi LiDAR yükseklik değerlerini gösteren yükseklik haritası

1.5 Tez Kapsamında Kullanılan Veri Kümeleri

Tez kapsamında iki farklı veri kümesi kullanılmıştır. Bu veri kümeleri hem LiDAR hem de hiperspektral verileri içermektedir. ABD'de Houston Üniversitesi ve çevresinden alınmış veri kümesi ve Gulfport Missipi bölgesinden alınmış Muufl Gulfport veri kümesine yönelik bilgiler alt başlıklarda detaylandırılmıştır.

1.5.1 Houston Üniversitesi Veri Kümesi

IEEE (Institute of Electrical and Electronics Engineers) Yer Bilimleri ve Uzaktan Algılama Topluluğunun 2013 yılında düzenlediği bir yarışmada sağlanan bu veri kümesi ABD'nin Houston Üniversitesi bölgesinin çevresinden elde edilmiştir. Hiperspektral ve LiDAR verilerini içeren iki veri kümesi yarışma kapsamında paylaşılmıştır [7]. 23 Haziran 2012 tarihinde sağlanan görüntünün uzamsal çözünürlüğü 349x1905'tir. Hiperspektral görüntüde 380 nm ile 1050 nm dalga boyu aralığında 144 farklı spektral bant bulunmaktadır. Piksel uzamsal çözünürlüğü ise 2.5m'dir. Houston Üniversitesi içerisinden alınan bu görüntülerde; sulak alanlar, asfalt yollar, toprak araziler, sağlıklı-sentetik-ezilmiş çimenlik alanlar, ağaçlık bölgeler, koşu pistleri ve araç park yeri gibi birçok işaretlenmiş bölge bulunmaktadır. Farklı sınıf olarak adlandırılan bu bölgelere ait eğitim ve test verileri iki ayrı küme halinde araştırmacılara sunulmuştur. Veri kümesinde yer alan 15 farklı sınıfa ait eğitim ve test verileri örnek sayıları ve sınıf bilgileri Tablo 1-1 ile verilmektedir.


Tablo 1-1: Houston Üniversitesi Veri Kümesi İçeriği

Sınıf Numarası	Sınıf Adı	Eğitim Verisi Örnek Sayısı	Test Verisi Örnek Sayısı
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	Evsel Bölge	196	1072
8	İşyeri Bölgesi	191	1053
9	Asfalt Yol	193	1059
10	Otoyol	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


Houston veri kümesine yönelik olarak bölgeye ait KYM (Kırmızı-Yeşil-Mavi) gösterimi, eğitim ve test örneklerinin HSG üzerindeki konumları Şekil 1-3 ile verilmektedir. İlgili şekil incelendiğinde imgenin sağ tarafında şehiriçi bölgenin bir kısmının buluttan kaynaklanan gölge sebebiyle karartı altında kaldığı görülmüştür. Hiperspektral görüntüleri oluşturan ışık bilgisinin karaltıdan dolayı değişmesiyle birlikte bulut gölgesinde kalan bu alandan materyallere özel farklı ve hatalı veriler okunmaktadır. Verinin sınıflandırılmasında bu bölgeden kaynaklı başarımların düşüşleri kaçınılmazdır. Ancak tez kapsamında gerçekleştirilen çalışmalarda test verisinin hangi bölgeden alındığına dair ya da gölgelik alanda bulunup bulunmadığına dair bir çalışma gerçekleştirilmemiştir.




(a)



(b)



(c)




(d)



(e)


Şekil 1-3: (a) Houston verisinin sahte KYM ile gösterimi (Bantlar:683.60-550.24-473.9 nm). (b) Eğitim Veri Kümesi Noktaları ve Sınıf-Renk İlişkisi. (c) Test Veri Kümesi Noktaları ve Sınıf – Renk İlişkisi. (d) Eğitim ve Test Verilerinin Birlikte Gösterimi (Yeşil: Eğitim Kümesi, Kırmızı: Test Kümesi). (e) Renk Sınıf İlişkisi.

HSG'lere ek olarak sađlanan ykseklik bilgisini ieren LiDAR verisine ait yođunluk deđerlerini ieren grsel Őekil 1-4 ile verilmektedir. Hiperspektral veri ile LiDAR verilerinin konumsal ve geometrik eŐlenmesi veri kmesi araŐtırmacılara sađlanmadan nce gerekleŐtirilmiŐtir.



Őekil 1-4: Houston niversitesi LiDAR yođunluk deđerleri grseli.

Houston veri kmesi ile birlikte sađlanan 3 farklı sınıfa ait rnek eđitim ve test veri kmelerinin yansım deđerlerini ieren grafikler Őekil 1-5 ile verilmektedir. Genel olarak test ve eđitim verilerinde aynı sınıfta yer alan spektral veriler beklenildiđi gibi benzer karakter gstermektedir. Ancak gneŐ iŐıđını yansıtabilmede glgelik alanda ya da baŐka bir materyalin etkisinde kalması durumunda spektral imzalarda farklılık gzlenebilmektedir. Ayrıca farklı sınıf olarak iŐaretlenmiŐ sınıfların da spektral imzalarının zellikle aynı materyali iermesi ya da aynı materyalden yapılması durumunda benzer karakteristik gsterebildiđi grlmektedir.



Şekil 1-5: Houston Veri Kümesine ait örnek 3 farklı sınıfın eğitim-test verilerine ait örnek yansımaya değerleri. (Sol grafikler: eğitim verileri, Sağ grafikler: test verileri)

1.5.2 Muufl Gulfort Bölgesi Veri Kümesi

Muufl veri kümesi Missisipi Gulf Park Kampüsü üzerinden Kasım 2010 tarihinde alınmış alınmış 325x225 uzamsal çözünürlüğüne sahip 405nm ile 1053nm bant aralığında 64 farklı dalga boyu aralığında hiperspektral veri kümesine ve LiDAR veri kümesine sahip geniş bir veri kümesini içermektedir [8]. Veri kümesine yönelik sağlanan görüntüler Şekil 1-6 ile verilmektedir. İlgili görselde öncelikle Google Haritalar yardımıyla elde edilmiş bölgeye ait fotoğraf ardından hiperspektral verilerden elde edilmiş KYM gösterimine ek olarak LiDAR verilerinden elde edilmiş yükseklik (DEM) ve son olarak işaretlenmiş bölgelerin sınıflarını gösteren imge bulunmaktadır. Buna ek olarak Muufl veri kümesinde yer alan sınıflara ait veri kümesi örnek sayıları ise Tablo 1-2 ile verilmektedir.


Tablo 1-2: Muufl Veri Kümesi İçeriği

Sınıf Numarası	Sınıf Adı	İşaretlenmiş Veri Kümesi Örnek Sayısı
1	Ağaçlık Bölge	23246
2	Çoğunlukla Çimenlik Bölge	4270
3	Karışık Zemin Yüzeği Bölgesi	6882
4	Kumlu Bölge	1826
5	Yol	6687
6	Su Bölgesi	466
7	Bina Bölgesi	2233
8	Bina Gölgesi	6240
9	Yaya Kaldırımı	1385
10	Sarı Kaldırım	183
11	Kumaş Paneller	269


Muufl verisinin asıl kullanım amacı içerisine konumlandırılmış farklı materyallerin belirlenmesi, yani hedef tespittir. Ancak ilerleyen zamanlarda verilerin işaretlenmesi gerçekleştirilmiş ve mutlak doğruluk haritası oluşturulmuştur. Piksellerin işaretlenmesi gerçekleştirilirken atamasına kesin karar verilemeyen pikseller yer almış ve “çoğunlukla” ifadeli sınıflar oluşturulmuştur. Sınıflandırma başarımları analiz edilirken tez kapsamında bu bilgi dikkate alınmıştır.




(a)




(b)



(c)



(d)



(e)

■ İşaretlenmemiş Bölgeler	■ Su Bölgesi
■ Ağaçlık Bölge	■ Bina Gölgesi
■ Çoğunlukla Çimenlik Bölge	■ Bina
■ Karışık Zemin Bölgesi	■ Yaya Kaldırımı
■ Kumlu Bölge	■ Sarı Kaldırım
■ Yol	■ Kumaş Panelleri

(f)

Şekil 1-6 : Muufl Veri Kümesi Bilgileri – (a) Muufl Gulport verisi Google Haritalar görseli. (b) Muufl HSG’lerden elde edilmiş KYM gösterimi. (c) Muufl LiDAR yükseklik verisi. (d) Muufl LiDAR yoğunluk verisi. (e) Muufl Veri Kümesi Doğruluk Görseli (f) Sınıf-Renk İlişkisi

1.5.3 Anlamsal Bölütleme Problemi ve Mevcut Çözüm Yöntemleri

Bu bölümde öncelikle anlamsal bölütlemenin tanımlaması gerçekleştirilmiş ardından hiperspektral görüntülerde anlamsal bölütleme probleminde kullanılan mevcut çözüm yöntemleri anlatılmıştır. Tez kapsamında yöntem olarak kullanılan derin öğrenmenin ve derin evrimsel sinir ağlarının hiperspektral verilerde kullanımına yönelik mevcut çalışmalar ve tezde kullanılan veri kümesine özel çalışmalar anlatılmıştır.

Tanım görsel algılamının en önemli özelliklerinden bir tanesidir. İnsan vizyonu için cisimlerin tanınması ve sınıflandırılması doğal ve spontan bir aktivitedir. Buna karşın, elde edilen görüntünün yorumlanması ve sınıflandırılması mevcut bilgisayar sistemlerinin yeteneklerinin ötesine geçebilmektedir [9].

Görüntünün anlamsal bölütlemesi görüntü üzerinde aynı özellikteki piksellerin parçalar halinde bir araya getirilmesi ve görüntünün belli bölgelere ayrılması olarak tariflenmektedir. Görüntü bölütlemesi; bölütleme esnasında kullanılan eğitim veri kümesine dayalı olarak, denetlemeli bölütleme (supervised clustering) veya denetlemesiz bölütleme (unsupervised clustering) şeklinde yapılmaktadır. Denetlemesiz bölütlemede piksel sınıflandırması etiketlenmemiş verilere dayanarak yapılmaktadır. Denetimli bölütleme işlemi, sınıflandırılmamış pikselleri, mevcut etiketli veriler temelinde çeşitli bilgi sınıflarından birine atamak için bilinen etiket örneklerini gruplamayı içermektedir [10].

Hiperspektral görüntüleme ile bir dizi zengin spektral bilgi taşıyan yüzlerce ardışık dalga boyunda veri toplanabilmektedir. Elde edilen bu zengin hiperspektral veri kümesi farklı alanlarda sınıflandırma problemi için girdi oluşturmaktadır. Jeoloji alanında toprağı ([11]) ve bitki örtüsünü oluşturan materyallerin belirlenmesi; savunma alanında uydu görüntülerinin sınıflandırılması, mayınlı bölgelerin tespit edilmesi, hava araçlarıyla elde edilen görüntülerin bölütlenmesi ([12]); çevre analizinde su kirliliği bulunan bölgelerin belirlenmesi, mineral tespiti ([13]) gibi birçok alanda hiperspektral görüntülerin bölütlenmesi gerçekleştirilmektedir. Bu uygulamalarda kullanılan yaygın teknik ise her bir pikselin ayrı ayrı sınıflandırılmasıdır. Hiperspektral görüntüleme bu kadar farklı alanda kullanılmasına rağmen verilerin sınıflandırılması esnasında veri kümesinden kaynaklı zorluklar bulunmaktadır. Bu zorluklar temel olarak; az sayıda işaretlenmiş eğitim veri kümesinin bulunması, hiperspektral verilerin yüksek boyutluluk problemi ve

materyallerin spektral imzalarının geniş uzamsal deęişkenlięi bařlıkları altında toplanmaktadır [14].

Hiperspektral görüntülerin denetimli bölütlemesinde kullanılmak üzere birçok yöntem önerilmiştir. Geleneksel hiperspektral veri sınıflandırma yöntemleri yalnızca spektral bilgiyi kullanmaktadır. Sınıflandırma algoritmaları olarak kullanılan yaygın geleneksel algoritmalar ise paralelkenar sınıflandırma, k-en yakın komşu, maksimum olasılık, minimum mesafe ve lojistik regresyondur [15]. Bahsi geçen algoritmaların çoğunluğu "yüksek boyutluluk" problemine karşı etkin bir çözüm sunamamaktadır. Hiperspektral verinin yüksek boyutlu ve sınırlı eğitim örnekleri ile başa çıkmak için sınıflandırma verisine yönelik olarak bazı boyut azaltma yöntemleri önerilmiştir. Boyut azaltma yöntemlerinden yaygın olanlar ise; temel bileşen analizi (PCA), veri kümesi içerisinde anlamlı bant seçimi ve bağımsız bileşen analizi (independent component analysis) verinin daha düşük boyutta ve daha farklı bir uzayda ifade edilmesini sağlamaktadır [16]. Boyut azaltma teknikleriyle birlikte özellikle düşük eğitim boyutlarında etkin ve istikrarlı bir yöntem olan DVM (Destek Vektör Makinesi), HSG'lerin sınıflandırılmasında başarılı sonuçlar vermiştir. DVM, çekirdek kaynaklı yüksek boyutlu bir özellik uzayında eğitim örneklerini en iyi şekilde ayıran en uygun karar hiper düzlemini öğrenerek veri kümesini sınıflara ayırmayı amaçlamaktadır. ([17],[18]).

İyi bir sınıflandırma işlemi en temelde üretilmiş iyi öznitelikler ile mümkündür. Son yıllarda uzamsal bilgi, hiperspektral veri sınıflandırması için gittikçe daha fazla önem kazanmakta, bunun sonucu olarak hiperspektral verilerden spektral özniteliklere ek olarak uzamsal özniteliklerin de çıkarılması ile birlikte çevre piksellerin etkisi öznitelik olarak sınıflandırıcılara verilmeye başlanmıştır [19]. Ek özniteliklerin çıkarılması ile birlikte çizgi tabanlı yeni sınıflandırma yöntemleri de anlamsal bölütleme probleminin çözümünde kendisine yer bulmaya başlamıştır [20]. Ayrıca uzamsal bilgilerin çıkarılmasıyla birlikte spektral bilginin ortamdaki kaynaklı deęişkenliğine de çözüm bulunmuştur. Morfolojik bilgilerin ve spektral verilerin bir araya getirilmesine dayanan öznitelik çıkarma işlemi DVM ile sınıflandırılmasından iyi sınıflandırma sonuçları elde edilmiştir [21].

Bu gelişmelere ek olarak son yıllarda görüntü işleme alanında çığır açan derin öğrenme tabanlı sınıflandırma ve derin öğrenme tabanlı öznitelik çıkarma yöntemleri hiperspektral veri kümelerine de uygulanmaya başlanmıştır.

Derin öğrenme kavramı, ilk defa 2014 yılında hiperspektral veri sınıflandırmasına girmiştir. Chen vd. tarafından gerçekleştirilen çalışmada öncelikle, klasik spektral bilginin sınıflandırılmasında istiflenmiş otomatik kodlayıcıların (autoencoders) uygunluğu doğrulanmış, ardından uzamsal özniteliklerin dâhil edildiği yeni bir sınıflandırma önerilmiştir. En yüksek sınıflandırma doğruluğunu elde edebilmek için, iki özniteliği birleştirecek yeni bir derin öğrenme çerçevesi kapsamında; temel bileşen analizi (PCA – Principle Component Analysis), derin öğrenme mimarisi ve lojistik regresyonun karışımını içeren bir sınıflandırıcı önerilmiştir. Özellikle, derin öğrenme mimarisi olarak, istiflenmiş otomatik tanımlayıcılar ile kullanışlı üst düzey özniteliklerin elde edilmesi sağlanmıştır. Elde edilen deneysel sonuçlar ile derin öğrenme tabanlı çerçevede yer alan sınıflandırıcıların rekabetçi bir performans sağladığı gösterilmiştir [22]. Chen vd. tarafından önerilen bir başka yöntemde ise derin yapay sinir ağı yapısı ile öznitelik çıkarımının ardından lojistik regresyon ile hiperspektral verilerin sınıflandırılması gerçekleştirilmiştir. Önerilen yöntemde öncelikle ham spektral bilgi ile öznitelik çıkarımı ve sınıflandırma gerçekleştirilmiş ardından veri kümesinden uzamsal bilgi çıkarılmıştır. Bu bilgi ile uzamsal bilginin tümleştirilmesi sonucu benzer yapay sinir ağı modeli ve sınıflandırıcı ile başarımın arttığı görülmüştür. Spektral ve uzamsal çerçevelere uygun olarak, önerilen derin yapay sinir ağının derinliğinin de çerçevesinin sınıflandırma performansı üzerinde önemli bir etkiye sahip olduğu görülmüştür [23].

Hu vd. tarafından gerçekleştirilen çalışmada ise derin evrimsel sinir ağına bulunan katmanların büyük çoğunluğunu içeren model ile Pavia Üniversitesi hiperspektral görüntüsünün sınıflandırılması sonucu oldukça dikkat çekici sonuçlar elde edilmiştir. Önerilen yapay sinir ağı modelinde girdi katmanı, evrişim katmanı, havuzlama katmanı, tam bağlı katman ve çıktı katmanı olmak üzere 5 adet katman bulunmaktadır. Önerilen bu sinir ağı modeli ile birlikte öznitelik çıkarımı ve sınıflandırıcı işlemi bir basamakta gerçekleştirilmiştir. Sınıflandırma başarımının DVM sınıflandırıcısından daha başarılı sonuçlar verdiği çalışmada gösterilmiştir [24].

Chen vd. tarafından gerçekleştirilen çalışmada derin yapay sinir ağı modelleriyle hiperspektral veriden üç boyutlu derin uzamsal ve spektral öznitelikler oluşturulmuştur. Evrişim ve toplama katmanları kullanılarak hiperspektral verilerden doğrusal olmayan, ayırt edici ve sabit derin öznitelikler çıkarılmıştır. Bunlara ek

olarak HSG verilerinin sınıflandırılmasında, eğitim verilerinin örnek sayısı ve verinin boyutu arasındaki dengesizliği ortadan kaldırmak amacıyla maliyet fonksiyonunda L2 (ikinci dereceden maliyet fonksiyonu) düzenlemesi yapılmıştır. Veri miktarını artırmak ve sınıflandırma başarımını artırmak için mevcut eğitim veri kümesi üzerinden; eğitim veri kümesi üzerine farklı seviyelerde gürültü eklenmesi ile yapay veri kümesi üretimi de gerçekleştirilmiştir. Yapay veri üretmek ve maliyet fonksiyonunu yeniden düzenleme işlemleri sonucu derin evrimsel sinir ağlarının hiperspektral veriler üzerindeki başarımı ciddi oranda artırmıştır [25].

Salman vd. tarafından gerçekleştirilen derin evrimsel sinir ağlarının öznetelik çıkarımını ve sınıflandırma işlemini tek basamakta toplayan çalışmada ise daha derin katmanlara sahip bir DESA mimarisi ile hiperspektral verilerin sınıflandırılması önerilmiş; K-en yakın komşuluk ve destek vektör makineleri sınıflandırıcılarına göre daha başarılı sonuçlar elde edilmiştir [26].

- **Houston Veri Kümesine Yönelik Gerçekleştirilmiş Çalışmalar**

Houston veri kümesi üzerinde oldukça yüksek sayıda çalışmalar gerçekleştirilmiş, çalışmaların birbirlerine olan üstünlükleri analiz edilmiştir. Genel olarak yapılan çalışmalarda LİDAR ve hiperspektral verilerinin kaynaştırılması ve sınıflandırma işleminin yapılmasından önce bu verilerden uzamsal ve biçimsel özneteliklerin çıkarılması gerçekleştirilmiştir. Buna ek olarak, özellik sayısındaki önemli artışın, çok yüksek boyutlu girdi problemine yol açabildiği görülmüş ve bu verilerin tümleştirilmesi için farklı yöntemler önerilmesine sebep olmuştur.

Liao vd. tarafından gerçekleştirilen çalışmada, çizge temelli yaklaşım ile LiDAR ve hiperspektral veriden biçimsel yöntemlerle çıkarılan öznetelikler tümleştirilmiştir. Sınıflandırıcı olarak DVM kullanılmış test veri kümesinde %94 oranında başarımla sağlamıştır [27].

Khodadadzadeh vd. tarafından gerçekleştirilen çalışmada EMAP yöntemi ile LiDAR ve HSG'lerden morfolojik profiller çıkarılmıştır. Alt uzay çok terimli lojistik regresyon (MLRsub) ile sınıflandırma işlemi ile sınıflandırma gerçekleştirilmiştir. Test verisi üzerinde %92.05 başarımla yakalanmıştır [28].

Aytaylan vd. çalışmada semantik bölütleme algoritması ile iki terimden oluşan tekli enerjili ve ikili enerjili yeni bir enerji fonksiyonu önerilmiştir. HySime algoritması ile boyut indirgemesinin önerildiği çalışmada enerji fonksiyonları tümleştirme için

kullanılmış ve DVM ile sınıflandırma gerçekleştirilmiştir. Başarımın %89.87'ye ulaştığı belirtilmiştir [29].

Rasti vd. tarafından önerilen bir başka yöntemde ise hiperspektral ve LiDAR füzyonu için yeni seyrek ve düşük rütbeli bir teknik önerilmiştir. Önerilen füzyon tekniği iki ana aşamadan oluşmaktadır. İlk olarak, sönüm profilleri (extinction profiles), sırasıyla, hiperspektral ve LiDAR verilerinden uzamsal bilgileri çıkarmak için kullanılmıştır. Ardından, Dik Toplam Değişim Analizi (Orthogonal Total Variation Component Analysis) kullanılarak öznitelikler tümlenmiştir. RO (Rastgele Orman) sınıflandırıcı ile sınıflandırma başarımı %92.45 olarak elde edilmiştir [30].

Veri kümesinde yer alan gölgeli bölgede test başarımının düşmesini önlemeye yönelik çalışmalar gerçekleştirilmiştir. Yüksek sınıflandırma başarımına sahip Luo vd. tarafından gerçekleştirilen çalışmada; bulut gölgesi ile karışan uzaktan algılama sahnelerinin sınıflandırılması için HSG ve LiDAR verilerini kaynaştırmak için yeni bir çerçeve önerilmiştir. Bu kapsamda gölge alan içeren ve içermeyen bölgeler ayrı ayrı işlenmekte ve buluttan kaynaklı gölge bölgelerde güvenilir eğitim örnekleri üretmek için yeni bir yöntem geliştirilmektedir. Sınıflandırma, gölge içermeyen (sınıflandırıcı, mevcut eğitim örnekleri tarafından eğitildiği) ve bulut gölge bölgeleri (sınıflandırıcının, üretilen eğitim örnekleri tarafından eğitildiği) spektral, biçimsel (HSG üzerinden çıkarılan morfolojik özellikler) ve yükseklik (LiDAR'dan üretilen morfolojik özellikler) özellikleri kullanılarak gerçekleştirilmiştir. Nihai sınıflandırma haritası gölge içermeyen ve bulut gölgesine sahip bölgelerinin sonuçlarının kaynaştırılmasıyla elde edilmiştir. Sonuç olarak önerilen yöntem ile sınıflandırma başarımının %95.92 olduğu görülmüştür [31].

Tez çalışması kapsamında ele alınan derin evrimsel sinir ağlarının Houston veri kümesinde kullanımına yönelik çalışmalar gerçekleştirilmiştir. Ghamisi vd. tarafından önerilen yöntemde öncelikle HSG ve LiDAR verileri üzerinden çıkarılan öznitelikler çizgi temelli yöntemlerle tümlenmiştir. Ardından evrim ve tam bağlı katman içeren ağ modeli ve lojistik regresyon sınıflandırıcısı ile sınıflandırma sonuçları oluşturulmuştur. Sonuç olarak bütün test verisi üzerinde sınıflandırma başarımının %91.02'ye ulaştığı gösterilmiştir [32]. Chen vd. gerçekleştirilen çalışmada veri tümlenmesi aşamasında da derin evrimsel sinir ağı kullanılmıştır. LiDAR ve hiperspektral verilerden komşu pikselleri de içerecek şekilde eğitim veri kümeleri oluşturulmuş; evrim katmanları ile etkin öznitelikler üretilmiştir. Ardından

tam bağılı sinir ağı; önceki DESA'lar tarafından elde edilen heterojen özellikleri kaynaştırmak üzere tasarlanmıştır. Sınıflandırma doğruluğunu daha da artırmak için ayrılma ve toplu normalleştirme stratejileri derin füzyon çerçevesinde benimsenmiştir. Bu yöntemin kullanılmasının ardından sınıflandırma başarımının %91.32 seviyelerine ulaştığı gösterilmiştir [33].

