

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

UZAKTAN ALGILANMIŞ VERİLERİN DERİN ÖĞRENME
YÖNTEMİYLE SINIFLANDIRILMASI

ELİF ÖZLEM YILMAZ
YÜKSEK LİSANS TEZİ
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI
JEODEZİ VE COĞRAFİ BİLGİ TEKNOLOJİLERİ PROGRAMI

GEBZE
2020

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

UZAKTAN ALGILANMIŞ VERİLERİN DERİN
ÖĞRENME YÖNTEMİYLE
SINIFLANDIRILMASI

ELİF ÖZLEM YILMAZ
YÜKSEK LİSANS TEZİ
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI
JEODEZİ VE COĞRAFİ BİLGİ TEKNOLOJİLERİ PROGRAMI

DANIŞMANI
PROF. DR. TAŞKIN KAVZOĞLU

GEBZE
2020

T.R.
GEBZE TECHNICAL UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

**CLASSIFICATION OF REMOTELY SENSED
DATA BY DEEP LEARNING METHOD**

ELİF ÖZLEM YILMAZ
A THESIS SUBMITTED FOR THE DEGREE OF
MASTER OF SCIENCE DEPARTMENT OF
GEOMATICS ENGINEERING
GEODESY AND GEOGRAPHICAL INFORMATION TECHNOLOGIES PROGRAMME

THESIS SUPERVISOR
PROF. DR. TAŞKIN KAVZOĞLU

GEBZE
2020



YÜKSEK LİSANS JÜRİ ONAY FORMU

GTÜ Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 17/07/2020 tarih ve 2020/34 sayılı kararıyla oluşturulan jüri tarafından 28/07/2020 tarihinde tez savunma sınavı yapılan Elif Özlem Yılmaz'ın tez çalışması Harita Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI) : Prof. Dr. Taşkın KAVZOĞLU

ÜYE

: Prof. Dr. Umut Güneş SEFERCİK

ÜYE

: Doç. Dr. İsmail ÇÖLKESEN

ÜYE

: Prof. Dr. Şinasi KAYA

ONAY

Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun
...../...../..... tarih ve/..... sayılı kararı.

İMZA/MÜHÜR

ÖZET

Teknolojinin gelişmesine paralel olarak uzaktan algılama uygulamaları sayesinde yeryüzünden daha fazla bilgi çıkarımı yapılabilmekte ve bu yolla elde edilen veriler insan faktörü minimize edilerek daha kısa sürede analiz edilebilmektedir. Bu noktada, makine öğrenmesi popüler bir veri işleme ve veri analizi olarak ön plana çıkmaktadır. Günümüzde özellikle makine öğrenmesinin bir alt kolu olarak ifade edilen derin öğrenme; ses tanıma, görüntü işleme, sınıflandırma ve obje tespiti gibi birçok alanda yaygın olarak kullanılmaktadır. Tez kapsamında uzaktan algılanmış hiperspektral görüntülerin derin öğrenme algoritmaları ile sınıflandırılması detaylı olarak incelenmiş ve analiz edilmiştir. İlk aşamada, görüntü sınıflandırması için farklı sayıda örneklerle elde edilen eğitim, test ve doğrulama veri setleri oluşturulmuştur. Ardından, bir derin öğrenme algoritması olan evrimsel sinir ağları ile 1, 2 ve 3 boyutlu eğitim modelleri oluşturulmuştur. Elde edilen modeller kullanılarak tematik haritalar üretilmiş ve bu haritaların doğrulukları karşılaştırılmıştır. Yapılan analizler sonucunda 3 boyutlu derin öğrenme modeli ile üretilen tematik haritaların doğruluklarının en yüksek değere sahip oldukları tespit edilmiştir. İkinci uygulamada, eğitim veri setleri farklı görüntü parçacıkları (15x15, 21x21 ve 27x27) kullanılarak oluşturulmuştur. Bu veri setleri, daha önceden oluşturulmuş 2 boyutlu ve 3 boyutlu derin öğrenme modelleri kullanılarak değerlendirilmiş ve tematik haritalar üretilmiştir. Eğitim veri seti boyutunun, tematik haritaların doğruluğunu önemli derecede etkilediği görülmüştür. Ayrıca, farklı sayıda örneklem içeren veri setleri ile üretilmiş haritaların doğruluklarının istatistiksel olarak anlamlılığını tespit etmek amacıyla McNemar testi uygulanmıştır. Tez kapsamında ele alınan son uygulamada ise bir derin öğrenme modelinin optimizasyonu ve ağ yapısını oluşturan parametreler incelenmiştir. Optimizasyon için kullanılan başarımlar iyileştirme algoritmaları kapsamında erken durdurma, düğüm seyreltme, standart başarımlar iyileştirme ve yığın normalizasyonu yaklaşımlarının modelin doğruluğuna olan etkisi incelenmiştir.