2. YAPAY SİNİR AĞLARI

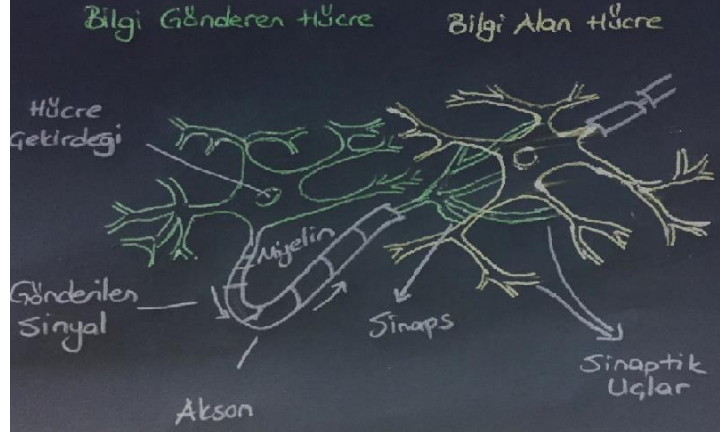
Bu bölümde tez kapsamında hiperspektral görüntülerden ve LiDAR verileri üzerinden öznitelik çıkarımı ve anlamsal bölütlemeye kullanılan derin yapay sinir ağı modelleri yönteminin sunulması gerçekleştirilmiştir.

2.1 Yapay Sinir Ağı Modeline Giriş

Yapay sinir ağları basit biyolojik sinir sisteminin çalışma şeklinden esinlenerek tasarlanan makine öğrenmesi yaklaşımıdır. Temel olarak girdi katmanı, ara katman ve çıktı katmanından oluşan yapay sinir ağları; ağırlıklandırılmış şekilde birbirlerine bağlanmış birçok işlem biriminden (nöronlar) oluşan matematiksel sistemlerdir. 1989 yılında George Cybenko tek gizli katmanlı yapay sinir ağları modellerinin “evrensel tahmin edici” olduğunu belirtmiş ve bir yapay sinir ağı modelinin sürekli ve çok değişkenli bir fonksiyonu yeterli miktarda nöron ve ağırlık kullanılması koşuluyla herhangi bir istenen ölçüde tahmin edebileceğini ortaya koymuştur. Buna ek olarak oluşabilecek tahmin hatalarının ise; yanlış belirlenmiş nöron ağırlıkları, öğrenme hızı parametreleri vb. gibi etmenlerden olduğunu belirtmiştir [34].

2.2 Biyolojik Sinir Ağı Matematiksel Modeli

Yapay bir sinir ağı modellemek için öncelikle matematiksel bir nöron modeline ihtiyaç duyulmaktadır. Nöronlar beynin temel hesaplama birimleridir. Temel olarak 3 bölümden oluşan nöron öncelikle dentritleri yardımıyla diğer hücrelerden aldığı bilgiyi hücre gövdesine kadar taşır. Kendi aksonuna ulaşan bilginin diğer hücrenin dentritine iletimini sinaps bağlantı elemanı üzerinden gerçekleştirir. Sinaps üzerindeki bağlantı elemanı ise iki hücre arasındaki etkileşim seviyesini belirlemektedir. Biyolojik sinir ağında yer alan elemanlar Şekil 2-1 ile verilmektedir.



Şekil 2-1: Biyolojik Sinir Ağı Modeli Elemanları

Kısaca biyolojik sinir ağı modeli ile matematiksel YSA model elemanlarının eşleştirmesi Tablo 2-1 ile verilmektedir.

Tablo 2-1: Biyolojik Sinir Ağı – Matematiksel Model Eşleştirme Tablosu

Biyolojik Sinir Ağı Elemanı	Matematiksel Model Elemanı
Nöron	İşlemci Elemanı
Dentrit	Birleştirme (Toplama) Fonksiyonu
Sinaps	Nöronlar arası bağlantı ağırlıkları ve sapma
Hücre Gövdesi	Aktivasyon Fonksiyonu
Akson	YSA Nöron Çıkışı

Oluşturulan YSA matematiksel modelinde çıktı değerinin denklemi 2-1 ile verilmektedir.


$$a = f(\sum_i^N (w_i x_i) + b) \quad 2-1$$

Burada a çıktı katmanında yer alan nöronun değerini, $f(x)$ lineer olmayan bir aktivasyon fonksiyonunu, w_i sinaptik aktarım ağırlığını, x_i nöronun girdisini, b sapma değerini ve N ise katmanda bulunan toplam nöron sayısını ifade etmektedir.

2.3 Yapay Sinir Ağları

Sinir ağları, katmanlara bağlı nöronların bir yapısı olarak modellenmiştir. İleri beslemeli yapay sinir ağı modelinde; belirli bir katmanın nöronlarının çıktıları, bir sonraki katmanın girdilerini bağlantı ağırlıkları ile oluşturur. Girdi her zaman ileri doğru (aktivasyon yönü) iletilmektedir. Bu yüzden aynı katmanda yer alan nöronlar birbirlerine bağlanamazlar. Girdi ve çıktı arasında yer alan katmanlar ise ara katman ya da gizli katman olarak adlandırılmaktadır. Tipik bir iki gizli katmana sahip YSA

modeli Şekil 2-2 ile verilmiştir. YSA modeline bağlı olarak; ilk katmanlarda girdi sinyalinden basit bilgiler çıkarılırken ikinci ve üçüncü gizli katmanlarda girdi sinyalinden daha karmaşık ve veri kümesine özel detaylı bilgiler çıkarılmaktadır. Derin sinir ağları yapılarında ilgili derinliği sağlayan katmanlar gizli katmanlardır. Gizli katmanların sayısının artması durumunda oluşturulan sinir ağı modeli daha derin ve karmaşıklığı artan bir yapıya dönüşmektedir. Buna ek olarak oluşturulan gizli katmanda yer alan nöron sayısı da YSA başarımını ve karmaşıklığını etkileyen önemli parametrelerden bir tanesidir [35].



Şekil 2-2: İki Gizli Katmanlı Yapay Sinir Ağı


Kurulan YSA modelinin eğitilmesi, kurulan ağda yer alan ağırlık parametrelerinin öğrenilmesi olarak da ifade edilebilmektedir. Eğitim esnasında ağırlıkların güncellenmesi ve ayarlanması geriye yayılım (backpropagation) ile gerçekleştirilmektedir.

2.4 Derin Evrimsel Sinir Ağlarına Genel Bir Bakış

Günümüzde evrimsel sinir ağları ve derin öğrenme tabanlı çözümler pek çok sorunda iyi sonuçlar vermektedir. Görüntü tanıma, ses tanıma ve doğal dil işleme gibi birçok farklı alanda uygulanabilmektedir. Özellikle görünür bantta elde edilmiş görüntülerin sınıflandırılmasında; olgun, başarılı ve popüler yöntem olan DESA (Derin Evrimsel Sinir Ağı) modeli resim üzerinde bir pikseli sınıflandırmaktan ziyade imgeyi genel olarak sınıflandırmaya yönelik çalışmalarda kullanılmıştır.

1998 yılında LeCun ve arkadaşları tarafından önerilen derin evrimsel sinir ağları ilk karmaşık problemlerin çözülmesinde kullanılmıştır. LeNet-5 olarak adlandırılan bu modelde el yazılarıyla oluşturulmuş rakam ve harflerin sınıflandırılması gerçekleştirilmiştir [36]. Bu gelişmenin ardından 2012 yılında Krizhevsky ve

arkadaşları 1000 farklı sınıfın yer aldığı 1.2 milyon veri kümesini içeren yüksek çözünürlüğe sahip görünür bantta yer alan görüntülerin sınıflandırılması problemine yönelik olarak mimarisi LeNet'e benzeyen AlexNet adında bir derin yapay sinir ağı modeli önermiştir [37]. Yarışma verisi olarak sunulan veri kümesi üzerinde en yüksek başarıma ulaşan bu mimari derin evrişim katmanlarına ek olarak aktivasyon fonksiyonu olarak RELU'yu önermiştir. AlexNet mimarisinde 5 farklı evrişim katmanı, 3 adet maksimum havuzlama katmanı, normalizasyon katmanları ve tam bağlı katmanlar yer almaktadır. AlexNet ile önerilen DESA modeli Şekil 2-3 ile verilmektedir. Katmanlarda gerçekleşen işlemler bu bölümün alt başlıklarında detaylandırılmaktadır.



Şekil 2-3: AlexNet DESA Mimarisi [37]

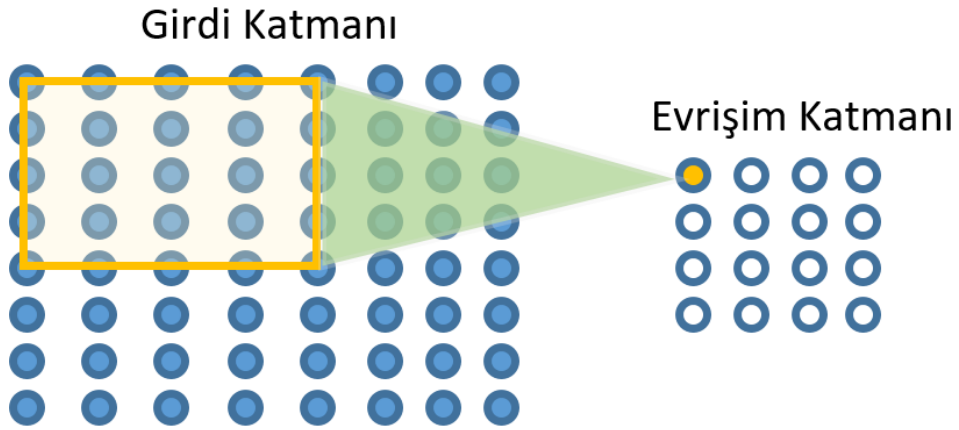
Bu gelişmelerin ardından araştırmacılar tarafından derin öğrenme tabanlı sınıflandırmaya yönelik çalışmalara hız verilmiştir. Özellikle artan veri miktarı ile birlikte DESA'da yer alan parametrelerin optimizasyonu daha yüksek başarımda gerçekleştirilmeye başlamıştır. 2015 yılında Google tarafından oluşturulan GoogLeNet ile yeni bir derin öğrenme mimarisi oluşturulmuştur. Bilinen popüler derin sinir ağı modeli olan VGGNet ile GoogLeNet ILSVRC 2014 yarışmasında en başarılı iki mimari olarak ilan edilmiştir [38].

Günümüzde gerçekleştirilen çalışmalarda ise özellikle AlexNet tarafından öğrenilen filtreler birçok çalışmada görüntülerden öznitelik çıkarma işleminde kullanılmaktadır. Özellikle ilk katmanda yer alan filtreler yardımıyla girdi verilerinden genel bilgiler ve özellikler çıkarılmaktadır. Verilerden öznitelik çıkarma gibi çalışmalarda da AlexNet tarafından öğrenilen filtreler kullanılmakla birlikte oldukça başarılı sonuçlar elde edilmektedir.

2.5 Derin Evrişimsel Sinir Ağı Mimarisi

Derin evrişimsel sinir ağlarında; girdi katmanı, evrişim katmanı, havuzlama katmanı, tam bağlı katman ve çıktı katmanı gibi katmanlar yer almaktadır. Ancak evrişimsel sinir ağları genellikle belirli bileşenler grubundan oluşmaktadır. Bu bileşenler, soruna göre özelleştirilmekte ve bahsi geçen bütün katmanları içermeyebilmektedir [48]. Derin evrişimsel sinir ağı temel olarak 3 temel yaklaşıma sahiptir.

1-) Yerel Alıcı Alanlar (Local Receptive Fields): Girdi sinyali ile gizli evrişim katmanında yer alan filtreler bölgesel alanlarda Şekil 2-4 ile gösterilen şekilde bağıllık kurmaktadır. Bağıllık kurulan bu alanlar ise yerel alıcı alan olarak adlandırılmaktadır. Herbir yerel alıcı alanın evrişim katmanında sonuç oluşturduğu bir nöron bulunmaktadır.



Şekil 2-4: Yerel Alıcı Alan Gösterimi


2-) Paylaşılan Ağırlıklar (Shared Weights): Evrişimsel sinir ağlarında her bir evrişim filtresine özel bir öznitelik haritası oluşmaktadır. Bu öznitelik haritası oluşturulurken imgenin bütün bölgesinden benzer özellikleri çıkaran filtreler kullanılmaktadır. Evrişim filtresinde yer alan parametreler ise paylaşılan ağırlık değerleri olarak adlandırılmaktadır [50]. Evrişimsel sinir ağları tarafından sağlanan bu özellik ile öğrenilen serbest parametre sayısı büyük ölçüde azaltılmaktadır. Bu sayede model üzerinde daha iyi bir genelleme sağlanabilmektedir.

3-) Alt Örnekleme: Alt örnekleme katmanında ise öznitelik haritalarının çözünürlüğü düşürülmektedir.

Bu bölümde DESA'da yer alan en önemli bileşenler özetlenecek, bu bileşenlerin sinir ağlarındaki rolü açıklanacak ve farklı bileşenlerin avantaj ve dezavantajları tartışılacaktır.

2.5.1 Evrişim Katmanı

Derin evrişimsel sinir ağlarının temel katmanı evrişim katmanıdır. Bu katman; öğrenilebilir bir dizi filtreden (çekirdeklerden) oluşmaktadır [48]. Her filtre ileri geçiş esnasında evrişim işleminden sorumludur. Her bir filtrenin girdi katmanı ile evrişim operasyonuna tabi tutulması sonucunda öznitelik haritaları oluşmaktadır. Oluşan bu öznitelik haritaları, ilgili evrişim katmanında saklı tutulmakta ve filtreye özel oluşturulmaktadır. Evrişim katmanı operasyonu Şekil 2-5 ile verilmektedir.



Şekil 2-5: Evrişim Katmanı Operasyonu ve Öznitelik Haritası Oluşumu

Evrişim katmanında yer alan filtrenin x eksenindeki boyutu K_x , y eksenindeki boyutu K_y ve derinliği d olan boyutlarda filtre tanımlaması yapılmaktadır. $K_x \times K_y \times d$ boyutunda oluşturulan filtre girdi sinyali ile aynı derinliğe sahip olmakla birlikte derinlik dışı boyutlarda ise girdi sinyalinin x ve y eksenindeki boyutlarından küçüktür. Filtre basamağı eğitilmeden önce tanımlanan serbest bir parametredir. Bu basamak filtrenin sinyal üzerinde bir kerede yer değiştireceği boyutu belirtmektedir. Daha büyük basamağa sahip filtreleme işlemi ile çıkış sinyalinin boyutu daha da küçülmektedir. Girdi sinyalinin boyutu $I_x \times I_y \times d$ ve evrişim katmanında n farklı filtrenin kullanıldığı varsayıldığında çıktı sinyalinin boyutu $O_x \times O_y \times n$ olmaktadır. Evrişim katmanından sonra oluşan sinyalin boyutunun değişimi denklem 2-2 ve 2-3 ile verilmektedir. Denklemlerde yer alan s parametresi filtre basamağını ifade etmektedir.

$$O_x = \frac{O_x - K_x}{s} + 1 \quad 2-2$$

$$O_y = \frac{I_y - K_y}{s} + 1 \quad 2-3$$

Örnek olarak girdi sinyalinin boyutu 1 x 144 x 1, evrişim filtresinin boyutu 1 x 5 x 1 ve 10 farklı evrişim filtresi kullanıldığı varsayımıyla evrişim basamak değerinin 1 olması durumunda çıktı sinyalinin boyutu 1 x 140 x 10 olacaktır.

İleri besleme esnasında herhangi bir öznitelik haritasının belirli pozisyonundaki nöronuna ait çıktının denklemi 2-4 ile verilmiştir. Burada m x m bir evrişim filtresini, l katman numarasını, y ilgili katmanın çıktısının aktivasyon fonksiyonundan geçirilmiş değerini, w_{ab} filtrenin a, b noktasındaki değerini göstermektedir. Evrişim katmanının çıktısına aktivasyon fonksiyonu uygulanması denklemi 2-5 ile verilmektedir.

$$x_{ij}^l = \sum_{a=0}^{m-1} \sum_{b=0}^{m-1} w_{ab} y_{(i+a)(j+b)}^{l-1} \quad 2-4$$

$$y_{ij}^l = \sigma(x_{ij}^l) \quad 2-5$$

2.5.2 Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu, bir ünitenin girdi nöronunun aktivasyon seviyesini bir çıkış sinyaline dönüştürmek için kullanılan bir fonksiyondur.

Yaygın olarak kullanılan aktivasyon fonksiyonları olan Sigmoid, tanh ve RELU doğrusal olmayan fonksiyonlardır. Yaygın olarak kullanılan aktivasyon fonksiyonları ve türevleri Tablo 2-2 ile verilmektedir. Buna ek olarak aktivasyon fonksiyonlarına ait grafiksel gösterimler ise Şekil 2-6 ile verilmektedir. Yapay sinir ağlarının doğrusal olmayan bir yapıya sahip olmaları aktivasyon fonksiyonundan kaynaklıdır [50]. Aktivasyon fonksiyonlarının kolay türevlenebilir olması gerekmektedir, bu özelliği sonucu maliyet fonksiyonu üzerinden ağırlıkların güncellenmesi sağlanmaktadır.

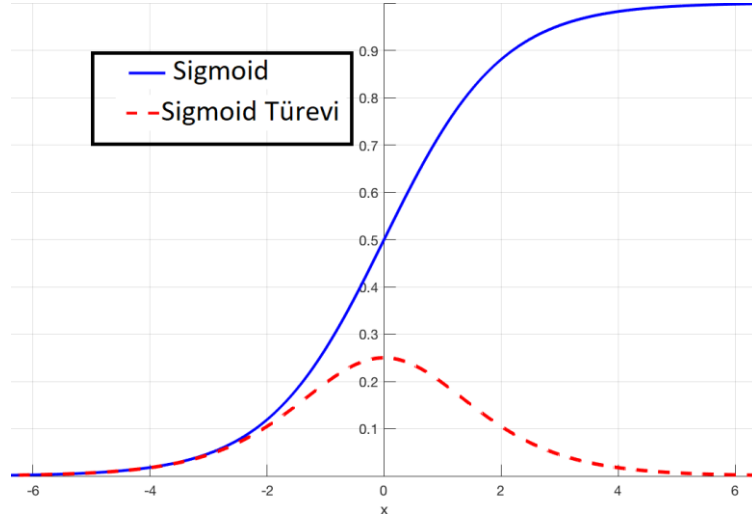
Tablo 2-2: Yaygın olarak kullanılan Aktivasyon Fonksiyonları ve Türevleri

Aktivasyon Fonksiyonu	Matematiksel Denklemler
Sigmoid	$f(x) = \frac{1}{1+e^{-x}}, f'(x) = f(x)(1-f(x))$
Tanh	$f(x) = \tanh(x) = \frac{2}{1+e^{-2x}} - 1, f'(x) = 1-f(x)^2$
RELU	$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}, f'(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$

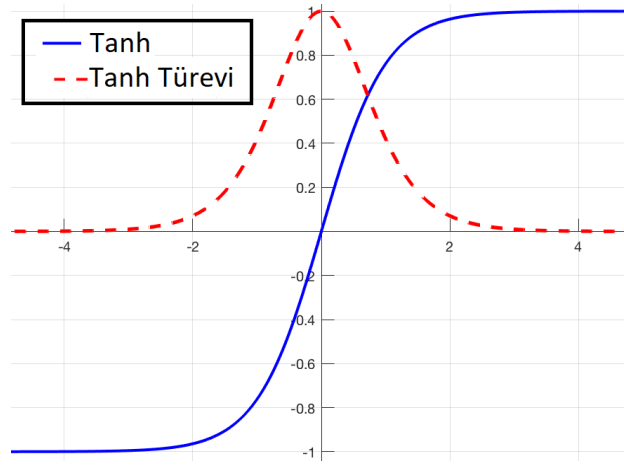
RELU aktivasyon fonksiyonu evrimsel sinir ağlarının kullanımının yaygınlaşmasının ardından yaygın olarak kullanılmaya başlanılmıştır. Diğer aktivasyon fonksiyonlarına göre hesaplama işlemi hızının daha yüksek olması özellikle AlexNet çalışmasında eğitim hızını artırması amacıyla tercih edilmiştir [37].

Buna ek olarak RELU aktivasyon fonksiyonu $y = 0$ fonksiyonuna göre simetrik değildir ve bir lojistik sigmoidden daha kademeli bir azalışa sahiptir. Bu özelliği ile birlikte geri yayılım esnasında öğrenme işleminde daha dayanıklı sonuçlar elde edilmesi sağlanmaktadır. Sonuç olarak, DESA eğitimi sırasında RELU ile daha iyi bir optimizasyon sağlanmaktadır [50].

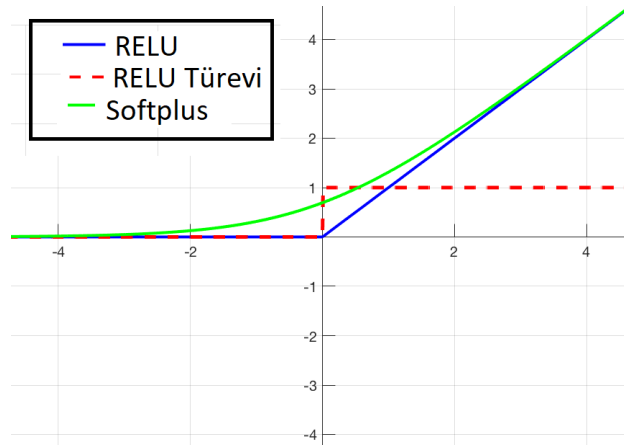
Bengio vd. tarafından gerçekleştirilen çalışmada Sigmoid aktivasyon fonksiyonuna sahip YSA'larda "*vanishing gradient*" olarak adlandırılan problemin oluşabildiği belirtilmiştir [39]. Kısaca bu problemi tariflemek gerekirse bir DESA'nın alt katmanlarının gradyanları 0 derecesine sahip olduğu zaman kaybolma eğilimleri oluşur. Bu kaybolan eğimler yavaş optimizasyon yaklaşmasına neden olur ve bazı durumlarda maliyet fonksiyonu yerel minimuma yaklaşır. ReLU'da ise çıktı 0'ın üstünde etkinleştirildiğinde, kısmi türevi 1'dir. Böylece DESA'da yer alan aktif gizli birimlerin gradyanlarının yok olma (vanishing gradient) eğilimleri yoktur [40].



(a)



(b)




(c)

Şekil 2-6: Aktivasyon fonksiyonları ve Türevleri ((a) Sigmoid –(b) tanh – (c)ReLU)

2.5.3 Havuzlama Katmanı (Pooling Layers)

Havuzlama katmanları genel olarak verinin boyutunu indirgemeye yönelik katmanlardır. Genel olarak havuzlama katmanında kullanılan yöntem belirlenen çerçevede maksimum değeri seçme operasyonudur. Buna ek olarak belirlenen çerçevede ortalama değeri alma, minimum değeri seçme gibi işlemleri gerçekleştiren havuzlama katmanları bulunmaktadır. Örnek bir havuzlama katmanı operasyonu Şekil 2-7 ile verilmektedir. İlgili şekilde maksimum değeri seçen bir havuzlama operasyonu tercih edilmiştir.



Şekil 2-7: Havuzlama Katmanı Örneği

2.5.4 Tam Bağlı Sinir Ağı Katmanı (Fully-Connected Layer)

Tam bağlı bir katmandaki nöronlar bir önceki katmandaki tüm etkinleşmelere tam bağlantılara sahiptir ve üretilen aktivasyon haritalarına dayalı büyük sınıflandırma işleminden sorumludurlar. Bu katmanda ileri besleme esnasında oluşan matematiksel ifade denklem 2-6 ile verilmektedir.

$$u_i^l = \sum_j w_{ji}^{l-1} y_j^{l-1} \quad 2-6$$
$$y_i^l = f(u_i^l) + b^{(l)}$$


Bu denklemde yer alan l , $(l - 1)$ katman numarası, i, j ise nöron numarasını, y_i^l oluşturulan çıktı katmanındaki değeri, w_{ji}^{l-1} gizli katmanda yer alan ağırlık değerini, y_j^{l-1} girdi nöronlarının değerini, u_i^l aktivasyon fonksiyonu öncesi çıktı katmanı değeri ve $b^{(l)}$ ise sapma değerini vermektedir. Burada belirtilen $f(\cdot)$ fonksiyonu ise aktivasyon fonksiyonunu ifade etmektedir.

2.5.5 Aşırı Uyum (Overfitting)

Aşırı uyum, yapay sinir ağı eğitiminde ortaya çıkan bir sorundur. Bir model eğitim verilerine aşırı uyumlu hale geldiğinde, genelleme yeteneğini kaybeder. Sinir ağı

modelinin gürültüyü de içeren eğitim veri kümesini eğitim esnasında büyük ölçüde öğrenmesi sonucu model eğitim veri kümesindeki daha genel bilgileri yakalayamayabilmektedir. DESA'larda eğitilmesi gereken çok sayıda filtre ağırlığı vardır, bu nedenle aşırı uyum, çok az sayıda işaretlenmiş eğitim veri kümesi nedeniyle oluşabilir [48].

Bırakma katmanları (dropout layer) aşırı uyumun önlenmesini düğüm ve bağlantıların ağı eğitim esnasında rastgele düşürülmesiyle sağlamaktadırlar. Bırakma işlemi sayesinde, eğitim veri kümesi ile yapay sinir ağı adaptasyonu sınırlandırılmakta ve dolayısıyla ağırlıkların bu verilere aşırı uyması engellenmektedir [49]. Bırakma katmanlarının kullanılması durumunda genel olarak eğitim ve doğrulama verileri arasındaki performans farkı genel olarak azalmaktadır. Bırakma katmanları yalnızca YSA modelinin eğitimi esnasında kullanılmaktadır. Test ve doğrulamada bırakma katmanları kullanılmamaktadır. Tipik bir bırakma katmanı ile nöronların bağlantılarının kesilmesi durumu Şekil 2-8 ile verilmiştir.



Şekil 2-8: Bırakma katmanı öncesi ve sonrası sinir ağı yapısı

2.5.6 Yiğın Normalizasyonu (Batch Normalization)

Son yıllarda DESA modellerinde özellikle evrişim ya da tam bağlı katmanın çıktısını normalize etmek verilerin standartlaştırılması için oldukça etkili bir yöntemdir. Genellikle aktivasyon fonksiyonundan önce gerçekleştirilen bu işlem katman çıktısının normalizasyonu olarak da adlandırılmaktadır. Yiğın normalizasyonu ile

katmanların çıktılarının belli limitlerde tutulması sağlanmakta ve bu da eğitimin hızlı bir şekilde gerçekleşmesi sağlamaktadır.

Yığın normalizasyonu ile birlikte kovaryans kayması (covariance shift) azaltılmaktadır. Bunu sağlayan sonuç ise her bir nöronun aktivasyonunun bir Gauss dağılımı haline getirilmesi ve bunun sonucu olarak nöronun aşırı aktif ya da aşırı pasif olmasının engellenmiş olmasıdır.

Katmanda bulunan yığında M adet girdi verisi bulunmakta ve her bir girdi verisi X_i , $i = 1 \dots M$ verilmektedir. Yığının ortalama değeri μ_B denklem 2-7 ile hesaplanmıştır. Ardından yığının standart sapmasının denklemi 2-8 ile verilmektedir. Sonuç olarak yığın normalizasyonu sonucu oluşan yeni değerler Y_i ile ifade edilmekte ve denklem 2-9 ile verilmektedir.

$$\mu_B = \frac{1}{M} \sum_{i=1}^M X_i \quad 2-7$$

$$\sigma_B = \frac{1}{M} \sum_{i=1}^M (X_i - \mu_B)^2 \quad 2-8$$

$$Y_i = \frac{X_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \quad 2-9$$

Katman normalizasyonunun ardından yeni katmanlara normalizasyonu gerçekleştirilmiş değerler girdi olarak verilmektedir.


2.5.7 Çıktı Katmanı (Output Layer)

DESA'da genel olarak çıktı katmanları ağ sonucu oluşan çıktı değerlerinden, girdi verisinin bulunabileceği sınıf üzerinde olasılık dağılımı sağlar. Bu katmanda softmax, sigmoid veya oklid gibi kullanılabilecek birçok fonksiyon bulunmaktadır.

Softmax özellikle derin evrişim sinir ağlarında kullanılan en yaygın fonksiyondur. Özellikle çok sınıflı sınıflandırma probleminin çözümünde, çıkışta oluşan değerlerin her bir sınıfta bulunma olasılığı tayin edilmektedir. Öncelikle softmax fonksiyonuna yönelik denklem 2-10 ile verilmiştir. Denklem içerisinde K toplam sınıf sayısını, j herhangi bir sınıf numarasını, j ise softmax operasyonu öncesi nöronun değerini göstermektedir. Örnek bir softmax operasyonu ise Şekil 2-9 ile verilmektedir. Test verisinin hangi sınıfta yer alabileceğine dair olasılıksal çıktı değerleri softmax ile hesaplanmakta ve bir test verisinin bulunabileceği sınıfların olasılık değerleri fonksiyonun çıktısı olarak verilmektedir.

$$\sigma(y)_j = \frac{e^y}{\sum_{k=1}^K e_k^y}, j = 1, 2, \dots, K$$

2-10



Şekil 2-9: YSA ve softmax fonksiyonu ile çok sınıflı sınıflandırma

2.6 Derin Evrişimsel Sinir Ağı Eğitimi ve Geri Yayılım (Backpropagation)

Evrişimsel sinir ağları, neredeyse her makine öğrenme problemi gibi eğitim verilerine dayalı olarak eğitilir. Genellikle, geri yayılım algoritması ile eğitilirler. Bir evrişim katmanının bir öznitelik haritasında, tüm nöronlar aynı ağırlıkları ve sapma değerlerini paylaşırlar. Bundan dolayı, genel olarak evrişim katmanında öğrenme işlemi daha az parametre ile gerçekleştirilmektedir. DESA verilen eğitim verileri için evrişim filtresinin parametrelerini veya ağırlıklarını ayarlamayı ve güncellemeyi gerektirir. Geri yayılım, sinir ağlarındaki ağırlıkların gradyan tabanlı optimizasyonunu gerçekleştirmek için gerekli hataları hesaplayarak düzeltmede etkili bir yöntemdir. Maliyet fonksiyonunu (veya hata fonksiyonu) en aza indiren ağırlıkların doğru kombinasyonu optimizasyon probleminin çözümüdür. Yöntem, her yinelemede (iterasyon-döngüde) maliyet fonksiyonunun gradyanının hesaplanmasını gerektirir, bu nedenle maliyet fonksiyonu, her yineleme adımında devam ettirilebilir ve türevlenebilir olmalıdır.

Eğitimsiz bir DESA'nın başlangıç ağırlıkları rastgele seçilir. Sonuç olarak eğitimden önce, sinir ağı, girdi verisi ile onun etiketlenmiş çıktısı arasında hiçbir ilişki bulunmadığı için ağ girişi için anlamlı öngörülerde bulunamaz. Yapay sinir ağı

modelini, doğru sınıftan veriler ve etiketli çıktıları içeren bir eğitim verisi kümesine maruz bırakarak ağırlıklar ayarlanır. Eğitim, ağırlıkların, istenilen çıktı ile yapay sinir ağı modelinin çıktısı arasındaki farkın asgariye indirildiği şekilde uyarlanmasıdır; bu, yapay sinir ağı modelinin sınıflandırma için gereken doğru özellikleri bulmak üzere eğitildiği anlamına gelir. Sinir ağına, ağırlıkların adapte edildiği ileri ve geri geçişlerinde iki hesaplama fazı vardır.

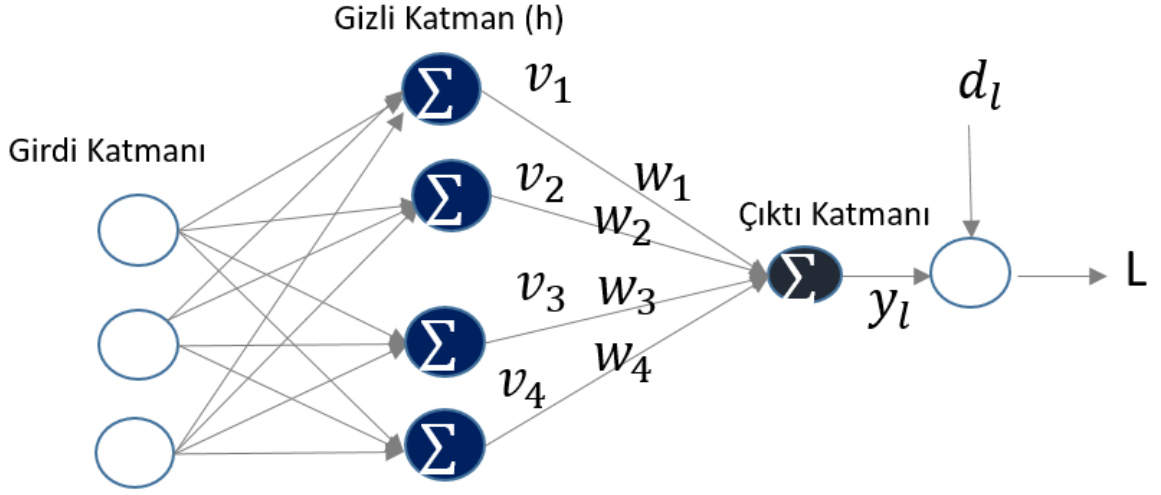
- İleri besleme esnasında; bir sinyal/görüntü girdi katmanı üzerinden yapay sinir ağı modeline beslenir. İlk ağı katmanı bir aktivasyon haritası çıkarır. Ardından, bu aktivasyon haritası, başka gizli harekete geçirme eşlemesini hesaplayan ilk gizli katmanın girdisidir. Bu aktivasyon haritasının değerlerini ikinci gizli katmanın girişleri olarak kullanarak, yine bir başka aktivasyon haritası hesaplanır. Bu işlemi her kat için gerçekleştirmek sonuçta ağı çıktısını sağlayacaktır.
- Geri besleme esnasında; ağırlıklar geri yayılım ile güncellenir. Geri yayılımın bir döngüsü birden çok parçadan oluşur, genellikle bir eğitim verisi için birden çok işlem yapılır:
 - Maliyet Fonksiyonu: İleri besleme de, girişler ve istenen çıktı değerleri bilinmektedir. Önceden tanımlanmış bir maliyet fonksiyonu L , giriş ve istenen çıktı arasındaki farkı en aza indirmek için kullanılır. Amacı, ağırlıkları, maliyet fonksiyon değerini düşürecek şekilde ayarlamaktır.
 - Geri Yayılım: Geriye doğru yayılım esnasında, maliyet fonksiyonuna en çok katkıda bulunan ağırlıkların belirlenmesi sağlanır.
 - Ağırlık Güncellemesi: Son aşamada ise, tüm ağırlıklar, maliyet fonksiyonunun gradyanının negatif yönünde güncellenir.

Dolayısıyla, geri yayılım probleminin özü, ağı ağırlıklarına göre maliyet fonksiyonunun gradyanını hesaplamaktır. Kısmi türevin hesaplanması, kayıp fonksiyon değerini en aza indirmek için zorunludur (geriye doğru geçişte yapılır). Stochastic Gradient Descent (SGD), sinir ağlarını en iyi duruma getirmek ve ağırlıkları en iyi şekilde güncellemek için kullanılan en yaygın yoldur.

- **Tipik Çok Katmanlı Yapay Sinir Ağının Eğitimi Örneği**

Tipik tek gizli katmana ileri beslemeli yapay sinir ağının eğitim süreci ve geri yayılım ile ağırlıkların güncellenmesi aşamaları örnek üzerinden tariflenmektedir [51].

Öncelikle tipik bir YSA modeli Şekil 2-10 ile verilmektedir. Tek bir gizli katmandan oluşan ağ modeli üzerinden eğitim ve ağırlık güncellemeleri matematiksel denklemler ile anlatılmaktadır.



Şekil 2-10: Basit tek gizli katmanlı YSA

Öncelikle maliyet fonksiyonu belirlenmekte ve belirlenen maliyet fonksiyonuna özel hata hesaplanmaktadır. L maliyet fonksiyonunu, e_l ise beklenen çıktı olan d_l ile ağ çıktısı y_l arasındaki farkı, l nöron numarasını, 0 ise çıktı katmanı olduğunu göstermektedir. Çıkış katmanından önce yer alan gizli katmanın çıktı değerleri ise v_j ile çıktı katmanı ağırlık değerleri w_j^0 ile verilmiştir.

$$L = \frac{1}{2} \sum_l (e_l)^2 \quad 2-11$$

$$e_l = d_l - y_l$$

$$y_l = \sum_j w_{jl}^0 v_j$$

Jacobian ise zincir kuralı oluşturacak şekilde 2-12 ile verilmiştir.

$$\frac{\partial L}{\partial w_{jl}^0} = \frac{\partial L}{\partial e_l} \frac{\partial e_l}{\partial y_l} \frac{\partial y_l}{\partial w_{jl}^0} \quad 2-12$$

Kısmi türevler hesaplanır ve denklemden yerine konulursa denklemin 2-13 oluşmaktadır:

$$\frac{\partial L}{\partial w_{jl}^0} = -v_j e_l \quad 2-13$$

SGD güncelleme kuralı kullanılarak çıktı katmanında yer alan ağırlıkların güncellemesi 2-14 denklemi ile verilmektedir.

$$w_{jl}^0(n+1) = w_{jl}^0(n) + \alpha(n)v_j e_l \quad 2-14$$

Çıktı ağırlıklarının güncelledikten sonra gizli katmanlardaki ağırlıkların güncellenme işlemi gerçekleştirilmektedir. Geriye doğru bir geçiş olduğu için öncelikle çıkış katmanlarının gradyanları hesaplanır, sonrasında ise gizli katmanların gradyanları hesaplanma işlemi gerçekleştirir. Gizli katmanda yer alan ağırlıklara yönelik Jacobian hesaplaması 2-15 ile verilmektedir.

$$\frac{\partial L}{\partial w_{ij}^h} = \frac{\partial L}{\partial v_j} \frac{\partial v_j}{\partial y_l} \frac{\partial z_j}{\partial w_{ij}^h} \quad 2-15$$

Jacobian hesaplamasının ardından kısmi türevlerin hesaplaması gerçekleştirilir.

$$\frac{\partial L}{\partial w_{ij}^h} = -x_i \sigma_j'(z_j) \sum_l e_l w_{jl}^0 \quad 2-16$$

Ardından gizli katmanlarda yer alan ağırlıklar için uygulanan güncelleme kuralı denklemi 2-17 ile verilmektedir.

$$w_{ij}^h(n+1) = w_{ij}^h(n) + \alpha(n)x_i \sigma_j'(z_j) \sum_l e_l w_{jl}^0 \quad 2-17$$

Son olarak, bir test veri kümesi kullanılarak ağırlık başarımı kontrol edilmektedir. Test veri kümesi eğitimde kullanılmayan bir veridir. Daha fazla sayıda ve çeşitlilikte eğitim verisi oluşturulması durumunda geri yayılım ile ağırlık değerleri daha iyi bir şekilde ayarlanabilir.

2.6.1 Maliyet Fonksiyonları

L maliyet fonksiyonunun değeri, bir eğitim görüntüsünün YSA'dan elde edilen çıktısı ile bilinen çıktı sonucu arasındaki farkı temsil etmektedir. Bu maliyet fonksiyonuna yönelik olarak iki temel varsayım bulunmaktadır.

- Maliyet fonksiyonu her partinin YSA'dan geçirilmesi sonucu değerlendirilir ve hata değerlerinin ortalaması alınır. Belirlenen hata değerleri ile ağırlık güncellemesi gerçekleştirilir.
- Maliyet fonksiyonu YSA çıktılarının bir fonksiyonu olarak tanımlanabilmelidir.

Yaygın olarak YSA'larında kullanılan maliyet fonksiyonları Tablo 2-3 ile verilmektedir. İlgili fonksiyonlarda yer alan \hat{x}_i beklenen çıktı değerini, x_i ağırlık çıktı değerini ve N ise sınıf sayısını ifade etmektedir.

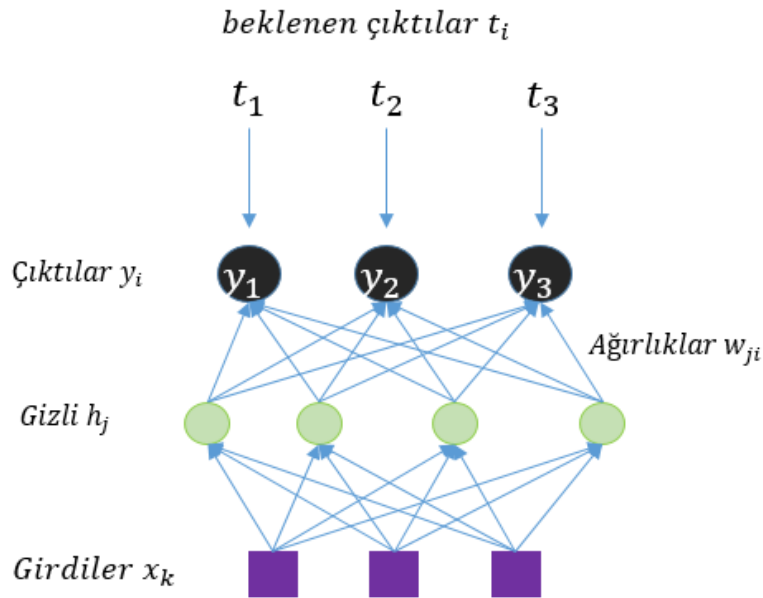
Tablo 2-3: Yaygın Kullanılan Maliyet Fonksiyonları Matematiksel İfadeleri

Maliyet Fonksiyonu	Denklem
İkinci Dereceden Maliyet Fonk. (Quadratic Cost Function)	$L = \frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2$
Çapraz Entropi Maliyet Fonk. (Cross Entropy Cost Function)	$L = \frac{1}{N} \sum_{i=1}^N \hat{x}_i \ln(x_i) + (1 - \hat{x}_i) \ln(1 - x_i)$
Üstel Maliyet Fonk. (Exponential Cost Function)	$L = \frac{1}{N} \tau \exp \frac{1}{\tau} \sum_{i=1}^N (x_i - \hat{x}_i)^2$

Derin evrişimsel sinir ağlarında genel olarak sınıflandırma işleminde softmax fonksiyonu kullanılmaktadır [48]. Geri yayılımda ise hata fonksiyonu olarak Çapraz Entropi Maliyet fonksiyonu kullanılmaktadır.

- Softmax Fonsiyonu ile Sınıflandırma ve Çapraz Entropi Hesabı

Sınıflandırma probleminde ikiden fazla sınıflı durum bulunuyorsa standart olarak softmax çıktı katmanı kullanılmaktadır. Softmax işlemi ile birlikte sınıflar üzerinde ayrık olasılık dağılımı tahmin edilebilmektedir. Çapraz entropi maliyet fonksiyonu ise istenen çıktı ile ağın çıktısı arasındaki hatayı ifade etmektedir.



Şekil 2-11: Çapraz entropi maliyet fonksiyonu geri yayılımı

Örnek bir çapraz entropi maliyet fonksiyonunu içeren YSA Şekil 2-11 ile verilmektedir. Matematiksel bağıntılarına yönelik detaylar ise basamaklar halinde

sunulmaktadır. Burada y_i YSA'nın çıkış vektörünü, s_i gizli katman çıktı değeri, t_i çıkış katmanında beklenen etiket değerini göstermektedir.

İleri besleme esnasında oluşan aktivasyon fonksiyonu öncesi 2-18 ile verilmektedir.

$$s_i = \sum_{j=1}^J h_j w_{ji} \quad 2-18$$

İleri besleme esnasında softmax fonksiyonu çıktı değeri 2-19 ile verilmiştir.

$$y_i = \frac{e^{s_i}}{\sum_c^{n\text{class}} e^{s_c}} \quad 2-19$$

Çok sınıflı çapraz entropi maliyet fonksiyonu aşağıdaki gibi hesaplanmaktadır.

$$E = - \sum_{i=1}^{n\text{class}} t_i \log(y_i) \quad 2-20$$

Maliyet fonksiyonunun hesaplanmasının ardından gradyanların hesabı gerçekleştirilir. Bu hesaplama gerçekleştirilirken kısmi türevler hesaplanmaktadır:

$$\frac{\partial E}{\partial y_i} = - \frac{t_i}{y_i} \quad 2-21$$

$$\frac{\partial y_i}{\partial s_k} = \begin{cases} \frac{e^{s_i}}{\sum_c^{n\text{class}} e^{s_c}} - \left(\frac{e^{s_i}}{\sum_c^{n\text{class}} e^{s_c}} \right)^2 & i = k \\ - \left(\frac{e^{s_i}}{\sum_c^{n\text{class}} e^{s_c}} \right)^2 & i \neq k \end{cases} \quad 2-22$$

$$\frac{\partial y_i}{\partial s_k} = \begin{cases} y_i(1 - y_i) & i = k \\ -y_i y_k & i \neq k \end{cases}$$

$$\begin{aligned} \frac{\partial E}{\partial s_i} &= \sum_k^{n\text{class}} \frac{\partial E}{\partial y_k} \frac{\partial y_k}{\partial s_i} \\ &= \frac{\partial E}{\partial y_i} \frac{\partial y_i}{\partial s_i} - \sum_{k \neq i} t_k y_i \\ &= -t_i(1 - y_i) + \sum_{k \neq i} t_k y_i \\ &= -t_i(1 - y_i) + \sum_{k \neq i} t_k y_i \\ &= -t_i + y_i \sum_{k \neq i} t_k \\ \frac{\partial E}{\partial s_i} &= y_i - t_i \end{aligned} \quad 2-23$$

Kısmi türevlerin hesaplanması sonucu en üst katmanda yer alan ağırlıkların gradyan hesabı gerçekleştirilir.

$$\begin{aligned}\frac{\partial E}{\partial w_{ji}} &= - \sum_i^{n_{class}} \frac{\partial E}{\partial s_i} \frac{\partial s_i}{\partial w_{ji}} \\ &= - (y_i - t_i) h_j\end{aligned}\quad 2-24$$

Gizli katmanda yer alan j indeksli gizli katmanın gradyan hesabına yönelik denklem ise 2-25 ile verilmiştir.

$$\begin{aligned}\frac{\partial E}{\partial s_j^1} &= - \sum_i^{n_{class}} \frac{\partial E}{\partial s_i} \frac{\partial s_i}{\partial h_j} \frac{\partial h_j}{\partial s_j^1} \\ &= - \sum_i^{n_{class}} (y_i - t_i) (w_{ji}) (h_j (1 - h_j))\end{aligned}\quad 2-25$$

2.6.2 SGD Methodu


Gradient Descent (GD) ve Stochastic Gradient Descent (SGD) yöntemleri parametreleri aranan bir maliyet fonksiyonunun iterasyonlar halinde minimumunu bulmayı amaçlamaktadır. Bu amaçla parametreler güncelleme kuralına göre SGD yardımıyla güncellenir. Büyük veri kümelerinde GD'yi kullanarak kesin gradyanları hesaplamak oldukça maliyetli bir işlemdir, çünkü bu yöntem tek bir iterasyon adımımda tek bir güncelleme gerçekleştirmek için tüm eğitim örnekleri boyunca çalışır. Stochastic Gradient Descent'de gerçek gradyanın bir yaklaşığı hesaplanır. Bu, bir parametre güncellemesi için yalnızca bir veya bir takım eğitim örnekleri kullanılarak yapılır.