Anahtar Kelimeler: Uzaktan Algılama, Görüntü Sınıflandırma Algoritmaları, Derin Öğrenme, Evrimsel Sinir Ağı, Başarım İyileştirme Teknikleri.

SUMMARY

Parallel to the development of technology and thanks to remote sensing applications, it is possible to extract more information from the Earth and the big data obtained can be analyzed in a shorter time without the human interaction. At this point, machine learning comes forward as a popular data processing and analysis method. Today deep learning, which is defined as a subbranch of machine learning, is used for various fields such as voice recognition, image processing, classification and object detection. In the scope of this thesis, remotely sensed hyperspectral images were examined and analyzed by using deep learning algorithms. Firstly, data sets of training, test and validation with different number of samples were produced for image classification. Then, 1D, 2D and 3D training models were created by using convolutional neural network, which is a deep learning algorithm. Thematic maps were produced by using those models, and the accuracies of the maps were compared. After the analysis, it was determined that the thematic maps produced with 3D deep learning models have the highest accuracy. In the second application, training data sets were created by using different sizes of image patches (15x15, 21x21 and 27x27). Later, those data sets were evaluated by using previously created 2D and 3D deep learning models, and thematic maps were produced. As a result, it was observed using different sizes of image patches in the training data has an important effect on thematic accuracies of the maps. Also, McNemar test is applied to examine the statistical significance of the maps produced by using different datasets having different number of samples. In the last application covered in this thesis, optimization of the deep learning model and the parameters forming the network structure are examined. Out of all regularization algorithms used for optimization, the effect of early stopping, dropout, standard regularization and batch normalization approaches on the model accuracy are investigated.

Key Words: Remote Sensing, Image Classification Algorithms, Deep Learning, Convolutional Neural Networks, Regularization Methods.

TEŞEKKÜR

Öncelikle tez çalışmam boyunca oldukça kıymetli bilgi, birikim, tecrübe ve görüşleri ile bana yol gösterici ve destek olan, değerli tez danışman hocam sayın Prof. Dr. Taşkın KAVZOĞLU'na,

Tüm tez çalışmam boyunca faydalı fikirleri ile bana yardımcı olan sayın kıymetli hocalarım Prof. Dr. Halis SAKA, Doç. Dr. İsmail ÇÖLKESEN ve Arş. Gör. Hasan TONBUL'a,

Akademik hayata adım atmamda beni teşvik eden ve Uzaktan Algılama bilim dalını bana sevdiren sayın hocam Prof. Dr. Derya MAKTAV'a,

Bugünlere gelebilmemi sağlayan ve benim hayatımın bir dönüm noktası olan, sayın ilkokul öğretmenim Mustafa ÇOBAN'a,

Tez çalışmam boyunca göstermiş oldukları destekle yanımda olan Arş. Gör. Sinan BİRİNCİ, Arş. Gör. Furkan SOĞUKKUYU, Arş. Gör. Süleyman ŞİŞMAN ve diğer çalışma arkadaşlarıma, GTÜ Harita Mühendisliği Bölümü hocalarıma ve Bölüm Sekteri Canan KIRCI'ya,