SGD, θ ile parametreleştirilen maliyet fonksiyonu $L(\theta)$ 'nin minimum noktasını bulmaya çalışan bir yöntemdir. Bunu kayıp fonksiyon değerini düşürmek için, parametrelere göre, maliyet fonksiyonunun $\nabla_{\theta} L(\theta)$ negatif eğim yönündeki θ parametrelerini güncelleyerek başarır. Öğrenme hızı η , yerel veya global minimuma erişmek için basamak boyutunu belirler. Güncelleme kuralı, denklem 2-26 ile verilmiştir.

$$\theta = \theta - \eta \nabla_{\theta} L(\theta) \quad 2-26$$

Uygun öğrenme hızının veya basamak boyutunun belirlenmesi, genellikle karmaşık bir sorundur. Çok yüksek öğrenme oranları uygulamak, düşük performansla neden

olabilir ya da çok düşük öğrenme oranları, yakınsamanın oldukça yavaşlamasına neden olabilmektedir. Öğrenme hızı parametresi, performansı artırmak için SGD algoritmasının bir uzantısı olarak kullanılır [48]. Öğrenme hızı çizelgelemesinde, öğrenme oranı yineleme sayısının azalan bir fonksiyonudur. Bu nedenle, ilk iterasyonların öğrenme oranları daha büyüktür ve dolayısıyla daha büyük parametre değişikliklerine neden olur. Daha sonraki iterasyonların ince ayarlamadan sorumlu öğrenme oranları daha düşüktür. Öğrenme oranlarının düşük ya da yüksek seviyede bulunması durumunda maliyet fonksiyonunun değerinin iterasyona bağlı değişimi Şekil 2-12 ile verilmektedir.



Şekil 2-12: Öğrenme Oranını Maliyet Fonksiyonuna Etkisi

2.7 Hiperparametrelerin Ayarlanması

Eğitim süreci içerisinde, öğrenme hızı, bırakma ve yığın boyutu ile ilgili birçok seçenek bulunmaktadır. Toplu boyut, bir çağda (epoch) kullanılan eğitim örneklerinin sayısıdır. Yığın boyutu arttıkça, daha fazla bellek alanı gerekir. Bunlar, eğitimden önce tanımlanması gereken, hiperparametrelerin, yani ağ ayarlarının örnekleridir. Dahası, evrişim çekirdeği boyutu, doğrusal olmayan aktivasyon fonksiyonları, maliyet fonksiyonu ve ağ katmanlarının sayısı gibi ağ mimarisi ile ilgili birçok hiperparametre bulunmaktadır. Hiperparametrenin seçimi, eğitim veri kümesinin boyutuna ve türüne bağlıdır. Parametrelerin seçilmesine ilişkin sıkı kurallar yoktur, yalnızca genel yönergeler bulunmaktadır [50].

Derin öğrenmede, kayıp fonksiyonu değeri, çağ başına izlenir. Bir çağ, eğitim sırasında ileri ve geri geçişlerdir. Eğitim sırasında kaybı izleyerek, uygun bir öğrenme oranının seçilip seçilmediğini gözlemleyebiliyor. Yüksek öğrenim oranları

ilk etapta kaybı daha hızlı düşürecek, ancak sonunda enerji seviyesindeki en uygun olmayan bir yerde sinir ağının yakınsamasına sebep olacaktır. Üstelik; aşırı uygunluk derecesi, eğitim ve doğrulama arasındaki doğruluk farkından anlaşılabilir.

Hiperparametre ayarlama, sinir ağı eğitiminin önemli fakat karmaşık bir parçasıdır. Doğru ayarları seçmek, istenen sonuçların elde edilmesinde önemlidir, ve genellikle deneyime dayanır. Özellikle karşılıklı olarak birbirine bağlı çok sayıda farklı ayarı seçmek, bunun şeffaf olmayan bir süreç olmasına neden olur. Üstelik, parametre seçme sürecinde, örneğin bilgisayar belleği kısıtlı olduğu için, ödün vermeler doğasında bulunmaktadır.

Tez kapsamında hiperparametrelerin belirlenmesi esnasında birçok farklı hiperparametrenin denenmesi gerçekleştirilmiştir. Eğitime başlamadan evvel ağırlıkların ilklendirilmesi -0.05 ile 0.05 arasında Gaussian dağılım ile rastgele atanmıştır. Ardından öğrenme oranı belirlenmesinde 0.08 ile 0.001 aralığında seviyeler tanımlanmıştır. Eğitim esnasında azalan hatalı sınıflandırma oranı doğrultusunda öğrenme oranı azaltılmıştır ve bu sayede SGD yönteminin yerel minimumu değil global minimumu bulması amaçlanmıştır. Burada önerilen ağırlık ilklendirme ve eğitim oranı parametreleri AlexNet çalışmasından referans alınarak belirlenmiştir [37].

3. HİPERSPEKTRAL VE LİDAR VERİLERİNDE ÖN İŞLEME VE BİÇİMSEL PROFİL HARİTALARININ ÇIKARIMI

Hiperspektral görüntülerde yer alan pikseller içerdikleri maddeler hakkında spektral bilgi sağlasalar da özellikle Houston Üniversitesi Hiperspektral Görüntüsünde yer alan bulut gölgesi kaynaklı gölgelik alan gibi veya aynı malzemedan üretilen farklı cisimlere yönelik bilgilerin sağlanmasında zayıf kalmaktadır. Buna ek olarak DESA modelleri işaretlenmiş bol miktarda eğitim kümesine ihtiyaç duymakla birlikte eğitim kümesinin boyutunun veri miktarıyla orantılı olmasını beklemektedir. Ancak mevcut popüler hiperspektral veri kümeleri incelendiğinde eğitim kümesi miktarı oldukça sınırlı buna ek olarak sağlanan verinin boyutu oldukça yüksektir.

Bu kapsamda öncelikle çevre piksel spektral bilgilerini de kapsayacak şekilde hiperspektral görüntülerden bölütler alınarak girdi olarak DESA'ya verilmiştir. Ardından ağı eğitimi ve test kümeleri üzerinde başarımlarına bakıldığında oldukça

dikkat çekici sonuçlar elde edilmiştir. Eğitim kümesi ile ağ başarılı bir şekilde eğitilebilmekte iken, test kümesi üzerinde başarımın oldukça düşük olduğu görülmüştür. Buna ek olarak literatürde aynı veri kümeleri üzerinde gerçekleştirilmiş çalışmalar incelendiğinde veri kümesinin sınıflandırma başarımının artmasının özellikle morfolojik profilleri içeren EMAP'ların oluşturulması ile gerçekleştiği görülmüştür.

Bu kapsamda DESA modellerine veriler sağlanmadan evvel HSG ve LiDAR veri kümelerine EMAP algoritması uygulanmış ve uzamsal haritaların çıkarımı gerçekleştirilmiştir. Buna ek olarak DESA için oldukça önem içeren farklı normalizasyon yöntemleri veri kümesine uygulanmıştır.

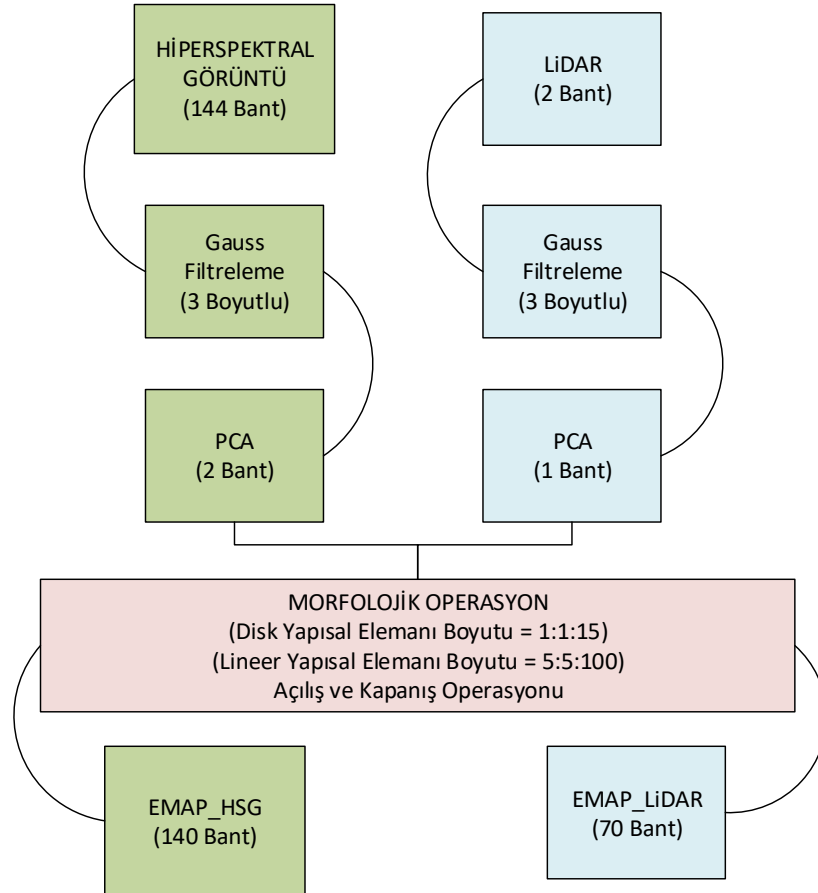
3.1 EMAP Yöntemi ile Biçimsel Profil Haritalarının Oluşturulması

Morfolojik filtreler tabanlı yaklaşımlar, uzaktan algılanmış görüntülerden uzamsal ve biçimsel özellikler çıkarmak için büyük potansiyel göstermektedir. Yüksek çözünürlüğe sahip görüntüler incelendiğinde bölge sınırları ve görüntüde yer alan cisimlerin şekilleri belirginlik göstermektedir. Ancak düşük çözünürlükte elde edilmiş görüntülerde cisimlere ait biçimsel özellikler gizli kalabilmektedir. Bu problemin üstesinden gelebilmek amacıyla açılış ve kapanış adı verilen morfolojik operasyonlar imgeye uygulanmaktadır. Yeniden yapılanma ile açılıp kapanış işlemleri, görüntüde yer alan cisimlerin biçimsel şeklini önemli ölçüde değiştirmeden biçimsel özelliklerinin ortaya çıkarılmasını sağlamaktadır. Açılış operasyonu ile birlikte gri tonlamaya sahip görüntüde birbirine bağlılığı bulunmayan ışık yapıları kaldırılmakta, kapama operasyonu ile birbirine bağlılığı bulunmayan karanlık nesnelerin kaldırılması gerçekleştirilmektedir.

Bu tez kapsamında veri kümelerine öncelikle Gauss filtreleri ile yumuşatma uygulanmıştır. Uygulanan Gauss filtresinin standart sapma değeri 0.12 en uygun değer olarak bulunmuş ve uygulanmıştır. Spektral boyutun tamamını kapsayan Gauss filtrelemesi ile spektral ve uzamsal eksende gürültünün azaltılması sağlanmıştır. Bu işlemin ardından HSG'lere PCA uygulanmış sonuç olarak veri kümesinin boyutu düşürülmüştür. Hiperspektral verilere uygulanan PCA sonucu oluşan ilk iki temel bileşenin kümülatif varyansın %99'undan fazlasını temsil ettiği her iki (Houston- Muufl) veri kümesinde de görülmüştür.

Hem LiDAR hem de ilk iki temel bileşen ile yeniden yapılandırılmış HSG'ler üzerinden morfolojik özniteliklerin çıkarımı gerçekleştirilmiştir. Farklı boyutlarda ve

şekillerde yapısal elemanlar kullanılarak açılış ve kapanış işlemleri gerçekleştirilmiştir [41]. Öncelikle disk şekline sahip yapısal eleman ile hem LiDAR hem de HSG için 15'er adet açma ve kapama işlemi uygulanmıştır. Disk şekilli yapısal elemanın yarıçap değeri 1'den 1'er kademeli artış ile 15'e kadar artırılarak birbirinden farklı morfolojik profiller oluşturulmuştur. Ardından aynı veri kümeleri üzerinden lineer yapısal elemanın boyutu 5'ten başlayarak 5'er kademeli artış ile 100'e kadar 20 adet açma ve kapama işlemi uygulanmıştır. Bu işlemler sonucu HSG'lerden her bir temel bileşene özgü 70'er adet morfolojik profil oluşturulmuştur. İlgili işlemler Houston veri kümesi boyutları referans alınacak şekilde gerçekleştirilen işlemler Şekil 3-1 ile verilmektedir. Sonuç olarak EMAP'leri içeren Houston veri kümesi HSG'leri verisinin boyutu 349x1905x140, EMAP'leri içeren Houston veri kümesi LiDAR verisinin boyutu ise 349x1905x70 olmuştur. Aynı şekilde Muufl verisinin uzamsal boyutları aynı kalmış derinlik boyutu ise HSG'de 140 LiDAR verisinde ise 70 olarak güncellenmiştir. Burada üretilen biçimsel özellikleri içeren haritalar EMAP_HSG ve EMAP_LiDAR olarak adlandırılmıştır.




Şekil 3-1: Morfolojik Profil Oluşturma Basamakları – Houston Veri Kümesi


Houston LiDAR verisine yönelik farklı morfolojik işlemler sonucu oluşturulmuş örnek EMAP'lar Şekil 3-2 ile verilmektedir. Açılış işlemi sonucu disk elemanın boyutundan büyük parlak cisimlerin daha belirgin bir şekilde ortaya çıktığı görülmektedir.



(a)



(b)



(c)

Şekil 3-2: Houston LiDAR verisine yönelik disk şekilli yapısal elemanlı açılış işlemi sonucu oluşan profiller (a) Disk yarıçapı 1 olan yapısal eleman ile açılış işlemi. (b) Disk yarıçapı 3 olan yapısal eleman ile açılış işlemi. (c) Disk yarıçapı 5 olan yapısal eleman ile açılış işlemi.

3.2 Veri Normalizasyonu

Yapay sinir ağlarına girdi verisi verilmeden evvel verilerin normalize edilmesi ağın performansı için oldukça önem taşımaktadır. Normalizasyon ile eldeki verilerin daha iyi modellenmesi ve veri kümesinde yer alabilecek aşırı uç değerlerden ağın kurtarılması sağlanabilmektedir. Spektral ve uzamsal verilerin elde edilmesinin ardından her veri kümesinin kendi içerisinde normalizasyonu gerçekleştirilmiştir. Verilerin normalizasyon işlemi bütün veri kümelerine uygulanmaktadır.

Tez kapsamında DESA başarımına direkt etkisi bulunan birçok farklı normalizasyon yöntemi denenmiş ve veri kümelerine özel normalize edilmiş veriler oluşturulmuştur. Hiperspektral verilerin normalizasyonu gerçekleştirilirken hem banda özel ayrıca

piksel tabanlı normalizasyonlar gerçekleştirilmiş en başarılı sonuçların oluşmasını sağlayan normalizasyon yöntemi belirlenmiştir.

Uygulanan normalizasyon yöntemlerinde x_n normalleştirilmiş veriyi, x_0 orijinal veriyi, x_{min} , x_{max} , $mean(x)$, $std(x)$ sırasıyla minimum, maksimum, verinin ortalama değerini ve standart sapmasını ifade etmektedir.

- [0, +1] aralığı normalizasyonu:

$$x_n = \frac{(x_0 - x_{min})}{(x_{max} - x_{min})} \quad 3-1$$

- [A, B] aralığı normalizasyonu:

$$x_n = \frac{(B - A)(x_0 - x_{min})}{(x_{max} - x_{min}) + A} \quad 3-2$$

- İstatiksel Normalizasyon:

$$x_n = \frac{x_0 - mean(x)}{std(X)} \quad 3-3$$

- Maksimumu Limitleme Normalizasyonu:

$$x_n = \frac{(x_0)}{x_{max}} \quad 3-4$$

Herbir veri kümesine özel en iyi sınıflandırma sonucunun üretilmesini sağlayan normalizasyon veri kümelerine uygulanmıştır. Sinir ağı kurulumunda veri normalizasyonu sınıflandırıcı başarıyı etkileyen önemli faktörlerden bir tanesidir.

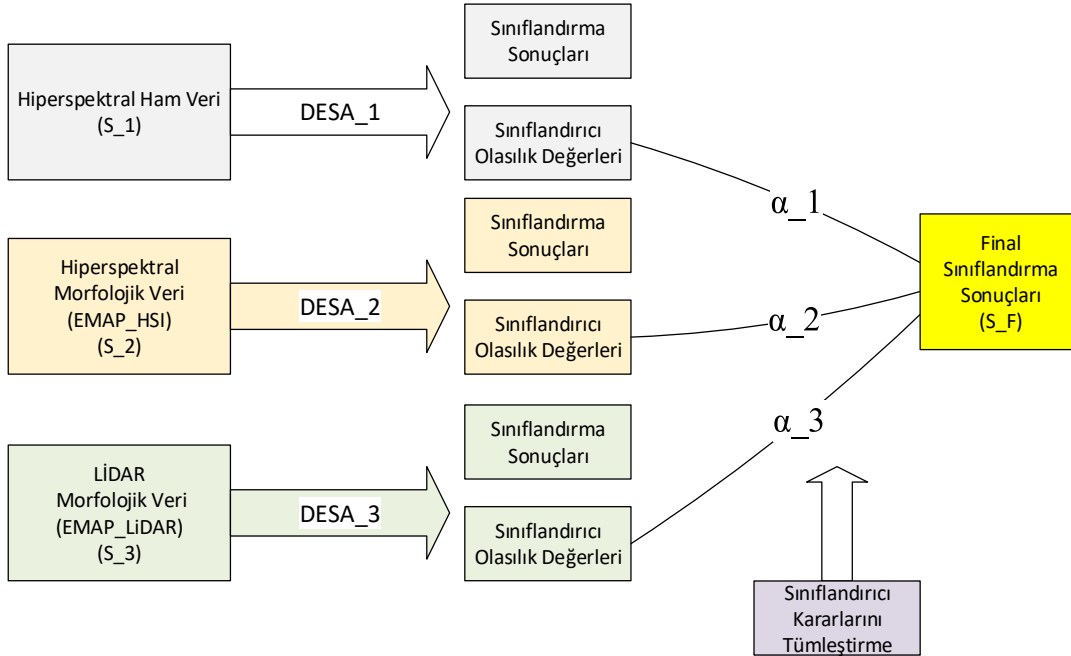
4. ÖNERİLEN HSG VE LiDAR TÜMLEŞTİRME YÖNTEMLERİ

Derin öğrenme ile anlamsal bölütleme probleminin çözümüne ek olarak HSG ve LiDAR verilerinin tümleştirilmesi gerekmektedir. HSG'lerin ve LiDAR verilerinin tümleştirilmesine yönelik olarak bu tez çalışması kapsamında temelde iki farklı yöntem önerilmektedir. Öncelikle veri kümelerinin kendi içerisinde DESA ile sınıflandırılmasının ardından sınıflandırma sonuçlarının olasılıksal karar değerlerinin birleştirilmesi ilk önerilen yöntemdir. Mevcut çalışmalar incelendiğinde oldukça yaygın bir şekilde kullanılan bir tümleştirme yöntemi olduğu görülmüştür ([42], [43]). Karar seviyesinde tümleştirmeye ek olarak öznitelik ve özellik seviyesinde veri tümleştirilmesinin ardından sınıflandırma işlemi de gerçekleştirilmektedir [44]. Tez kapsamında önerilen diğer yöntem ise sınıflandırma öncesi biçimsel ve spektral özelliklerin birleştirilmesinin ardından tümleştirilmiş veriye yönelik DESA oluşturulması amaçlanmaktadır.

Öznitelik bazında tümleştirme için ise ilk kez bu tez çalışması kapsamında önerilen bir tümleştirme yöntemi kullanılmıştır. Özellikle HSG ve LiDAR bilgileri üzerinden iyileştirilmiş AlexNet'in ilk katmanında yer alan filtrelerin kullanıldığı tümleştirme ve tümleştirme verisinden öznitelik çıkarma işlemi kurulan DESA'nın sınıflandırma başarımının artmasına etki etmiştir.

4.1 Olasılıksal Karar Tabanlı Tümleştirme

Karar seviyesi tümleştirme işleminde birbirinden farklı veri kümelerinin sınıflandırıcılarından gelen skor değerlerine yönelik sınıflandırıcı kararlarını birleştirme işlemi gerçekleştirilir. Bu kapsamda ise öncelikle oluşturulmuş spektral, ve uzamsal haritaları içeren EMAP_HSG ve EMAP_LiDAR veri kümelerine özel DESA sınıflandırıcıları kurulumu gerçekleştirilmiştir ve sınıflandırıcıların herbir pikseli hangi sınıfa hangi olasılıkla koyduğu belirlenmiştir. Ayrıca DESA çıktısı olarak ilgili piksellerin herbir sınıfta bulunma olasılık değerleri oluşturulmuştur. Bu işlemlerin ardından sınıflandırıcı kararlarının birleştirilmesi gerçekleştirilmiştir. Herbir sınıflandırıcının sonuç olarak oluşturulacak sınıflandırma sonucuna etkisinin eş ağırlıkta etki etmesi sağlanmıştır. Gerçekleştirilen olasıksal karar seviyesi tümleştirme işlemi Şekil 4-1 ile verilmektedir.



Şekil 4-1: Hiperpektral ve LiDAR Verilerinin Sınıflandırma Sonuçlarının Karar Seviyesinde Tümleştirme Basamakları

Denklem 4-1 ile her bir sınıftan gelen test pikselinin hangi olasılıkla hangi sınıfta yer alacağı verilmektedir. M toplam sınıf sayısını, S_1, S_2, S_3 ise sırasıyla spektral, EMAP_HSG ve EMAP_LiDAR sınıflandırıcıları göstermektedir.

$$P_n^{S-1} = [P(y_n = 1|a_n) P(y_n = 2|a_n) \dots P(y_n = M|a_n)] \quad 4-1$$

$$P_n^{S-2} = [P(y_n = 1|b_n) P(y_n = 1|b_n) \dots P(y_n = M|b_n)]$$

$$P_n^{S-3} = [P(y_n = 1|c_n) P(y_n = 1|c_n) \dots P(y_n = 1|c_n)]$$

Her bir verinin birbirinden bağımsız olduğu varsayılmış ve karar tümleştirilmesi esnasında eş ağırlıklandırma ile $\alpha_1 = \alpha_2 = \alpha_3$ final sınıflandırma sonucu oluşturulmuştur. Denklem

4-2 final olasılıksal tümleştirilmiş sınıflandırıcı S_F ilgili test verisinin bulunduğu sınıf bilgisi y_n ile verilmiştir.

$$P_n^{S_F} = \frac{\alpha_1 x P_n^{S_1} + \alpha_2 x P_n^{S_2} + \alpha_3 x P_n^{S_3}}{\alpha_1 + \alpha_2 + \alpha_3} \quad 4-2$$

$$P_n^{S_F} = [P_{n,1}^{S_F} P_{n,2}^{S_F} P_{n,3}^{S_F} \dots P_{n,M}^{S_F}]$$

$$y_n = \max(P_{n,c}^M)$$

4.2 Öznitelik Tabanlı Tümleştirme


Veri kümelerinin DESA ile sınıflandırılma işleminden önce özniteliklerinin tümleştirilip ardından sınıflandırma operasyonuna tutulması da oldukça yaygın bir uygulamadır. Ancak burada karşılaşılan temel problem özniteliklerin hangi yöntemle tümleştirileceği olmuştur. Tez kapsamında 2 farklı ve başarılı yöntemle özniteliklerin tümleştirilmesi gerçekleştirilmiştir.

4.2.1 Piksel Seviyesinde Tümleştirme

Piksel seviyesindeki veri füzyonu, ölçülen fiziksel parametrelerin birleşmesine yönelik olarak en düşük seviyede birleşme anlamına gelir. Ayrıca, yaygın olarak, her algılayıcıdan elde edilen verilerin daha büyük bir veri vektörü oluşturmak için kullanıldığı öznitelik çıkarma seviyesinde füzyon olarak anılır. Yeni veri vektörünün boyutları daha büyük ve görüntüde farklı bir hiper uzayda bir pikseli temsil etmekte ve böylece daha iyi bir sınıflandırma sağlayabilmektedir. Hiperspektral görüntüler

için piksel düzeyi füzyonuna odaklanan uygulamalar için popülerlik giderek artmaktadır

Piksel tabanlı tümleştirmede verinin boyutunun artması DESA tabanlı sınıflandırıcılar için problem oluşturabilmektedir, bunun sebebi ise veri boyutunun artmasıyla birlikte işaretlenmiş örnek sayısının artması beklentisidir. DESA ile farklı tümleştirilmiş verilerin sınıflandırılmasının ardından en yüksek başarımlar hiperspektral ve LiDAR uzamsal haritalarının piksel seviyesinde uç uca eklenmesiyle sağlanmıştır.



Şekil 4-2: Piksel seviyesinde EMAP_HSG ve EMAP_LiDAR Verilerinin Tümleştirilmesi


4.2.2 Boyutsal Tümleştirme

Son yıllarda DESA modelleriyle görünür bantta elde edilmiş imgeler üzerinde ciddi başarımlar elde edilmektedir. Özellikle AlexNet ile DESA tabanlı sınıflandırma ile en iyi sınıflandırma başarımları ve en iyi sınıflandırma yaklaşımı elde edilmiştir. Alexnet ile önerilen DESA ağı Bölüm 2.5'te tariflenmiştir. İlgili tümleştirme uygulanırken dikkate alınan temel yaklaşım AlexNET evrişim katmanında yer alan filtrelerin düzenlenmesi ve veri kümesine uygulanabilmesidir.

Kısaca AlexNet sinir ağını tanıtmak gerekirse 224 x 224 x 3 boyutunda görünür bantta imgeler girdi katmanında verilmekte ve sinir ağı model içerisinde bulunan 5 evrişim katmanı ve havuzlama katmanı ile birlikte 3 farklı tam bağlı katmandan geçirilerek softmax sınıflandırıcı ile sonlanmaktadır. Önerilen bu sinir ağı modeli ile birlikte birinci evrişim katmanında öğrenilen filtrelerin girdi imgelerinden üst seviye öznelikler ürettiği ancak ağı derin katmanlarında veri kümesine özel detay seviye özneliklerin çıkarıldığı görülmüştür [37] .

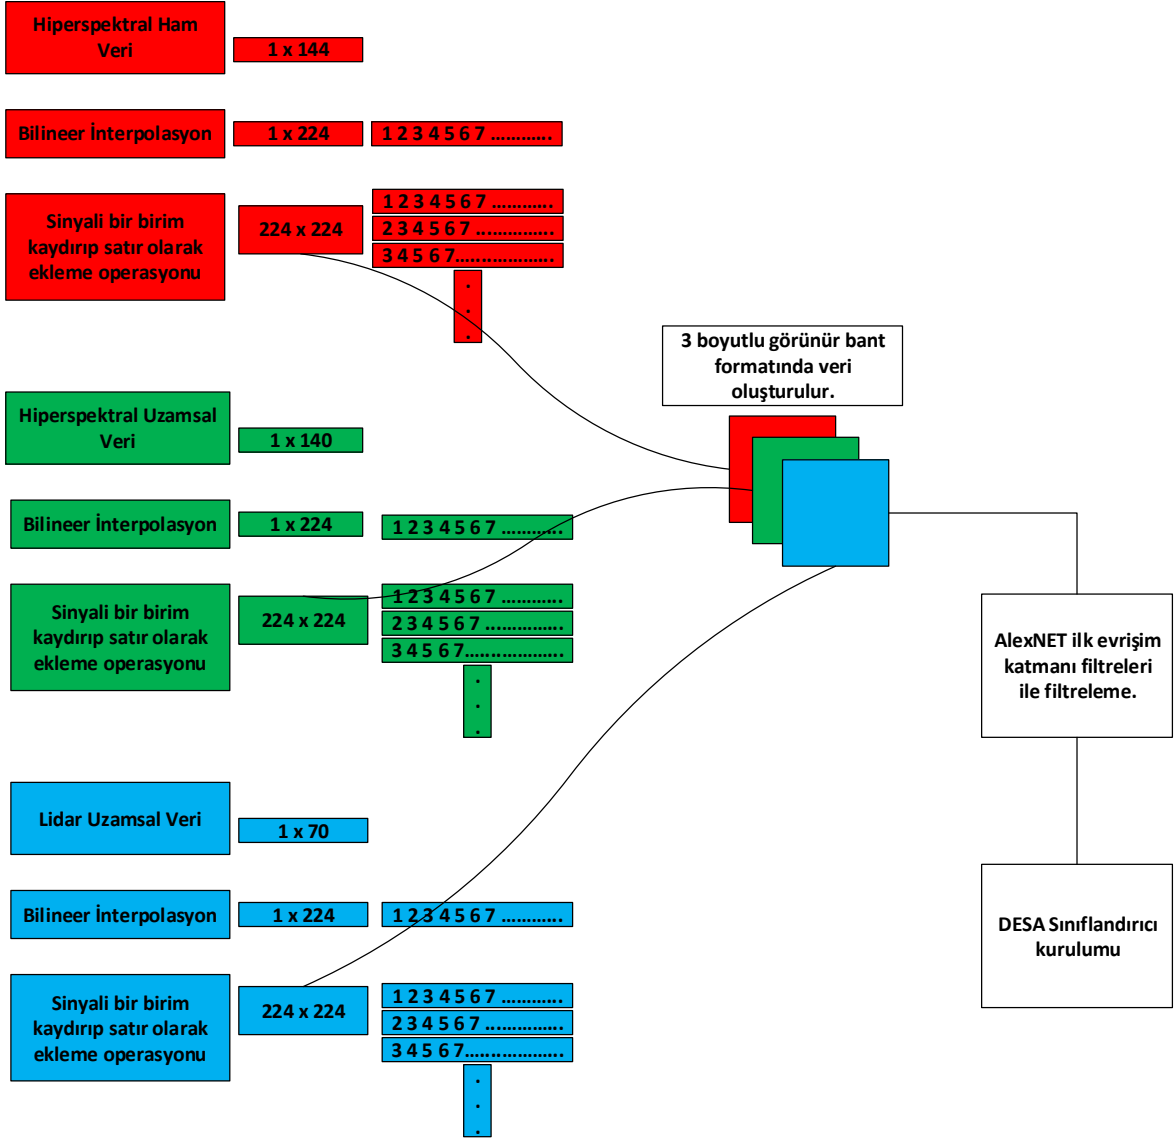
AlexNet mimarisine benzer mimari öneren iyileştirilmiş AlexNet mimarisi ile ilgili veri kümesinde daha başarılı sonuçlar elde ettiği görülmüş bu nedenle ilk katman filtre

seti olarak iyileştirilmiş AlexNet tarafından üretilen filtreler esas alınmıştır. İlk evrişim katmanında öğrenilen filtreler Şekil 4-3 ile verilmektedir.




Şekil 4-3: MatConvNet_alexNet İlk Evrişim Katmanının Öğrendiği Filtreler (64 adet) ([37],[45])

Sonuç olarak AlexNet filtrelerini kullanarak öznitelikler üretme amacıyla sırasıyla piksel seviyesinde spektral ve biçimsel veriler interpolasyon yöntemiyle boyutları 1×224 'e getirilmiştir. Herbir veri kümesi birer birer kaydırılarak sonuç olarak $224 \times 224 \times 3$ 'lük bir veri oluşturulmuştur. Ardından AlexNet tarafından öğrenilen ilk katmandaki filtreler kullanılarak eğitim kümesi oluşturulmuş buna ek olarak spektral ve uzamsal haritaların tümleştirilmesi sağlanmıştır. Şekil 4-4 ile tümleştirme ve iyileştirilmiş AlexNet'in ilk evrişim katmanının çıktısı blok diyagramlar halinde verilmektedir.



Şekil 4-4: AlexNet Girdisi Oluşturacak Şekilde Hiperspektral ve LiDAR Özniteliklerinin Tümlleştirilmesi

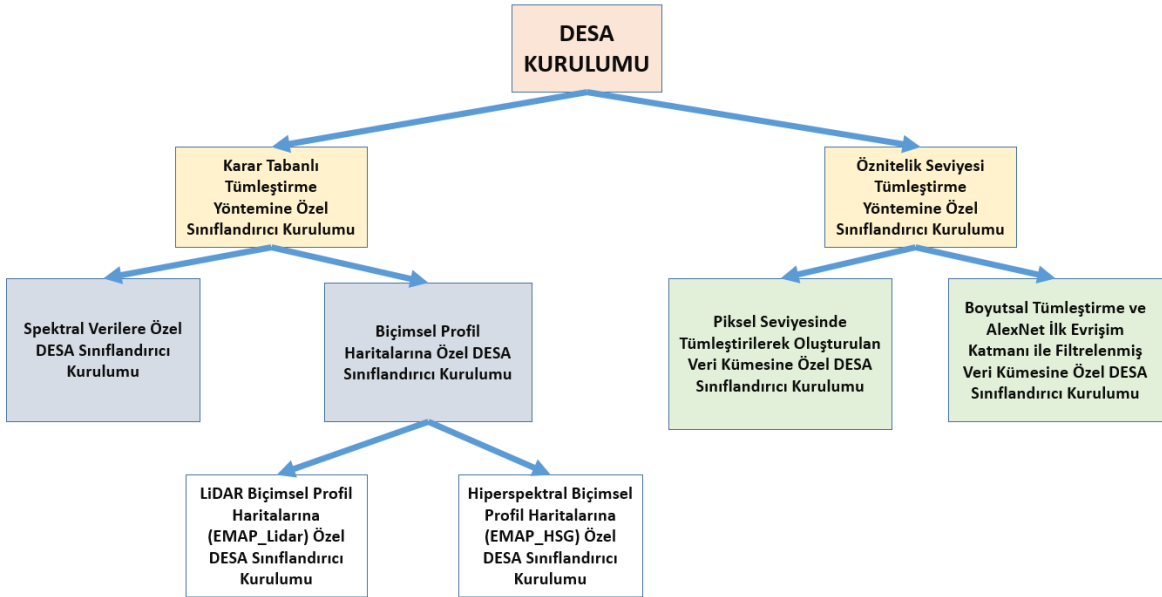
HSG ve LiDAR verilerinin 224x224x3 boyutuna getirilmesinin ardından; AlexNet'in ilk gizli katmanında yer alan evrişim katmanı, normalizasyon ve aktivasyon işlemi ve son olarak da havuzlama katmanı ile verinin boyutu 24 x 24 x 64'e dönüştürülmüştür. Ardından Bölüm 5.2.2'te bu tümlleştirme yöntemine özel önerilen DESA ile sınıflandırma işlemi gerçekleştirilmiştir. İyileştirilmiş AlexNet ile girdi verisinin boyutunun değişimi Şekil 4-5 ile verilmiştir.



Şekil 4-5: İyileştirilmiş AlexNet İlk Evrişim Katmanı ve Havuzlama Katmanı Sonrası Girdi Verisi Boyut Değişimi

5. DESA SINIFLANDIRICI KURULUMLARI

Bu bölümde önerilen tümleştirme yöntemleriyle birlikte oluşturulmuş veri kümelerine özel kurulan DESA modelleri verilmektedir. 2 ana başlıkta toplanılan tümleştirme yöntemlerine özel sınıflandırıcı kurulumları Bölüm 4 ile aynı akış ile verilmektedir. Bu bölümde kurulan DESA sınıflandırıcı çeşitleri Şekil 5-1 ile özetlenmektedir. Kurulan sınıflandırıcılara ait bilgiler alt başlıklarda detaylandırılmıştır.



Şekil 5-1: Tümleştirme Yöntemine Özel DESA Kurulum Genel Bilgilendirmesi

Farklı veri kümelerine özel DESA modelleri oluşturulurken; farklı aktivasyon fonksiyonları ve “Batch Normalization” etkisi her bir DESA modeli için denenmiştir. Sonuç olarak oluşturulan bütün DESA modellerinde aktivasyon fonksiyonu olarak RELU kullanılması ve katman düzgeleme/normalizasyonu (Batch Normalization) gerçekleştirilmesi durumunda en başarılı sınıflandırıcı sonuçları elde edilmiştir. Ayrıca DESA’da bırakma(dropout) katmanı kullanılması eğitim esnasında kurulan ağın aşırı öğrenme (overfitting) probleminden etkilenmesini azaltmıştır ve test verileri üzerinden ağın sınıflandırma başarımının bir miktar artış göstermesini sağlamıştır.

5.1 Karar Tabanlı Tümeştirme Yöntemine Özel DESA Kurulumları

Karar tabanlı tümeştirme yöntemini sağlayabilmek amacıyla her bir veri kümesine özel olarak DESA modelleri kurulumu gerçekleştirilmiştir. Alt başlıklarda kurulan sınıflandırıcılara özel detaylar verilmektedir.

5.1.1 Spektral Verilere Özel DESA Sınıflandırıcı Kurulumu

Houston ve Mufl’a ait HSG’lerden elde edilen ham spektral bilgilerin sınıflandırılmasına yönelik DESA modelleri oluşturulmuştur. Yalnızca piksel verileri ile DESA yapılarının girdi katmanı oluşturulmuştur. Veri kümelerine yönelik birçok sinir ağı modeli oluşturulmuş ve test veri kümesi ile sınıflandırıcılara yönelik başarımlar incelenmiştir. Sınıflandırma öncesinde her bir piksel verisi istatistiksel normalizasyon ile normalize edilmiştir. Ardından yalnızca ham spektral verilerin sınıflandırılmasında en iyi sonucu veren sinir ağı modeli her iki veri kümesi için Şekil 5-2 ile verilmiştir. Her iki veriyi en iyi sınıflandıran DESA modelinde 3 adet evrişim katmanı, 1 tam bağlı katman bulunmaktadır. Katmanlarda yer alan filtrelerin boyut bilgileri ve her bir katmandan sonra verinin boyutunun değişim bilgileri de Şekil 5-2 ile sağlanmıştır. Softmax fonksiyonu ile sınıflandırma işlemi gerçekleştirilmiş test verisinin sınıflarda bulunma olasılıkları oluşturulmuştur. En yüksek olasılık değerine sahip çıktı test verisinin atandığı sınıf olarak belirlenmiştir.

Houston HSG Spektral Veri Kümesine Özel DESA Modeli		Muufi HSG Spektral Veri Kümesine Özel DESA Modeli	
GİRDİ	[1x144x1]	GİRDİ	[1x64x1]
EVİRİŞİM_1 Batch Norm RELU	Çekirdek Boyut: 1 x 6 x 1 Çekirdek Sayısı # 24 – Kayma Miktarı: 2	EVİRİŞİM_1 Batch Norm RELU	Çekirdek Boyut: 1 x 6 x 1 Çekirdek Sayısı # 24 Kayma Miktarı: 2
Öznetelik Haritası	[1 x 70 x 24]	Öznetelik Haritası	[1 x 30 x 24]
Havuzlama_1 (Maks.)	Havuzlama Boyut: [1 x 2]	Havuzlama_1 (Maks.)	Havuzlama Boyut : [1 x 2]
Öznetelik Haritası	[1 x 35 x 24]	Öznetelik Haritası	[1 x 15 x 24]
EVİRİŞİM_2 Batch Norm RELU	Kernel size : 1 x 5 x 24 Kernel # 48 Stride : 3	CONV_2 Batch Norm RELU	Çekirdek Boyut: 1 x 6 x 24 Çekirdek Sayısı # 48 Kayma Miktarı: 1
Öznetelik Haritası	[1 x 11 x 48]	Öznetelik Haritası	[1 x 10 x 48]
EVİRİŞİM_3 Batch Norm RELU	Kernel size : 1 x 5 x 48 -- Kernel # 96 -- Stride : 3	CONV_3 Batch Norm RELU	Çekirdek Boyut: 1 x 4 x 48 Çekirdek Sayısı # 96 -- Kayma Miktarı: 3
Öznetelik Haritası	[1 x 3 x 96]	Öznetelik Haritası	[1 x 3 x 96]
Tam Bağlı Katman	1 x 1 x 15	Tam Bağlı Katman	1 x 1 x 11
SoftMax Kayıp		SoftMax Kayıp	
Çıktı	Olasılık Vektörü [1 x 15]	Output	Olasılık Vektörü [1 x 11]

Şekil 5-2: Houston- Muufi Spektral Veri Kümelerine Özel DESA Modeli

5.1.2 Biçimsel Haritalara Özel DESA Sınıflandırıcı Kurulumu

Ham hiperspektral ve LiDAR veri kümelerine ek olarak üretilen biçimsel profil haritalarını içeren veri kümelerine özel olarak DESA sınıflandırıcı kurulumu gerçekleştirilmiştir. Hem EMAP_ LiDAR hem de EMAP_HSG için girdi katmanında piksel bilgisi sağlanmaktadır. Bir piksel verisinde farklı biçimsel elemanlar ile açma ve kapama operasyonları ile elde edilmiş bilgi bulunmaktadır.

- **EMAP_HSG Haritalarına Özel DESA Sınıflandırıcı Kurulumu**

Muufi ve Houston veri kümelerinden üretilen EMAP uzamsal haritalarına özel olarak oluşturulan DESA modelleri Şekil 5-3 ile verilmektedir. Her iki veri kümesinin girdi boyutu benzerlik göstermektedir, ancak sınıf sayıları birbirinden farklılık göstermektedir. Son katman haricinde aynı boyutlarda filtre ve katmanlar ile DESA

modelleri oluşturulmuştur. Spektral veri kümesi için önerilen ağ ile aynı derinlikte ve benzer şartlarda DESA modeli oluşturulmuştur.

Houston ve Muufl HSG EMAP Verilerine Özel Önerilen DESA Modeli	
GİRDİ	[1x140x1]
EVRIŞİM_1 Batch Norm RELU	Çekirdek Boyut: 1 x 5 x 1 – Çekirdek Sayısı # 24 – Kayma Miktarı: 3
Öznitelik Haritası	[1 x 46 x 24]
Havuzlama_1 (Maks.)	Havuzlama Boyut: [1 x 2]
Feature Map	[1 x 23 x 24]
EVRIŞİM_2 Batch Norm RELU	Çekirdek Boyut: 1 x 5 x 24 – Çekirdek Sayısı # 48 – Kayma Miktarı: 2
Öznitelik Haritası	[1 x 10 x 48]
EVRIŞİM_3 Batch Norm RELU	Çekirdek Boyut: 1 x 6 x 48 – Çekirdek Sayısı # 96 – Kayma Miktarı: 2
Öznitelik Haritası	[1 x 3 x 96]
Tam Bağlı Katman	1 x 1 x 15 (Houston Veri Kümesine Özel) 1 x 1 x 11 (Muufl Veri Kümesine Özel)
SoftMax Kayıp	
Çıktı	Olasılık Vektörü [1 x 15] (Houston Veri Kümesine Özel) Olasılık Vektörü [1 x 11] (Muufl Veri Kümesine Özel)

Şekil 5-3: Houston- Muufl EMAP_HSG Veri Kümelerine Özel DESA Modeli

- **LİDAR Uzamsal Veri Kümesine Özel DESA Sınıflandırıcı**

Muufl ve Houston'a ait LiDAR veri kümelerinden üretilen EMAP uzamsal haritalarına (EMAP_LiDAR) özel olarak oluşturulan DESA modelleri Şekil 5-4 ile verilmektedir. Her iki veri kümesinin girdi boyutu aynıdır, ancak sınıf sayıları birbirinden farklılık göstermektedir. Son katman haricinde aynı parametreler ile verilerin DESA modelleri oluşturulmuştur. Tez kapsamında önerilen DESA modellerinde 3 adet evrişim katmanı ve 1 adet tam bağlı katman ile en iyi sınıflandırma sonuçları elde edilmiştir. Biçimsel haritası oluşturulmuş LiDAR verilerinden işaretlenmiş bilgiler piksel halinde alınarak DESA'ya verilmiştir.

Houston ve Muufl LiDAR EMAP Verilerine Özel Önerilen DESA Modeli	
GİRDİ	[1x70x1]
EVRİŞİM_1 Batch Norm RELU	Çekirdek Boyut 1 x 4 x 1 – Çekirdek Sayısı # 24 – Kayma Miktarı: 2
Öznitelik Haritası	[1 x 34 x 24]
Havuzlama_1 (Maks.)	Havuzlama Boyut: [1 x 2]
Öznitelik Haritası	[1 x 17 x 24]
EVRİŞİM_2 Batch Norm RELU	Çekirdek Boyut: 1 x 5 x 24 – Çekirdek Sayısı # 48 – Kayma Miktarı: 2
Öznitelik Haritası	[1 x 7 x 48]
EVRİŞİM_3 Batch Norm RELU	Çekirdek Boyut: 1 x 5 x 48 – Çekirdek Sayısı # 96 – Kayma Miktarı: 1
Öznitelik Haritası	[1 x 3 x 96]
Tam Bağlı Katman	1 x 1 x 15 (Houston Veri Kümesine Özel) 1 x 1 x 11 (Muufl Veri Kümesine Özel)
SoftMax Kayıp	
Çıktı	Olasılık Vektörü [1 x 15] (Houston Veri Kümesine Özel) Olasılık Vektörü [1 x 11] (Muufl Veri Kümesine Özel)

Şekil 5-4: Houston- Muufl EMAP_LiDAR Veri Kümelerine Özel DESA Modeli

5.2 Öznitelik Seviyesi Tümeleştirme DESA Sınıflandırıcı Kurulumu

Burada önerilen tümeleştirme yönteminde ise sınıflandırıcı kurulmadan önce elde edilen verilerin tümeleştirilmesi gerçekleştirilmektedir. İki farklı öznitelik seviyesine ait tümeleştirme detayları Bölüm 4'te verilmektedir. Füzyonu gerçekleştirilmiş veri kümeleri üzerinden sınıflandırıcı kurulumu gerçekleştirilmiştir.

5.2.1 Piksel Seviyesinde Tümeleştirilerek Oluşturulan Veri Kümesine Özel DESA Sınıflandırıcı Kurulumu

Piksel seviyesi tümeleştirmede en iyi DESA sınıflandırma başarımı EMAP_LiDAR ve EMAP_HSG görüntülerinin piksel seviyesinde tümeleştirilmesiyle elde edilmiştir. Tümeleştirilmiş veriye özel olarak kurulan DESA, 3 adet gizli evrişim katmanı ve tam bağlı katman yapısı DESA'nın içerdiği katmanlardır. Evrişim katmanlarından hemen sonra katman normalizasyonu gerçekleştirilmiş ve aktivasyon fonksiyonu olarak RELU kullanılmıştır. Tam bağlı katmanda bırakma (dropout) kullanımı


gerçekleştirilmiş ve ağın aşırı öğrenme probleminden korunması sağlanmıştır. Kurulan DESA modeline ait detaylar Şekil 5-5 ile verilmektedir.