Yakın ve değerli arkadaşlarım olan sevgili Beril VAROL, Büşra YALAUÇ, Hazal SÖNMEZ, Serdar GÜRER ve sevgili abim Yasin Özgür YILMAZ ve sevgili yengem Nazlı ÜN YILMAZ'a,

Ve hayallerimin peşinden koşmam da bana her türlü maddi ve manevi desteği veren ve bu hayattaki en büyük destekçilerim olan canım annem Huriye YILMAZ ve canım babam Kadir YILMAZ'a şükranlarımı ve saygılarımı sunuyorum.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	v
SUMMARY	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
SİMGELER ve KISALTMALAR DİZİNİ	xii
ŞEKİLLER DİZİNİ	xiii
TABLolar DİZİNİ	xvi
1. GİRİŞ	1
2. UZAKTAN ALGILANMADA SINIFLANDIRMA TEKNİKLERİ	5
2.1. Sınıflandırma Algoritmaları	5
2.2. Kontrollü Sınıflandırma Algoritmaları	9
2.2.1. En Kısa Uzaklık Sınıflandırma Algoritması	9
2.2.2. Paralelkenar Sınıflandırma Algoritması	10
2.2.3. Maksimum Olabilirlik Sınıflandırma Algoritması	11
2.2.4. Mahalanobis Uzaklığı Sınıflandırma Algoritması	12
2.2.5. Yapay Sinir Ağları Sınıflandırma Algoritması	13
2.2.6. Doğrusal Ayrıcı Sınıflandırma Algoritması	14
2.2.7. Destek Vektör Makineleri Sınıflandırma Algoritması	15
2.3. Kontrolsüz Sınıflandırma Algoritmaları	15
2.3.1. K-Ortalama Sınıflandırma Algoritması	15
2.3.2. ISODATA Sınıflandırma Algoritması	16
2.3.3. Bulanık Mantık Sınıflandırma Algoritması	16
2.4. Sınıflandırma Sonuçlarının Değerlendirilmesi	17
3. YAPAY SİNİR AĞLARI	22
3.1. Yapay Sinir Ağların Tarihsel Gelişimi	22
3.2. Yapay Sinir Ağları ve Genel Özellikleri	24
3.3. Yapay Sinir Ağ Çeşitleri	26
3.4. Yapay Sinir Ağlarının Uygulama Alanları	27
3.5. Uzaktan Algılamada Yapay Sinir Ağları	29

3.5.1. Arazi Örtüsü/Kullanımı Sınıflandırılması ve Değişim Analizi	30
Uygulamaları	
3.5.2. Karışık Piksel Uygulamaları	32
3.5.3. Obje Tespiti Uygulamaları	34
4. DERİN ÖĞRENME	36
4.1. Yapay Sinir Ağlarından Derin Öğrenmeye Tarihsel Bakış	37
4.2. Derin Öğrenme Yaklaşımları	37
4.3. Derin Öğrenme Modelleri	38
4.3.1. Gürültü Giderici Otomatik Kodlayıcı	38
4.3.2. Tekrarlayan Sinir Ağları	39
4.3.3. Derin İnanç Ağları	40
4.3.4. Uzun Kısa Vadeli Bellek	41
4.3.5. Evrimsel Sinir Ağları	42
4.4. Evrimsel Sinir Ağı ve Mimarisi	43
4.4.1. Evrimsel Katman ve Çeşitleri	44
4.4.1.1. Bir Boyutlu Evrimsel Katman	44
4.4.1.2. İki Boyutlu Evrimsel Katman	45
4.4.1.3. Üç Boyutlu Evrimsel Katman	46
4.4.2. Ortaklama Katmanı	46
4.4.3. Yığın Normalizasyon Katmanı	47
4.4.4. Düzleştirme Katmanı	48
4.4.5. Seyreltme Katmanı	48
4.4.6. Aktivasyon Fonksiyonları	49
4.4.7. Maliyet Fonksiyonları	50
4.4.8. Rastgele Gradyan İnişi Fonksiyonu	51
4.4.9. Öğrenme Hızı	51
4.5. Aşırı ve Yetersiz Öğrenme	52
4.6. Başarım İyileştirme ve Optimizasyon	53
4.7. Derin Öğrenmede Kullanılan Kütüphaneler	56
4.8. Uzaktan Algılamada Derin Öğrenme	57
4.8.1. Ön İşleme Uygulamalarında Derin Öğrenme	58
4.8.2. Görüntü Sınıflandırma Uygulamalarında Derin Öğrenme	59
4.8.3. Obje Tespiti/Tanıma Uygulamalarında Derin Öğrenme	61