GİRDİ	[1x210x1]
EVRİŞİM_1 Batch Normalization RELU	Çekirdek Boyut: 1 x 7 x 1 – Çekirdek Sayısı # 24 – Kayma Miktarı: 2
Öznetelik Haritası	[1 x 102 x 24]
Havuzlama_1 (Maks.)	Havuzlama Boyut: [1 x 2]
Öznetelik Haritası	[1 x 51 x 24]
EVRİŞİM_2 Batch Normalization RELU	Çekirdek Boyut 1 x 6 x 24 – Çekirdek Sayısı # 48 – Kayma Miktarı: 3
Öznetelik Haritası	[1 x 16 x 48]
EVRİŞİM_3 Batch Normalization RELU	Çekirdek Boyut: 1 x 7 x 48 – Çekirdek Sayısı # 96 – Kayma Miktarı: 3
Öznetelik Haritası	[1 x 4 x 96]
Tam Bağlı Katman	1 x 1 x 15 (Houston Veri Kümesine Özel) 1 x 1 x 11 (Muufli Veri Kümesine Özel)
SoftMax Kayıp	
Çıktı	Olasılık Vektörü [1 x 15] (Houston Veri Kümesine Özel) Olasılık Vektörü [1 x 11] (Muufli Veri Kümesine Özel)

Şekil 5-5: Houston- Muufli EMAP_HSG-EMAP_ LiDAR Piksel Seviyesinde Tümlleştirilmiş Veri Kümelerine Özel DESA Modeli

5.2.2 Boyutsal Tümlleştirme ve Alexnet İlk Evrişim Katmanı Filtrelenmiş Veri Kümesine Özel DESA Sınıflandırıcı Kurulumu

Tez kapsamında önerilen ve özellikle Houston veri kümesinde başarılı sonuçlar alınmasını sağlayan bu yönteme ait önerilen DESA modeli Şekil 5-6 ile verilmektedir. İlgili DESA modelinde yer alan detaylı bilgiler ise Şekil 5-7 ile verilmektedir. Bu modele özel olarak AlexNet filtreleri yardımıyla kurulumu gerçekleştirilecek olan DESA'nın girdileri oluşturulmuş ve ardından sınıflandırma sonuçlarının oldukça başarılı olduğu görülmüştür. Kurulumu gerçekleştirilen DESA modelinde 2 adet evrişim katmanı, havuzlama katmanı ve tam bağlı sinir ağı modeli bulunmaktadır. Öznetelik seviyesinde tümlleştirme gerçekleştirilirken temel olarak referans alınan boyut kriteri AlexNet modeline uyumlu hale getirmektir. DESA kurulumunda ise AlexNet'in ilk evrişim katmanı sonucu oluşan veri boyutu dikkate alınmıştır.



Şekil 5-6: Houston- Muufl, Spektral-EMAP_HSG-EMAP_ LiDAR Boyutsal Tümlleştirilmiş ve AlexNet İlk Evrişim katmanı Filtreleri ile Oluşturulmuş Veri Kümelerine Özel DESA Modeli Şekilsel Anlatımı

GİRDİ	[27x27x64]
EVRIŞİM_1 RELU	Çekirdek Boyut 6 x 6 x 64 Çekirdek Sayısı # 64 Kayma Miktarı: 3
Öznitelik Haritası	[8 x 8 x 64]
EVRIŞİM_2 Batch Normalization RELU	Çekirdek Boyut: 5 x 5 x 64 Çekirdek Sayısı # 128 Kayma Miktarı: 3
Öznitelik Haritası	[2 x 2 x 128]
Havuzlama_1 (Maks.)	Havuzlama Boyut: [2 x 2]
Öznitelik Haritası	[1 x 1 x 128]
Tam Bağlı Katman	1 x 1 x 15 (Houston Veri Kümesine Özel) 1 x 1 x 11 (Muufl Veri Kümesine Özel)
SoftMax Kayıp	
Çıktı	Olasılık Vektörü [1 x 15] (Houston Veri Kümesine Özel) Olasılık Vektörü [1 x 11] (Muufl Veri Kümesine Özel)

Şekil 5-7: Houston- Muufl, Spektral-EMAP_HSG-EMAP_ LiDAR Boyutsal Tümlleştirilmiş ve AlexNet İlk Evrişim katmanı Filtreleri ile Oluşturulmuş Veri Kümelerine Özel DESA Modeli

6. DENEYSEL SONUÇLAR

Bu bölümde önerilen tümleştirme yöntemleriyle birlikte oluşturulmuş ve veri kümelerinin DESA ile sınıflandırılma sonuçlarına ait bilgiler verilmektedir. Ardından sınıflandırıcı başarımlarının değerlendirilmesi gerçekleştirilmiştir.

Veri kümelerinin sınıflandırılmasında K-Çapraz doğrulama yöntemi kullanılmıştır. K değeri 10 olarak alınmış, verinin %90'ı eğitim verisi %10'u doğrulama (geçerleme) verisi olarak alınmıştır. Test verileri ayrı bir kümede yer almaktadır ve eğitime hiçbir şekilde dahil edilmemektedir.

DESA tabanlı sınıflandırma sonuçları tez kapsamında herbir operasyonda iki farklı sınıflandırıcı sonuçları ile karşılaştırılmıştır. Sınıflandırıcılar hakkında genel bilgiler ve kappa istatistik değerinin hesaplanmasına yönelik bilgilendirme alt bölümde verilmiştir.

Deneylerde DESA modelleri MATLAB ortamında geliştirilmiş olan MatConvNet kütüphanesi kullanılarak gerçekleştirilmiştir [45].

6.1 Genel Karşılaştırma Parametreleri ve Karşılaştırma Sınıfları

Kappa istatistik değeri ile sınıflandırma sonuçlarının birbirlerine karşı üstünlükleri incelenebilmektedir. Kappa (κ) istatistik ölçüsü, referans verilerle otomatik sınıflandırılmış veriler arasındaki gerçek uyum ile yine referans verilerle rastgele sınıflandırılmış veriler arasındaki şans uyumu arasındaki farkı göstermek için kullanılmaktadır. Kappa katsayısı, hata matrisinin satır ve sütun toplamları ve köşegeni üzerindeki elemanlar kullanılarak hesaplanır. Kappa istatistiği, köşegen üzerinde bulunmayan elemanları da doğruluk değerlendirmesine katmaktadır. Cohen kappa istatistiği denklemi denklem 6-1 ile verilmektedir. Burada N toplam örnek sayısını, d hata matrisinin diyagonalinde bulunan örnek sayısını, $a_{i,j}$ hata matrisinde bulunan değerlerin yerini, κ ise Cohen kappa değerini göstermektedir:

$$\kappa = \frac{d - q}{N - q} \quad 6-1$$
$$q = \frac{\sum_{i=1}^N (\sum_{j=1}^N a_{i,j} \sum_{j=1}^N a_{j,i})}{N}$$

Derin yapay sinir ağlarıyla oluşturulmuş sınıflandırma başarımları aynı veriler ile sınıflandırma operasyonuna tabi tutulan DVM ve RO (Rastgele Orman) Sınıflandırıcısı ile kıyaslanmıştır.

DVM öğrenme boyunca, ayırma düzlemi (hiper düzlem) ile bunun her iki tarafında bulunan veri örnekleri arasındaki mesafenin maksimum olması için düzlemin pozisyonunu optimize etmektedir. DVM iki sınıfa ait örnekler arasındaki karar yüzeyini oluştururken yüzeyin iki sınıfa olan uzaklığını en yüksek dereceye çıkarmaya çalışmaktadır. İki'den fazla sınıflandırma da ise "Birine karşı" stratejisi, çok sınıflı sınıflandırma sorununun çözümüdür ve DVM, DESA'ya karşı karşılaştırmacı sınıflandırıcı olarak kullanılmaktadır [46].


DVM'ye ek olarak Rastgele Orman Sınıflandırması'da (random forest) DESA'ya karşı sınıflandırıcı olarak kullanılmaktadır. Birden fazla bağımsız ağaç tahminleyicileri ile rastgele belirlenmiş özellik kümesinin sınıflandırılması gerçekleştirilir. HSG'lerin sınıflandırılmasında oldukça yaygın bir şekilde kullanılmaktadır [47].

6.2 Karar Tabanlı Tümleştirme Sonuçları


Farklı veri kümelerine ve veri kümelerinden üretilen verilere (biçimsel profil haritaları) özel DESA'lar kurulmuş ardından her bir sınıflandırıcının çıktısı olan her bir test verisinin hangi olasılıkla hangi sınıfta yer alabileceği bilgisi kullanılmıştır. Kurulumu gerçekleştirilen DESA tabanlı sınıflandırıcıların yapısı ve parametreleri deneysel olarak belirlenmiştir. İki farklı veri kümesi ile elde edilen sonuçlar alt başlıklarda verilmektedir.

6.2.1 Spektral Verilere Özel DESA Sınıflandırıcı Sonuçları

Houston ve Muuff'a ait HSG'lerden elde edilen ham spektral bilgilerin sınıflandırılmasına yönelik DESA modelleri Bölüm 5.1.1'de verilmektedir. Eğitim esnasında oluşan sonuçları içeren grafikler her bir veri kümesine özel olarak Şekil 6-1 ve Şekil 6-2 ile verilmiştir. Grafiklerde yer alan Top-1 hata değişimi eğitim ve doğrulama kümelerinin her bir yinelemede oluşan hata oranını, Top-5 hata değişimi ise ağ tarafından oluşturulan sonuçların en yüksek 5 olasılıklı değerinin doğru sınıfta bulunmama durumunu gösteren hata durumunu göstermektedir. İlgili grafikler incelendiğinde her iki veri kümesinde bulunan eğitim kümesinin başarıyla eğitildiği ancak doğrulama (geçerleme) verilerinin sınıflandırılması başarımının %80 seviyelerinde olduğu görülmüştür. Burada spektral bilginin sınıflandırmada oldukça etkili sonuçlar verdiği, ancak tek başına yeterli olmadığı görülmektedir.



Şekil 6-1: Houston HSG spektral verilerine özel DESA Eğitim Grafikleri –a) Kayıp Fonksiyon Değişimini – b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) – c)Top-5 Hatalı Sınıflandırma Oranı Değişimini (Olasılıksal olarak en yüksek 5 değerin doğru sınıfla eşleşmeme durumu) göstermektedir.



Şekil 6-2: Mufl HSG spektral verilerine özel DESA Eğitim Grafikleri – a) Kayıp Fonksiyon Değişimi –b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) –c) Top-5 Hatalı Sınıflandırma Oranı Değişimini (Olasılıksal olarak en yüksek 5 değerin doğru sınıfla eşleşmeme durumu) göstermektedir.

Test veri kümesi üzerinden kurulan DESA modellerinin başarımları ve kappa istatistik değerleri Tablo 6-1 ile verilmektedir. Spektral bantta oldukça önemli verilerin bulunduğu ancak daha yüksek başarımlar için ek bilgilere ihtiyaç duyulduğu sonuçlar üzerinden de görülmektedir.

Tablo 6-1: Yalnızca Spektral Veriye Özel DESA Sınıflandırıcı Test Başarımları ve Kappa İstatistik Değerleri

Veri Kümesi	Houston	Muufi
Test Verisi Başarımı	%80.25	%81.49
Kappa Değeri	0.7860	0.8099

DESA'nın sınıflandırma başarımlarını karşılaştırmak amacıyla 2 farklı sınıflandırıcıların spektral veriler üzerindeki başarımları Tablo 6-2 ile verilmiştir. Her iki veri kümesinde de DESA ile sınıflandırmanın en iyi sınıflandırma başarımlarını yakaladığı görülmüştür.

Tablo 6-2: Yalnızca Spektral Verilerin DVM ve Rastgele Orman Sınıflandırıcısı Test Başarımı ve Kappa İstatistik Değerleri

Veri Kümesi	Houston		Muufi	
	DVM	RO	DVM	RO
Sınıflandırıcı				
Test Başarımı	%78.23	%74.01	%82.32	%81.79
Kappa Değeri	0.7654	0.7198	0.7716	0.7646

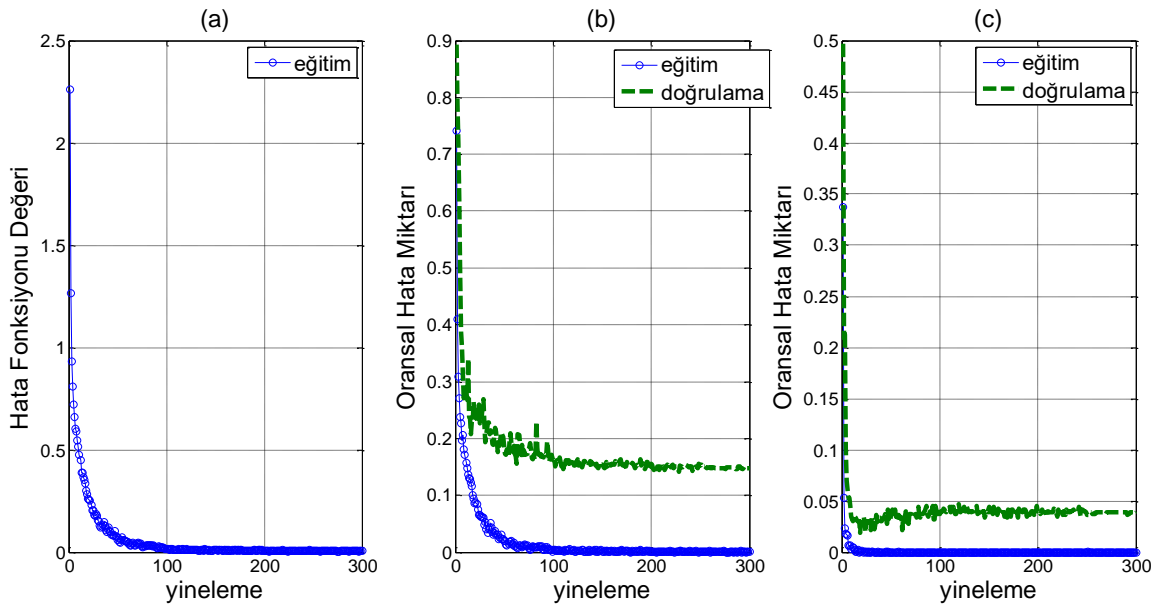
6.2.2 Biçimsel Haritalara Özel DESA Sınıflandırıcı Sonuçları

Mevcut çalışmalar incelendiğinde spektral bilgilere ek olarak sağlanan uzamsal ve biçimsel özelliklerin sınıflandırma başarımlarını önemli ölçüde artırdığı görülmüştür. Bu kapsamda HSG'lerden ve LiDAR verilerinden oluşturulan EMAP biçimsel haritalarına özel sınıflandırma işlemi gerçekleştirilmiştir. Bu kapsamda her bir veri kümesinden oluşturulan EMAP_HSG ve EMAP_LiDAR verilerine özel DESA yapıları kurulmuş ve sınıflandırma başarımları incelenmiştir. Her iki haritadan alınan eğitim ve test verileri yalnızca piksel seviyesi bilgileri içermektedir.

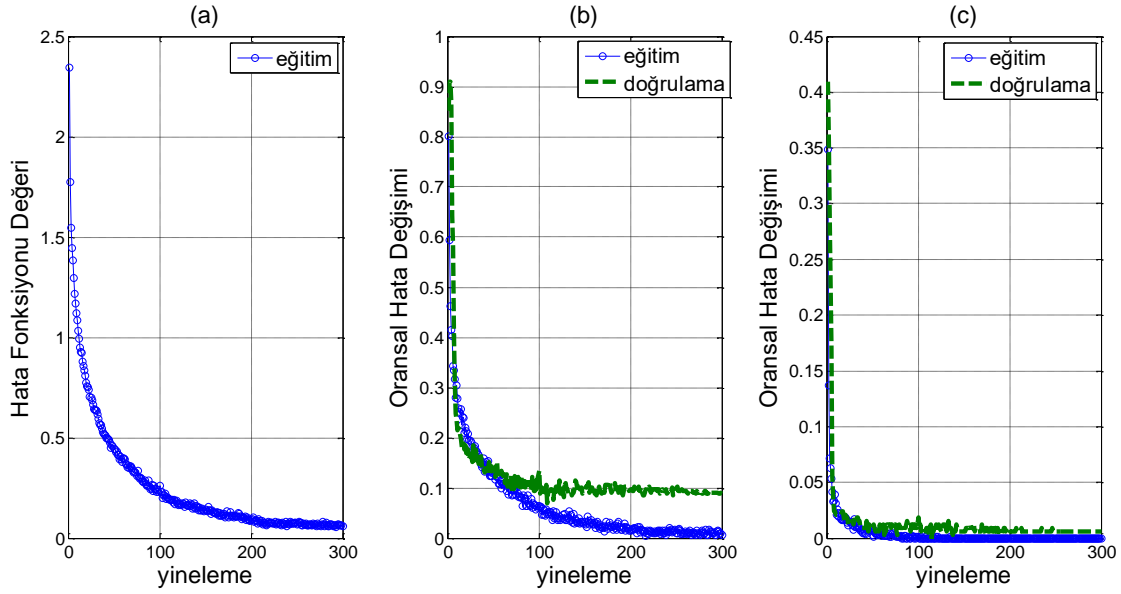
- **EMAP_HSG Haritalarına Özel DESA Sınıflandırıcı Sonuçları**

Muufi ve Houston veri kümelerinden üretilen EMAP uzamsal haritalarına özel olarak oluşturulan DESA modelleri Bölüm 5.1.2'de verilmektedir. Eğitim esnasında oluşan

sonuçları içeren grafikler her bir veri kümesine özel olarak Şekil 6-3 ve Şekil 6-4 ile verilmiştir. Grafiklerde yer alan Top-1 hata değişimi eğitim ve doğrulama kümelerinin her bir yinelemede oluşan hata oranını, Top-5 hata değişimi ise ağ tarafından oluşturulan sonuçların en yüksek 5 olasılıklı değerinin doğru sınıfta bulunmama durumunu gösteren hata durumunu göstermektedir. İlgili grafiklerde eğitim verileri üzerinden hata fonksiyonunun zamanla 0'a yakınsadığı ve eğitim verilerinin başarıyla sınıflandırılabilirdiği görülmektedir. Doğrulama kümesinin başarımında ise oransal hata miktarının %15 olduğu değerlerde kaldığı görülmektedir. İlgili grafikler incelendiğinde morfolojik bilgileri içeren haritaların sınıflandırma başarımını artırabilecek bilgiler içerdiği görülmektedir. Her iki veri kümesinde yer alan doğrulama verileri üzerinde başarımın yüksek seviyede olduğu görülebilmektedir.



Şekil 6-3: Houston EMAP_HSG Haritalarına özel DESA Eğitim Grafikleri – a) Kayıp Fonksiyon Değişimini – b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) – c) Top-5 Hatalı Sınıflandırma Oranı Değişimini (Olasılıksal olarak en yüksek 5 değerinin doğru sınıfta eşleşmeme durumu) göstermektedir.



Şekil 6-4: Muufl EMAP Haritalarına özel DESA Eğitim Grafikleri – a) Kayıp Fonksiyon Değişimini – b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) – c) Top-5 Hatalı Sınıflandırma Oranı Değişimi (Olasılıksal olarak en yüksek 5 değerin doğru sınıfla eşleşmeme durumu) göstermektedir.

DESA modelleri ile yalnızca EMAP_HSG verisinin sınıflandırma sonuçları ve kappa istatistik değerleri Tablo 6-3 ile verilmektedir. Yalnızca spektral verilerden oluşan DESA sınıflandırıcısına göre daha yüksek başarımda sonuçlar elde edilmiştir. Her iki veri kümesinde de benzer sonuç karakteristiği bulunmaktadır.

Tablo 6-3: EMAP_HSG DESA Sınıflandırıcı Test Başarımı ve Kappa İstatistik Değeri

Veri Kümesi	Houston	Muufl
Test Verisi Başarımı	%83.09	%88.00
Kappa Değeri	0.8164	0.8435


EMAP_HSG verilerine özel kurulan DESA sınıflandırıcısına ek olarak farklı sınıflandırıcıların spektral veriler üzerindeki başarımları Tablo 6-4 ile verilmektedir. Sınıflandırıcıların başarımlarının birbirlerine yakın değerler ürettiği görülmüştür. Ancak burada genel yaklaşım olarak HSG'lerden elde edilen piksel tabanlı biçimsel veri girdilerinin sınıflandırma sonuçlarını artıracak özellikler içerdiği görülmüştür.

Tablo 6-4: EMAP_HSG Piksel Verilerinin DVM ve Rastgele Orman sınıflandırıcı Test Başarımı ve Kappa İstatistik Değerleri


Veri Kümesi	Houston		Muufi	
	DVM	RO	DVM	RO
Test Başarımı	%82.3645	% 84.2994	%88.3412	%86.1848
Kappa Değeri	0.8085	0.8295	0.8486	0.8216

- **LiDAR Uzamsal Veri Kümesine Özel DESA Sınıflandırıcı**

Muufi ve Houston'a ait LiDAR veri kümelerinden üretilen EMAP uzamsal haritalarına (EMAP_LiDAR) özel olarak oluşturulan DESA modelleri Bölüm 5.1.2'de verilmektedir. Eğitim esnasında oluşan sonuçları içeren grafikler her veri kümesine özel olarak Şekil 6-3 ve Şekil 6-4 ile verilmiştir. Grafiklerde yer alan Top-1 hata değişimi eğitim ve doğrulama kümelerinin her bir yinelemede oluşan hata oranını, Top-5 hata değişimi ise ağ tarafından oluşturulan sonuçların en yüksek 5 olasılıklı değerinin doğru sınıfta bulunmama durumunu gösteren hata durumunu göstermektedir. İlgili grafiklerde sınıf bilgileri farklı olsa da benzer yükseklik değerlerine sahip veriler olduğu görülmektedir. Örneğin Houston veri kümesinde yer alan ezilmiş ve sağlıklı çimen sınıflarına ait yükseklik bilgileri büyük oranda benzerlik göstermektedir. Eğitim esnasında da sınıfların birbirinden ayıramayabildiği görülmüştür. Buna göre LiDAR verilerinin genel sınıflandırma resmini gösterecek değil tamamlayıcı bilgi sağlayacak içeriğe sahip olabileceği görülmektedir. Her iki veri kümesinde de benzer eğitim senaryosu oluşmaktadır.



Şekil 6-5: Houston EMAP_ LiDAR Haritalarına özel DESA Eğitim Grafikleri – a) Kayıp Fonksiyon Değişimi – b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) – c) Top-5 Hatalı Sınıflandırma Oranı Değişimini (Olasılıksal olarak en yüksek 5 değerin doğru sınıfla eşleşmeme durumu) göstermektedir.



Şekil 6-6: Muufi EMAP_ LiDAR Haritalarına özel DESA Eğitim Grafikleri – a) Kayıp Fonksiyon Değişimi – b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) – c) Top-5 Hatalı Sınıflandırma Oranı Değişimini (Olasılıksal olarak en yüksek 5 değerin doğru sınıfla eşleşmeme durumu) göstermektedir.

DESA modelleri ile yalnızca EMAP_ LiDAR verisinin sınıflandırma sonuçları ve kapa istatistik değerleri Tablo 6-5 ile verilmektedir. LiDAR verilerinden üretilen biçimsel özellikleri içeren haritalardan çok sınıflı probleme önemli seviyede bilgi sağlandığı sonuçlardan görünmektedir. Asıl bilgi kaynağı olmayan LiDAR verilerinin tamamlayıcı görevinde önemli katkılar sağlayabileceği sonuçlardan çıkarılabilmektedir.

Tablo 6-5: EMAP_ LiDAR DESA Sınıflandırıcı Test Başarımı ve Kappa İstatistik Değeri

Veri Kümesi	Houston	Mufl
Test Verisi Başarımı	%68.66	%66.05
Kappa Değeri	0.6598	0.6016

EMAP_ LiDAR verilerine özel kurulan DESA sınıflandırıcısına ek olarak DVM ve RF sınıflandırıcılarının LiDAR verilerinden üretilen biçimsel/morfolojik veriler üzerindeki başarımları Şekil 6-4 ile verilmektedir. DVM ve RF Hiperspektral veri kümelerinin sınıflandırma problemlerinde oldukça yaygın olarak kullanılan ve yüksek başarımların yakalanmasını sağlayan sınıflandırıcılardır. DVM kullanılırken kernel olarak lineer yapı kullanılmıştır.

Tablo 6-6: EMAP_HSG Piksel Verilerinin DVM ve Rastgele Orman sınıflandırıcı Test Başarımı ve Kappa istatistik Değerleri

Veri Kümesi	Houston		Mufl	
	DVM	RO	DVM	RO
Test Başarımı	%63.45	%64.8848	%71.4142	69.3232
Kappa Değeri	0.6001	0.6188	%0.6279	0.6116

6.2.3 Sınıflandırıcı Sonuçlarının Tümüleştirilmesi

Üç farklı veri kümesine özel sınıflandırma işlemi gerçekleştirilmiş ve test kümesi üzerindeki başarımları oluşturulmuştur. Morfolojik profil haritaları oluşturulan Hiperspektral ve LiDAR verilerinin sınıflandırma sonuçları ve yalnızca spektral bilgileri içeren DESA tabanlı sınıflandırıcı sonuçları ile test verisinin hangi sınıfta yer alabileceğine dair olasılıksal sonuçlar oluşturulmuştur. Ardından herbir test verisinin sınıfının sonucunun belirlenmesinde eşit ağırlık katsayısı referans alınarak sınıflandırıcı sonuçlarının ortalaması son kararı oluşturmuştur. Öncelikle üç farklı sınıflandırıcının olasılık sonuçlarının farklı kombinasyonlar ile toplanmasının

ardından oluşan sınıflandırma sonuçları iki farklı veri kümesine özel olarak Tablo 6-7 ile verilmektedir.

Tablo 6-7: Olasıksal Eş Ağırlıklı Karar Seviyesinde Tümlleştirme Sonuçları

Veri Seti	Houston		Muufi	
	Test Başarımı	Kappa	Test Başarımı	Kappa
Spektral_HSG EMAP_HSG	%85.96	0.8476	%89.98	0.8686
Spektral_HSG EMAP_LiDAR	%84.64	0.8332	%86.62	0.8277
EMAP_LiDAR EMAP_HSG	%84.18	0.8283	%89.89	0.8674
Spektral_HSG EMAP_HSG EMAP_LiDAR	%88.22	0.8721	%91.81	0.8923

Sonuç olarak en başarılı sınıflandırma üç ayrı sınıflandırıcının eşit ağırlık ile sonuçlarının toplanmasıyla oluştuğu görülmüştür. Burada sınıflandırıcı kararlarının tümlleştirilmesi toplam başarımın artmasında oldukça etkili olmuştur. Sınıflandırıcı kararlarının tümlleştirilmesinin ardından Houston veri kümesinin sınıflandırılmasında en yüksek başarımın yakalandığı EMAP_HSG veri kümesine özel sınıflandırıcı başarımının %4 artış gösterdiği görülmüştür. Muufi veri kümesinde ise yine benzer sonuç karakteristiği görülmüştür.

Houston veri kümesinde ait bütün piksellerin sınıflandırılmasının ardından oluşan bölgeye ait anlamsal bölütleme sonucu Şekil 6-7 ile verilmektedir. Yalnızca test piksellerinin sınıflandırma sonucunu ise Şekil 6-8 verilmektedir. İki ayrı sonuç kümesi incelendiğinde ise Houston veri kümesinde bulut gölgesi ile kararın bölgede bütün sınıflandırıcıların tek başına sınıflandırma başarımının oldukça düştüğü ancak tümlştirmenin ardından başarımın bu bölgede bir miktar yükseldiği görülmektedir.


Muufi veri kümesinde ise sınıflandırma hatalarının görüntünün geneline homojen bir şekilde dağılım gösterdiği görülmektedir. Yalnızca test verilerinin sınıflandırma sonuçları ise Şekil 6-9 ile verilmiştir. Mutlak doğruluk haritasının görselinde sağlandığı şekilde sınıflara ait test veri kümesi sayıları oldukça farklılık göstermektedir.



(a)



(b)



(c)



(d)

Şekil 6-7: Houston Veri Kümesinin DESA ile piksellerin tamamının sınıflandırılması sonuçları – (a) Spektral Sınıflandırıcı Sonucu – (b) EMAP_HSG Sınıflandırıcı Sonucu – (c) EMAP_LiDAR Sınıflandırıcı Sonucu – (d) Olasılıksal Karar Birleştime Sonrası Sınıflandırma Sonucu



(a)



(b)




(c)




(d)


Şekil 6-8: : Houston Veri Kümesinin DESA ile test piksellerin sınıflandırılması sonuçları (Kırmızı: Hatalı sınıflandırma, Yeşil: Doğru Sınıflandırma)– (a) Spektral Sınıflandırıcı Sonucu – (b) EMAP_HSG Sınıflandırıcı Sonucu – (c) EMAP_LiDAR Sınıflandırıcı Sonucu – (d) Olasılıksal Karar Birleştime Sonrası Sınıflandırma Sonucu




(a)




(b)



(c)



(d)



(e)

Şekil 6-9: Muufl Veri Kümesinin DESA ile test piksellerin sınıflandırılması sonuçları– (a) Spektral Sınıflandırıcı Sonucu – (b) EMAP_HSG Sınıflandırıcı Sonucu – (c) EMAP_LiDAR Sınıflandırıcı Sonucu – (d) Olasılıksal Karar Birleştime Sonrası Sınıflandırma Sonucu – (e) Mutlak Doğruluk Haritası (Ground Truth)


6.2.4 Öznitelik Seviyesi Tümlleştirme DESA Sınıflandırma Sonuçları

Bu bölümde uzamsal ve biçimsel özellikleri içeren LiDAR - HSG'leri bilgileri ve spektral bilgilerin sınıflandırma işleminden önce iki farklı yöntemle tümlleştirme gerçekleştirilmiştir. Tümlleştirme işleminin ardından veri kümelerine özel DESA sınıflandırıcı sonuçları alt başlıklarda sunulmuştur.


6.2.5 Piksel Seviyesi Tümlleştirme Veri

Piksel seviyesi tümlleştirmede en iyi DESA sınıflandırma başarımı EMAP_ LiDAR ve EMAP_HSG görüntülerinin piksel seviyesinde tümlleştirilmesiyle elde edilmiştir. Bu kapsamda oluşturulan DESA modeli Bölüm 5.2.1'de verilmektedir.

Eğitim esnasında oluşan sonuçları içeren grafikler herbir veri kümesine özel olarak Şekil 6-10 ve Şekil 6-11 ile verilmiştir. Grafiklerde yer alan Top-1 hata değişimi eğitim ve doğrulama kümelerinin her bir yinelemede oluşan hata oranını, Top-5 hata değişimi ise ağ tarafından oluşturulan sonuçların en yüksek 5 olasılıklı değerinin doğru sınıfta bulunmama durumunu gösteren hata durumunu göstermektedir. Eğitim grafikleri incelendiğinde eğitim esnasında verilerin eğitim kümesinin eğitiminin sağlandığı ve doğrulama kümesi üzerinde de iyi başarımlar elde edildiği görülmektedir. Fazla miktarda verinin eğitim kümesinde kullanılması sonucu oluşturulacak sınıflandırıcının daha iyi bir genelleyici ve sınıflandırıcı olacağı değerlendirilmektedir.



Şekil 6-10: Houston EMAP_ LiDAR ve EMAP_HSG piksel seviyesinde tümleştirilmiş veri kümesine özel DESA Eğitim Grafikleri – a) Hata Fonksiyonu Değişimini – b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) – c) Top-5 Hatalı Sınıflandırma Oranı Değişimini (Olasılıksal olarak en yüksek 5 değerin doğru sınıfla eşleşmeme durumu) göstermektedir.



Şekil 6-11: Muuf EMAP_ LiDAR ve EMAP_HSG piksel seviyesinde tümleştirilmiş veri kümesine özel DESA Eğitim Grafikleri – a) Hata Fonksiyonu Değişimini – b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) – c) Top-5 Hatalı Sınıflandırma Oranı Değişimini (Olasılıksal olarak en yüksek 5 değerin doğru sınıfla eşleşmeme durumu) göstermektedir.

DESA modelleri ile piksel seviyesinde tümleştirilmiş EMAP_HSG ve EMAP_LiDAR verilerinin sınıflandırma sonuçları ve kappa istatistik değerler Tablo 6-8 ile verilmektedir. Sonuç olarak Houston veri kümesine göre olasılıksal karar seviyesinde elde edilmiş test başarımından daha yüksek başarımlar elde edilmiştir. Ancak Muufl veri kümesinde piksel seviyesinde tümleştirmeden elde edilen başarımların olasılıksal karar seviyesinde tümleştirmeden daha düşük sonuçlar verdiği görülmektedir.

Tablo 6-8: EMAP_LiDAR ve EMAP_HSG Piksel Seviyesinde Tümleştirilmiş Veri Kümesine Özel DESA sınıflandırıcı Test Başarımı ve Kappa istatistik Değeri

Veri Kümesi	Houston	Muufl
Test Verisi Başarımı	%89.08	%89.45
Kappa Değeri	0.8814	0.8621

EMAP_LiDAR ve EMAP_HSG Piksel Seviyesinde Tümleştirilmiş veri kümesine özel kurulan DESA sınıflandırıcısına ek olarak farklı sınıflandırıcıların tümleştirilmiş veri kümesi üzerindeki başarımları Tablo 6-9 ile verilmektedir. Sınıflandırıcıların başarımlarının birbirlerine yakın değerler ürettiği görülmüştür ancak burada özellikle yarışma verisi olarak sunulmuş ve test-eğitim kümesinin ayrı paylaşıldığı veri kümesi olan Houston veri kümesinde DESA ile elde edilen başarımların daha iyi sonuçlar verdiği görülmektedir.

Tablo 6-9 EMAP_LiDAR ve EMAP_HSG Piksel Seviyesinde Tümleştirilmiş Veri Kümelerinin Piksel Seviyesinde DVM ve Rastgele Orman Sınıflandırıcısı Test Başarımı ve Kappa istatistik Değerleri

Veri Kümesi	Houston		Muufl	
	DVM	RO	DVM	RO
Test Başarımı	%87.7675	%88.6857	%90.6003	%89.88
Kappa Değeri	0.8671	0.8771	0.8773	0.8681

Houston veri kümesine ait bütün piksellerin sınıflandırılmasının ardından oluşan bölgeye ait anlamsal bölütleme sonucu ve yalnızca test piksellerinin sınıflandırma sonucunu Şekil 6-12 ile verilmektedir. Buluttan kaynaklı karartı oluşan bölgede bulunan test verilerinin doğru sınıflandırılmasının bu tümleştirme yöntemiyle artış

gösterdiği görülmektedir. Muufl veri kümesine ait mutlak doğruluk ile sınıflandırma sonucu Şekil 6-13 ile verilmektedir. Sınıflandırma hatalarının belirli bir bölgede toplanmadığı görülmüştür.




(a)




(b)

Şekil 6-12: Houston_EMAP ve Houston_ LiDAR Piksel Seviyesinde Tümleştirilmiş Veri Kümesinin DESA ile Sınıflandırılması – (a) piksellerin tamamının sınıflandırılması sonuçları –(b) Test piksellerin sınıflandırılması sonuçları (Kırmızı: Hatalı sınıflandırma, Yeşil: Doğru Sınıflandırma)



(a)




(b)

Şekil 6-13: Muufl_EMAP ve Houston_ LiDAR Piksel Seviyesinde Tümleştirilmiş Veri Kümesinin DESA ile Sınıflandırılması – (a) Sınıflandırıcı Sonucu (b) Mutlak Doğruluk Haritası (Ground Truth)


6.2.6 Boyutsal Tümlleştirme ve Alexnet İlk Evrişim Katmanı ile Filtreleme ile Oluşturulmuş Veri Kümesi Sınıflandırıcı Sonuçları

Tez kapsamında önerilen ve özellikle Houston veri kümesinde başarılı sonuçlar alınmasını sağlayan DESA modeline ait detaylı bilgiler Bölüm 5.2.2’de verilmektedir. Bu modele özel olarak AlexNet filtreleri yardımıyla DESA’nın girdileri oluşturulmuş ve ağıın sonuçlarının oldukça başarılı olduğu görülmüştür. Özellikler Houston veri kümesinde gölgelik alan olarak tanımlanan bölgede yer alan test verilerinin başarımının arttığı görülmüştür. Çok kısa bir zamanda veri kümesinin eğitilmesi sağlanmıştır. AlexNet filtreleri yardımıyla girdi imgelerinden sınıflandırmayı kolaylaştırabilen özellikler çıkarılmış ve daha az iterasyonlar ile sınıflandırıcıların eğitimi tamamlanmıştır. Burada veri kümesi sınıflandırmadan önce [0 255] aralığına normalize edilmiştir.

Eğitim esnasında oluşan sonuçları içeren grafikler herbir veri kümesine özel olarak Şekil 6-10 ve Şekil 6-11 ile verilmiştir. Grafiklerde yer alan Top-1 hata değişimi eğitim ve doğrulama kümelerinin her bir yinelemede oluşan hata oranını, Top-5 hata değişimi ise ağı tarafından oluşturulan sonuçların en yüksek 5 olasılıklı değerinin doğru sınıfta bulunmama durumunu gösteren hata durumunu göstermektedir. Eğitim grafikleri incelendiğinde eğitim esnasında verilerin eğitim kümesinin eğitiminin sağlandığı ve doğrulama kümesi üzerinde de iyi başarımlar elde edildiği görülmektedir.



Şekil 6-14: Houston boyutsal tümleştirilmiş ve AlexNet İlk Evrişim Katmanı ile filtrelenmiş veri kümesine özel DESA Eğitim Grafikleri – a) Hata Fonksiyonu Değişimini – b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) – c) Top-5 Hatalı Sınıflandırma Oranı Değişimini (Olasılıksal olarak en yüksek 5 değerin doğru sınıfla eşleşmeme durumu) göstermektedir.



Şekil 6-15: Muufl boyutsal tümleştirilmiş ve AlexNet İlk Evrişim Katmanı ile filtrelenmiş veri kümesine özel DESA Eğitim Grafikleri – a) Hata Fonksiyonu Değişimini – b) Top-1 Hatalı Sınıflandırma Oranı Değişimini (Toplam Oransal Hata) – c) Top-5 Hatalı Sınıflandırma Oranı Değişimini (Olasılıksal olarak en yüksek 5 değerin doğru sınıfla eşleşmeme durumu) göstermektedir.

Bu yöntem ile birlikte Houston veri kümesinden en yüksek sınıflandırma başarımına ulaşılmıştır. Her iki veri kümesinde ulaşılan test başarım ve kappa istatistik değerleri Tablo 6-10 ile verilmektedir.

Tablo 6-10: Houston- Muufl Spektral--EMAP_HSG--EMAP_ LiDAR Boyutsal Tümlleştirilmiş ve AlexNet İlk Evrişim katmanı Filtreleri ile Oluşturulmuş Veri Kümelerine DESA sınıflandırıcı Test Başarımı ve Kappa istatistik Değeri

Veri Kümesi	Houston	Muufl
Test Verisi Başarımı	%93.97	%90.86
Kappa Değeri	0.9346	0.8809

Özellikle Houston veri kümesinde genel olarak sınıflandırma başarımının düşmesine sebep olan gölgelik alan test kümesinin önerilen bu yöntem ile başarımının yükseldiği görülmüştür. Bütün piksellerin sınıflandırıldığı ve yalnızca test verilerinin sınıflandırma durumu Şekil 6-16 ile verilmektedir.




(a)




(b)

Şekil 6-16: Houston, Spektral-EMAP_HSG-EMAP_ LiDAR Boyutsal Tümlleştirilmiş ve AlexNet İlk Evrişim katmanı Filtreleri ile Oluşturulmuş Veri Kümesinin DESA ile Sınıflandırılması – (a) piksellerin tamamının sınıflandırılması sonuçları –(b) Test piksellerin sınıflandırılması sonuçları (Kırmızı: Hatalı sınıflandırma, Yeşil: Doğru Sınıflandırma)

Muufl veri kümesinde ise olasılıksal karar tabanlı birleştirme sonucunun bir miktar gerisinde sonuçlar olduğu görülmüştür. Ancak Muufl veri kümesinde işaretlenmiş sınıfların birbirine karışabildiği görülmüştür. Buna rağmen önerilen bu yöntemle ciddi başarım sonuçları elde edilmiştir. Sınıflandırma sonucu Şekil 6-17 ile verilmektedir.



(a)



(b)

Şekil 6-17: Muufl, Spektral-EMAP_HSG-EMAP_ LiDAR Boyutsal Tümeleştirilmiş ve AlexNet İlk Evrişim katmanı Filtreleri ile Oluşturulmuş Veri Kümesinin DESA ile Sınıflandırılması – (a) Sınıflandırıcı Sonucu (b) Mutlak Doğruluk Haritası (Ground Truth)

6.3 Karşılaştırma Sonuçları

Houston veri kümesinin her aşamada gerçekleştirilmiş sınıflandırma sonuçlarını içeren sonuçlar özet halinde Tablo 6-12 ile verilmiştir. Sonuç olarak tez kapsamında yeni bir tümeleştirme yöntemi olarak önerilen boyutsal tümeleştirme ve ardından AlexNet filtrelerinin kullanımı sonucu oluşan veri kümesinin DESA tarafından sınıflandırılması ile başarımın ciddi oranda arttığı görülmüştür.

Houston ve Muufl sınıf numaraları ile sınıf isimlerinin eşleştirilmesi hatırlatma amacıyla Tablo 6-11 ile verilmektedir.

Tablo 6-11: Houston ve Muufl Sınıf Numarası ve Sınıf Adı

Sınıf Numarası	Houston	Muufl
1	Sağlıklı Çimen	Ağaçlık Bölge
2	Ezilmiş Çimen	Çoğunlukla Çimenlik Bölge
3	Yapay Çimen	Karışık Zemin Yüzeyi Bölgesi
4	Ağaç	Kumlu Bölge
5	Toprak	Yol
6	Su	Su Bölgesi
7	Evsel Bölge	Bina Bölgesi
8	İşyeri Bölgesi	Bina Gölgesi
9	Asfalt Yol	Yaya Kaldırımı
10	Otoyol	Sarı Kaldırım
11	Tren Yolu	Kumaş Paneller
12	Otopark 1	
13	Otopark 2	
14	Tenis Kortu	
15	Koşu Yolu	

Tablo 6-12: Houston Veri Kümesine Özel Tez Kapsamında Önerilen Yöntemlerin Sonuç Karşılaştırması

Sınıf	Yalnızca Spektral	EMAP_HSG	EMAP_LiDAR	Olasılıksal Karar Tümlleştirme	Piksel Seviyesinde Tümlleştirme (EMAP_HSG) (EMAP_LiDAR)	Boyutsal Tümlleştirme ve AlexNet İlk Katman uygulaması
#1	83.09	78.63	49.76	82.81	82.90	84.42
#2	82.98	79.41	59.30	85.05	84.96	98.97
#3	99.80	100	89.90	100	99.80	100
#4	92.71	84.66	57.95	92.80	93.28	97.82
#5	97.92	99.05	86.46	99.90	99.33	99.90
#6	96.50	99.30	86.71	100	91.61	99.30
#7	87.5	83.30	70.80	93.09	92.44	92.44
#8	42.16	61.25	85.28	75.68	88.22	96.87
#9	81.77	79.32	68.46	86.68	86.12	90.93
#10	55.79	95.27	61.58	83.49	91.99	82.33
#11	77.89	64.61	71.06	74.29	78.84	99.43
#12	76.75	85.21	63.68	95.77	82.42	90.49
#13	78.59	77.54	55.43	78.94	80.35	87.02
#14	98.78	100	96.76	100	100	100
#15	97.67	100	60.67	99.37	99.15	100
Genel Test Başarımı	80.25	83.09	68.66	88.22	89.08	93.97
Ortalama Test Başarımı	83.32	85.84	70.92	89.86	90.09	94.66
kappa	0.7860	0.8164	0.6598	0.8721	0.8814	0.9346

En başarılı sınıflandırıcıya ait karışıklık matrisi Tablo 6-13 ile verilmektedir. Burada özellikle sağlıklı çimen (#1) ile ezilmiş çimen (#2) sınıflarının birbirlerine karışabildiği görülmektedir. Spektral imzaları çok yüksek oranda benzerlik gösteren bu iki sınıfın çevresinde yer alan sınıfların benzerlik gösterebilmesi durumundan dolayı ayrıca diğer çalışmalarda da birbirine en çok karışan sınıflar olduğu için toplam başarıyı etkileyen önemli unsur olduğu görülmektedir. Buna ek olarak özellikle gölgelik alanda bulunan test verilerinin toplam sınıflandırma başarılarını düşüren etkiye sebep olduğu görülmektedir.

Tablo 6-13: Houston En Başarılı Sınıflandırıcı (Boyutsal Tümlleştirilmiş AlexNet ilk Evrişim Katmanı ile Filtrelenmiş DESA Sınıflandırıcısı) Karışıklık Matrisi

	#1	#2	#3	#4	#5	#6	#7	#8	#9	#10	#11	#12	#13	#14	#15
#1	84.40	14.6	-	0.95	-	-	-	-	-	-	-	-	-	-	-
#2	0.66	98.9	-	0.38	-	-	-	-	-	-	-	-	-	-	-
#3	-	-	100	-	-	-	-	-	-	-	-	-	-	-	-
#4	1.04	1.04	-	97.82	-	-	0.09	-	-	-	-	-	-	-	-
#5	-	-	-	-	99.90	-	-	-	-	-	-	-	-	0.09	-
#6	-	-	-	-	-	99.30	-	-	-	-	-	-	0.69	-	-
#7	0.18	0.37	-	0.09	-	0.56	92.44	4.38	0.09	-	1.21	0.09	0.56	-	-
#8	-	-	-	-	-	-	1.71	96.86	-	-	-	-	1.42	-	-
#9	-	-	-	-	1.42	-	-	-	90.93	0.66	3.49	3.49	-	-	-
#10	-	-	-	-	-	-	-	3.18	0.09	82.34	14.38	-	-	-	-
#11	-	-	-	-	-	-	-	-	-	0.28	99.43	-	0.28	-	-
#12	-	-	-	-	-	-	-	9.03	-	-	0.38	90.49	0.09	-	-
#13	-	-	-	-	-	-	-	-	5.61	-	4.91	2.46	87.02	-	-
#14	-	-	-	-	-	-	-	-	-	-	-	-	-	100	-
#15	-	-	-	-	-	-	-	-	-	-	-	-	-	-	100

Derin evrişimli sinir ağlarının yer aldığı diğer çalışmalar ile karşılaştırıldığında ise oluşan sonuçlar Tablo 6-14 ile verilmektedir. Özellikle gölge bölgeye yönelik ekstra bir önlem alınmayan çalışmalar içerisinde en iyi sınıflandırıcı sonucunun yakalandığı görülmüştür. Ancak gölgeden kaynaklı alana özel önlem alan sınıflandırıcı sonuçlarından bir miktar düşük sınıflandırma sonuçları elde edilmiştir.

Tablo 6-14: Houston Veri kümesine Özel Önerilen Boyutsal Tümeleştirilmiş AlexNet ilk Evrişim Katmanı ile Filtrelenmiş DESA Sınıflandırıcı Yönteminin Mevcut Sonuçlar ile Karşılaştırılması

Sınıf	GBFF CNN [32]	MLRsub MRF [28]	OTCVA RF [30]	GGF-SVM [27]	MFC SVM [31]	Önerilen Yöntem
#1	78.73	83.1	80.6	82.9	97.3	84.42
#2	94.92	83.1	99.6	99.3	97.0	98.97
#3	100	100	100	100	100	100
#4	99.34	95.9	96	99.3	97.4	97.82
#5	99.62	100	99.4	100	99.8	99.90
#6	95.80	98.8	95.8	95.1	95.8	99.30
#7	87.87	84.8	86.0	90.9	97.4	92.44
#8	95.25	83.6	93.5	95.6	91.5	96.87
#9	89.71	96.5	97.1	89.3	93.9	90.93
#10	81.18	86.8	68.5	92.8	90.1	82.33
#11	86.34	99.7	98.9	96.6	98.6	99.43
#12	92.70	99.8	100	91.9	97.7	90.49
#13	87.02	85.3	74.7	74.4	82.5	87.02
#14	99.19	100	100	100	100	100
#15	89.64	98.7	100	98.7	98.7	100
Genel Test Başarımı	91.8	92.9	92.7	93.8	95.6	93.97
Ortalama Test Başarımı	91.0	92.0	92.4	94.0	95.9	94.66
kappa	0.90	0.91	0.92	0.93	0.96	0.9346
Gölge Düzeltme	x	x	x	x	+	x

Mufl veri kümesinin her aşamada gerçekleştirilmiş sınıflandırma sonuçlarını içeren sonuçlar özet halinde Tablo 6-15 ile verilmiştir. En iyi başarımın sağlandığı yöntem olasılıksal karar tümeleştirme olduğu görülmektedir. Genel doğru sınıflandırma oranına bakıldığında ise Houston veri kümesinde en yüksek başarımların elde edildiği yöntem olan boyutsal tümeleştirme tabanlı DESA sınıflandırıcısı ile en başarılı sonuçlar elde edilmektedir.

Tablo 6-15: Muufl Veri Kümesine Özel Tez Kapsamında Önerilen Yöntemlerin Sonuç Karşılaştırması

Sınıf	Yalnızca Spektral	EMAP_HSG	EMAP_Lidar	Olasılıksal Karar Tümeleştirme	Piksel Seviyesinde Tümeleştirme (EMAP_HSG) (EMAP_LİDAR)	Boyutsal Tümeleştirme ve AlexNet İlk Katman uygulaması
#1	86.39	89.71	74.64	93.61	90.90	89.51
#2	75.41	89.18	60.35	92.51	87.50	92.85
#3	70.36	83.72	40.82	85.43	84.78	87.76
#4	88.58	92.41	79.49	96.29	93.74	95.77
#5	82.16	85.36	44.04	89.91	86.09	90.39
#6	93.98	96.44	99.18	99.45	98.90	99.72
#7	82.51	90.24	71.54	91.23	91.88	94.88
#8	75.86	88.76	84.51	93.35	92.81	95.34
#9	63.57	85.44	43.65	84.28	80.77	88.56
#10	96.38	96.38	86.74	98.79	100	98.79
#11	99.40	100	95.85	100	100	98.81
Test Başarımı	0.81	0.88	0.66	0.91	0.89	0.90
Ortalama Test Başarımı	83.15	90.69	70.98	93.17	91.58	93.85
kappa	0.8099	0.8435	0.6016	0.8923	0.8621	0.8809

Muufl veri kümesi için en başarılı sınıflandırıcıya ait karışıklık matrisi Tablo 6-16 ile verilmektedir. Burada veri kümesi işaretlenirken bazı piksellerin sınıfına ait net yaklaşım bulunmayabilmektedir. Bu sebeple sınıf başlıklarında çoğunlukla ifadesi yer almıştır. Karışıklık matrisi incelendiğinde “çoğunlukla çimenlik bölge (2)” ve “karışık zemin yüzeyi (3)” sınıflarının birbirlerine karışabildiği gözükmetedir. Burada her iki sınıfın verilerinin karışma durumunun yüksek olasılıklı olduğu değerlendirilmektedir. Yaya kaldırımı ve kumlu bölgeler sınıflarında birbirlerine karışabildiği görülmüş ve bu sınıflarında birbirlerine komşu piksellerde yer aldığı ve geçiş esnasında sınıf işaretlerinin birbirine kayabileceği değerlendirilmektedir.

Tablo 6-16: Muufl En Başarılı Sınıflandırıcı (Olasıksal Kararları Tümüleştirilmesi ile Oluşan Sınıflandırıcı) Karışıklık Matrisi

	#1	#2	#3	#4	#5	#6	#7	#8	#9	#10	#11
#1	93.61	1.83	1.11	0.15	0.34	0.44	2.10	0.10	0.19	0.09	0.00
#2	1.22	92.51	5.17	0.02	0.07	0.40	0.02	0.23	0.11	0.16	0.02
#3	1.51	9.52	85.43	0.94	0.36	0.50	0.05	0.05	0.97	0.14	0.47
#4	0.05	0.05	0.63	96.29	0.11	-	-	0.05	2.60	0.17	-
#5	1.70	0.30	1.01	0.36	89.91	0.01	0.42	0.72	3.62	1.89	-
#6	0.27	-	0.27	-	-	99.45	-	-	-	-	-
#7	3.93	0.51	0.46	0.09	1.50	0.04	91.23	2.01	0.14	0.04	-
#8	1.05	0.17	0.06	0.03	0.48	0.01	2.44	93.35	2.21	0.14	-
#9	0.77	1.08	3.26	6.38	1.86	-	0.07	0.38	84.28	1.86	-
#10	-	1.20	-	-	-	-	-	-	-	98.79	-
#11	-	-	-	-	-	-	-	-	-	-	100

Muufl Gulport veri kümesine yönelik anlamsal bölütleme operasyonunun uygulandığı çalışma miktarı oldukça düşüktür. Bu tezde Muufl veri kümesi özellikle Houston veri kümesi için uygulanan tümleştirme ve sınıflandırma yöntemlerinin başka bir veri kümesinde ne gibi sonuçlar üreteceğini değerlendirmek için ele alınmıştır. Sonuç olarak Houston veri kümesinde etkileyici sonuçlar elde edilmesini sağlayan boyutsal tümleştirme ardından AlexNet evrişim filtreleri ile filtreleme sonuç olarak DESA sınıflandırıcı kurulumu yöntemi Muufl veri kümesinde etkili sonuçlar vermiştir. Aynı derin öğrenme mimarisi içerisinde farklı veri kümeleri için iyi bir sınıflandırma kurgusu oluşturulmuştur.

7. SONUÇLAR VE DEĞERLENDİRME

Bu tez kapsamında gerçekleştirilen çalışmalarda hiperspektral veriler ve LiDAR verilerine sahip veri kümelerinin tümleştirilmesi ve anlamsal bölütlenmesi için yeni tümleştirme ve sınıflandırma yöntemi önerilmiştir. İlk aşama olarak hiperspektral ve LiDAR verilerinden biçimsel özellikleri içeren profiller üretilmiş ve yeni veri kümelerinin oluşturulması sağlanmıştır.

Önerilen tümleştirme yöntemlerinden karar seviyesinde tümleştirmede piksel tabanlı olarak biçimsel haritaları içeren hiperspektral, LiDAR verilerine ve yalnızca spektral verilere özel derin evrişimsel sinir ağı kurulmuştur. Özellikle Houston veri kümesinde bulut gölgesi altında kalan test verilerinin yalnızca spektral bilgi kullanılması durumunda başarımının oldukça düşük olduğu ve bu durumun genel başarımı düşürdüğü gözlenmiştir. Buna ek olarak biçimsel LiDAR verilerinin sınıflandırma

sonucunun tek başına düşük seviyede olmasına rağmen sınıflandırıcı kararlarının ortaklanması esnasında başarımı artıran bir etki gösterdiği görülmüştür. Sonuç olarak Muufl ve Houston verilerinin sınıflandırılmasında olasılıksal karar seviyesinde tümleştirmenin genel sınıflandırma başarımını oldukça yükselttiği görülmüştür. Houston veri kümesinde yalnızca spektral bilgiler ile oluşturulan sınıflandırıcı sonuçları %80.25 iken sınıflandırıcı kararlarının tümleştirilmesinin ardından bu oran %89.86'ya ulaşmıştır. Muufl veri kümesinde ise yalnızca spektral veriler ile %81 olan başarımların ardından %91'e ulaşmıştır. LiDAR sınıflandırıcı etkisi dahil edilmediği durumda ise sınıflandırıcı başarımlarının %3 civarında daha düşük değerler oluşturduğu görülmüştür.

Yarışma veri kümesi olan Houston'a yönelik olarak özellik seviyesinde tümleştirmede bu tez çalışmasında ilk kez önerilen yöntem ile sınıflandırma başarımları oldukça etkileyici değerlere ulaşmıştır. Önerilen bu yöntem kapsamında öncelikle piksel seviyesinde biçimsel haritalardan ve HSG'den veriler alınmış ve veriler interpolasyon ile boyutu artırılmış ardından kaydırma ve alt alta yerleştirme operasyonu ile birlikte 224 x 224 x 3 boyutuna getirilmiştir. Bu işlemin ardından AlexNet'in ilk katmanında yer alan filtreler kullanılarak bu veri kümesinden özellikler çıkarılmıştır. Piksellerin kaydırılması sonucu her bir spektral bandın birbirine göre durumunun filtreleme ile incelenmesi sağlanmıştır. AlexNet filtrelemesi sonrası oluşan veri kümesine özel DESA kurulmuş ve başarımın mevcut çalışmalarda gölge bulmaya yönelik özel çalışma gerçekleştirilmeyen çalışmalar içerisinde en iyi sonuç verdiği görülmüştür. Muufl veri kümesinde ise benzer yöntem ve DESA mimarisi ile başarılı sonuçlar elde edilmiş ancak olasılıksal karar tümleştirmede daha başarılı sonuçlar alındığı görülmüştür. Muufl veri kümesinin piksellerinin işaretlenmesi esnasında bazı piksellerin hangi sınıfta yer aldığına dair bir miktar belirsizliklerin bulunduğu görülmüştür. Tez kapsamında Muufl veri kümesinin Houston'a ek olarak kullanılmasındaki temel amaç ise önerilen yöntemin farklı veri kümelerinde çalışabilirliğini göstermektir.

Derin evrimsel sinir ağlarının son yıllarda oldukça popüler olması sonucunda, bu ağların birçok yeni alanda uygulanabilirliği sorgulanmaktadır. Hiperspektral veri kümelerinin sınıflandırılmasında da oldukça etkili sonuçlar verebildiği bu tez kapsamında çıkarılan önemli sonuçlardan bir tanesidir. Ancak spektral bilgileri destekleyecek biçimsel ve uzamsal bilgilerin DESA'ya girdi olarak verilmesini

sağlamak gerekliliği çalışmadan çıkarılan en önemli sonuçlardan bir tanesidir. DESA'da yer alan aktivasyon katmanı olarak RELU'nun ve evrişim katmanı sonrasında gerçekleştirilecek olan yığın normalizasyonunun ("Batch normalization") DESA'nın başarımını daha da artırdığı görülmüştür.

Tezin genel literatüre katkısı ise; hiperspektral verilerin sınıflandırılması için önerilen derin evrişimsel sinir ağlarının rekabetçi sonuçlar vermesi olmuştur. Özellikle eğitim veri kümesinde bulunan veri mитарının artırılması DESA'nın başarımını daha da üst seviyelere taşınmasını sağlayacaktır. Bütün bunlara ek olarak LiDAR verisinin çok önemli tamamlayıcı bilgiler sağladığı ancak bu bilgilerin doğru tümleştirme yöntemiyle ortaya çıkabileceği görülmüştür. AlexNet ile önerilen filtrelerin ise genel özellik bilgilerini kullanmak için oldukça kullanışlı bilgiler sunduğu ve bu filtrelerin HSG'lere uygulanabilirliği bu tez çalışmasında gösterilmiştir.

KAYNAKLAR (REFERENCES)

- [1] S. E. Yüksel, S. Küçük, E. Gunes, M. Boyacı, K. G. Toker “Hacettepe Üniversitesi’nde Uzaktan Algılama Çalışmaları”, Elektrik Mühendisliği, Temmuz **2015**.
- [2] D. G. Manolakis, R. B. Lockwood, T. W. Cooley, Hyperspectral Imaging Remote Sensing: Physics, Sensors, and Algorithms Cambridge University Press, **2016**.
- [3] D. Gerçek, D. Çeşmeci, M.K. Güllü, A. Ertürk, S. Ertürk, Hiperspektral görüntüleme ve görüntü işlemenin bugünü, yakın geleceği ve mevcut araştırma eğilimleri, XYZ Dergi, 18 - 25, **2013**.
- [4] M.S Kim, Y.R. Chen, P.M. Mehl, “Hyperspectral Reflectance and Fluorescence Imaging System for Food Quality and Safety”, Transactions of ASAE, vol.44, no.3,721-729, **2001**.
- [5] J.M. Cathcart, R.D. Bock, ve R. Campbell, “Analysis of Soil and Environmental Processes on Hyperspectral Infrared Signatures of Landmines”, Technical Report, Georgia Inst. of Tech.-Electro-Optics Environment and Materials Lab. Available at: <http://handle.dtic.mil/100.2/ADA432578>, **2004**.
- [6] M. Maggioni, G.L. Davis, F.J. Warner, F.B. Geshwind, A.C. Coppi, R.A. DeVerse, ve R.R. Coifman, “Hyperspectral Microscopic Analysis of Normal, Benign and Carcinoma Microarray Tissue Sections”, edited by Alfano R.R. ve Katz A., Optical Biopsy VI, vol. 6091, no.1, p. 60910I, SPIE, **2006**
- [7] IEEE Geoscience and Remote Sensing Society 2013 Data Fusion Contest. <http://www.grss-ieee.org/community/technical-committees/data-fusion>.
- [8] P. Gader, A. Zare, R. Close, J. Aitken, and G. Tuell, Muufl gulfport hyperspectral and lidar airborne data set. Technical Report Tech. Rep. REP-2013-570, University of Florida, Gainesville, FL, Oct. **2013**.
- [9] S. Gautama, G. Heene, R. Pires, J. D'Haeyer, I. Bruyland, Ignace, Computer vision techniques for remote sensing, **2017**.
- [10] P. S. Sabale, and C. R. Jadhav. “Supervised, Unsupervised, and Semisupervised Classification Methods for Hyperspectral Image Classification- A Review.”, **2014**.
- [11] F. M. Lacar, M. Lewis, I, T. Grierson, Use of hyperspectral imagery for mapping grape varieties in the Barossa Valley, South Australia. 6. 2875 - 2877 vol.6. 10.1109/IGARSS.2001.978191, **2001**.

- [12] X. Huang and L. Zhang, "An SVM ensemble approach combining spectral, structural, and semantic features for the classification of high-resolution remotely sensed imagery," *IEEE Trans. Geosci. Remote Sens.*, vol. 51, no. 1, pp. 257–272, Jan. **2013**.
- [13] Freek van der Meer, Analysis of spectral absorption features in hyperspectral imagery, In *International Journal of Applied Earth Observation and Geoinformation*, Volume 5, Issue 1, Pages 55-68, **2004**.
- [14] G. Camps-Valls, L. Bruzzone, Kernel-based methods for hyperspectral image classification. *Geoscience and Remote Sensing*, *IEEE Transactions on*. 43. 1351 – 1362, **2005**.
- [15] G. M. Foody and A. Mathur, "A relative evaluation of multiclass image classification by support vector machines," in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 42, no. 6, pp. 1335-1343, June **2004**
- [16] J Wang and C. Chang, "Independent component analysis-based dimensionality reduction with applications in hyperspectral image analysis," in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 44, no. 6, pp. 1586-1600, June **2006**.
- [17] L. Gao *et al.*, "Subspace-Based Support Vector Machines for Hyperspectral Image Classification," in *IEEE Geoscience and Remote Sensing Letters*, vol. 12, no. 2, pp. 349-353, Feb. **2015**.
- [18] W. Li, S. Prasad, J. E. Fowler and L. M. Bruce, "Locality-Preserving Dimensionality Reduction and Classification for Hyperspectral Image Analysis," in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 50, no. 4, pp. 1185-1198, April **2012**.
- [19] B. Song *et al.*, "Remotely Sensed Image Classification Using Sparse Representations of Morphological Attribute Profiles," in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 52, no. 8, pp. 5122-5136, Aug. **2014**.
- [20] G. Camps-Valls, N. Shervashidze and K. M. Borgwardt, "Spatio-Spectral Remote Sensing Image Classification With Graph Kernels," in *IEEE Geoscience and Remote Sensing Letters*, vol. 7, no. 4, pp. 741-745, Oct. **2010**.
- [21] J. Li, J. M. Bioucas-Dias and A. Plaza, "Spectral–Spatial Classification of Hyperspectral Data Using Loopy Belief Propagation and Active Learning," in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 51, no. 2, pp. 844-856, Feb. **2013**.

- [22] Y. Chen, Z. Lin, X. Zhao, G. Wang and Y. Gu, "Deep Learning-Based Classification of Hyperspectral Data," in *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 7, no. 6, pp. 2094-2107, June **2014**.
- [23] Y. Chen, X. Zhao, and X. Jia, "Spectral-spatial classification of hyperspectral data based on deep belief network," *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens.*, vol. 8, no. 6, pp. 2381-2392, Jun. **2015**.
- [24] W. Hu, Y. Huang, L. Wei, F. Zhang, H. Li., Deep Convolutional Neural Networks for Hyperspectral Image Classification. *Journal of Sensors*, 1-12, **2015**.
- [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," in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 54, no. 10, pp. 6232-6251, Oct. **2016**.
- [26] M. Salman and S. E. Yüksel, "Hyperspectral data classification using deep convolutional neural networks," *24th Signal Processing and Communication Application Conference (SIU)*, Zonguldak, Turkey, 2016, pp. 2129-2132, **2016**.
- [27] W. Liao, A. Pižurica, R. Bellens, S. Gautama and W. Philips, "Generalized Graph-Based Fusion of Hyperspectral and LiDAR Data Using Morphological Features," in *IEEE Geoscience and Remote Sensing Letters*, vol. 12, no. 3, pp. 552-556, March **2015**.
- [28] M. Khodadadzadeh, J. Li, S. Prasad and A. Plaza, "Fusion of Hyperspectral and LiDAR Remote Sensing Data Using Multiple Feature Learning," in *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 8, no. 6, pp. 2971-2983, June **2015**.
- [29] H. Aytaylan and S. E. Yuksel, "Semantic segmentation of hyperspectral images with the fusion of LiDAR data," *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Beijing, 2016, pp. 2522-2525, **2016**.
- [30] B. Rasti, P. Ghamisi, J. Plaza and A. Plaza, "Fusion of Hyperspectral and LiDAR Data Using Sparse and Low-Rank Component Analysis," in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 55, no. 11, pp. 6354-6365, Nov. **2017**.
- [31] R. Luo *et al.*, "Fusion of Hyperspectral and LiDAR Data for Classification of Cloud-Shadow Mixed Remote Sensed Scene," in *IEEE Journal of Selected*

- Topics in Applied Earth Observations and Remote Sensing*, vol. 10, no. 8, pp. 3768-3781, Aug. **2017**.
- [32] P. Ghamisi, B. Höfle and X. X. Zhu, "Hyperspectral and LiDAR Data Fusion Using Extinction Profiles and Deep Convolutional Neural Network," in *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 10, no. 6, pp. 3011-3024, June **2017**.
- [33] Y. Chen, C. Li, P. Ghamisi, X. Jia and Y. Gu, "Deep Fusion of Remote Sensing Data for Accurate Classification," in *IEEE Geoscience and Remote Sensing Letters*, vol. 14, no. 8, pp. 1253-1257, Aug. **2017**.
- [34] G. Cybenko, "Approximations by superpositions of sigmoidal functions", *Mathematics of Control, Signals, and Systems*, 2 (4), 303-314, 1989.
- [35] D. Stathakis, "How many hidden layers and nodes", *International Journal of Remote Sensing*, 30 pp. 2133-2147, **2009**.
- [36] Y. Lecun, L. Bottou, Y. Bengio and P. Haffner, "Gradient-based learning applied to document recognition," in *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, Nov **1998**.
- [37] A. Krizhevsky, I. Sutskever, G. E. Hinton, ImageNet Classification with Deep Convolutional Neural Networks. *Neural Information Processing Systems*. 25. . 10.1145/3065386, **2012**.
- [38] C. Szegedy *et al.*, "Going deeper with convolutions," *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, 2015, pp. 1-9, **2015**.
- [39] Y. Bengio, P. Simard and P. Frasconi, "Learning long-term dependencies with gradient descent is difficult," in *IEEE Transactions on Neural Networks*, vol. 5, no. 2, pp. 157-166, Mar **1994**.
- [40] A. L. Maas, A. Y. Hannun, A. Y. Ng, "Rectifier nonlinearities improve neural network acoustic models", *Proc. ICML*, vol. 30, **2013**.
- [41] W. Liao, R. Bellens, A. Pižurica, W. Philips, and Y. Pi, "Classification of hyperspectral data over urban areas using directional morphological profiles and semi-supervised feature extraction," *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens.*, vol. 5, no. 4, pp. 1177–1190, Aug. **2012**.
- [42] J. A. Benediktsson, J. A. Palmason, J. R. Sveinsson, and J. Chanussot. Decision level fusion in classification of hyperspectral data from urban areas. In

- Geoscience and Remote Sensing Symposium, 2004. IGARSS '04. Proceedings. 2004 IEEE International, volume 1, page 76, Sept **2004**.
- [43] Z. Ye, S. Prasad, W. Li, J. E. Fowler, and M. He. Classification based on 3-d dwt and decision fusion for hyperspectral image analysis. *IEEE Geoscience and Remote Sensing Letters*, 11(1):173–177, Jan **2014**.
- [44] Q. Man, P. Dong, and H. Guo. Pixel-and feature-level fusion of hyperspectral and lidar data for urban land-use classification. *Int. J. Remote Sens.*, 36(6):1618–1644, March **2015**.
- [45] <http://vlfeat.org/matconvnet/>
- [46] F. Melgani and L. Bruzzone, "Classification of hyperspectral remote sensing images with support vector machines," in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 42, no. 8, pp. 1778-1790, Aug. **2004**.
- [47] J. Ham, Yangchi Chen, M. M. Crawford and J. Ghosh, "Investigation of the random forest framework for classification of hyperspectral data," in *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, no. 3, pp. 492-501, March **2005**.
- [48] A. Karpathy, "Convolutional neural networks for visual recognition." Course notes of Stanford CS class CS231n.
- [49] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A simple way to prevent neural networks from overfitting," *Journal of Machine Learning Research* 15, **2014**.
- [50] M. Nielsen, "Neural networks and deep learning online book." <http://neuralnetworksanddeeplearning.com>, 2017. Accessed: 09-02-**2017**.
- [51] Peter Sadowski "Notes on backpropagation" <https://www.ics.uci.edu/~pjsadows/notes.pdf>, **2016**.

ÖZGEÇMİŞ

Kimlik Bilgileri

Adı Soyadı : Mesut SALMAN
Doğum Yeri : ANKARA
Medeni Hali : Evli
E-posta : mesalman@aselsan.com.tr
Adresi :Emek Mah. Bosna Hersek Caddesi: 18/4 Çankaya / Ankara

Eğitim

Lise : İncesu Anadolu Lisesi (2007)
Lisans : Hacettepe Üniversitesi, Elektrik-Elektronik Mühendisliği (2013)

Yabancı Dil ve Düzeyi

İngilizce : İleri Düzey

İş Deneyimi

MİLSOFT, (2013-2014)
TUBİTAK BİLGEM İLTAREN, (2014-2016)
ASELSAN, (2016-Devam ediyor)

Deneyim Alanları

Elektronik Harp Sistemleri,
EO/IR Kendini Koruma ve Karşı Tedbir Sistemleri,
İşaret ve Görüntü İşleme
Algoritma Geliştirme ve Veri İşleme

Tezden Üretilmiş Projeler ve Bütçesi

-

Tezden Üretilmiş Yayınlar

M. Salman and S. E. Yüksel, "Hyperspectral data classification using deep convolutional neural networks," *2016 24th Signal Processing and Communication Application Conference (SIU)*, Zonguldak, Turkey, 2016, pp. 2129-2132.

M. Salman and S. E. Yüksel, " Fusion of Hyperspectral Image and LiDAR Data and Classification using Deep Convolutional Neural Networks *2018 26th Signal Processing and Communication Application Conference (SIU)*, İzmir, Turkey, 2018, (accepted 31.03.2018).

Tezden Üretilmiş Tebliğ ve/veya Poster Sunumu ile Katıldığı Toplantılar

SIU 2016 Zonguldak



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: 29/03/2018

Tez Başlığı / Konusu: Hiperspektral Ve LiDAR Verilerinin Öznitelik Ve Karar Seviyelerinde Tümlleştirilmesi Ve Derin Evrişimli Sinir Ağlarıyla Sınıflandırılması

Yukarıda başlığı/konusu gösterilen tez çalışmamın a) Kapak sayfası, b) Giriş, c) Ana bölümler d) Sonuç kısımlarından oluşan toplam 96 sayfalık kısmına ilişkin, 29/03/2018 tarihinde şahsım/tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 3 'dir.

Uygulanan filtrelemeler:

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

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü Tez Çalışması Orijinallik 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: Mesut Salman

Öğrenci No: N13123146

Anabilim Dalı: Elektrik ve Elektronik Mühendisliği

Programı: Elektrik ve Elektronik Mühendisliği - Yüksek Lisans

Statüsü: Y.Lisans Doktora Bütünleşik Dr.

29.03.2018

DANIŞMAN ONAYI

UYGUNDUR.

Yrd. Doç. Dr. Seniha Esen Yüksel

(Unvan, Ad Soyad, İmza)