4.8.4. Görüntü Yorumlama Uygulamalarında Derin Öğrenme	62
5. UYGULAMA	64
5.1. Çalışma Alanı ve Veri Seti	64
5.2. Eğitim, Test ve Doğrulama Veri Setinin Oluşturulması	67
5.3. Farklı Boyuttaki ESA'ların Performans Analizi	68
5.3.1. Bir Boyutlu ESA	68
5.3.1.1. Bir Boyutlu Derin Öğrenme Modelinin Performans Analizi	68
5.3.1.2. Bir Boyutlu Derin Öğrenme Modelinin Sınıflandırma Sonuçları ve Doğruluk değerlendirilmesi	70
5.3.2. İki Boyutlu ESA	73
5.3.2.1. İki Boyutlu Derin Öğrenme Modelinin Performans Analizi	73
5.3.2.2. İki Boyutlu Derin Öğrenme Modelinin Sınıflandırma Sonuçları ve Doğruluk değerlendirilmesi	74
5.3.3. Üç Boyutlu ESA	77
5.3.3.1. Üç Boyutlu Derin Öğrenme Modelinin Performans Analizi	77
5.3.3.2. Üç Boyutlu Derin Öğrenme Modelinin Sınıflandırma Sonuçları ve Doğruluk değerlendirilmesi	78
5.4. Farklı Görüntü Parçacıklarının ESA Performansına Etkisi	81
5.4.1. Görüntü Parçacık Boyutunun Belirlenmesi	81
5.4.2. Görüntü Parçacık Boyutunun 2B ESA Performansına Etkisi ve Doğruluk Analizi	82
5.4.3. Görüntü Parçacık Boyutunun 3B ESA Performansına Etkisi ve Doğruluk Analizi	91
5.4.4. Farklı Görüntü Parçacıklarının ve Farklı Sayıda Örneklem Kullanılmasının Karşılaştırılması	98
5.5. Başarım İyileştirme Tekniklerinin ESA'lara Uygulanması	103
5.5.1. Başarım İyileştirme Teknikleri Kullanılmadan Oluşturulmuş ESA ve Sonucu	103
5.5.2. Erken Durdurma Tekniğinin Uygulanması ve Sonucu	107
5.5.3. Düğüm Seyreletme Tekniğinin Uygulanması ve Sonucu	111

5.5.4. Standart Başarım İyileştirme Parametresinin Uygulanması ve Sonucu	115
5.5.5. Yığın Normalizasyon Tekniğinin Uygulanması ve Sonucu	119
5.5.6. Başarım İyileştirme Tekniklerinin Birlikte Kullanılarak Uygulanması ve Sonucu	123
5.5.7. Başarım İyileştirme Tekniklerinin Karşılaştırılması	127
6. SONUÇLAR ve TARTIŞMA	129
KAYNAKLAR	132
ÖZGEÇMİŞ	149

SİMGELER ve KISALTMALAR DİZİNİ

<u>Simgeler ve</u>	<u>Açıklamalar</u>
<u>Kısaltmalar</u>	
χ^2	: Ki-kare
B	: Boyut
CNTK	: Microsoft Cognitive Toolkit
CPU	: Central Processing Unit
DN	: Doğru Negatif
DP	: Doğru Pozitif
ESA	: Evrişimsel Sinir Ağı
GTÜ	: Gebze Teknik Üniversitesi
LSTM	: Long-Short time memory (uzun kısa süreli bellek)
RAM	: Random Access Memory
RTF	: Radyal Temelli Fonksiyon
SN	: Saniye
TM	: Trademark
UHD	: Ultra Yüksek Çözünürlük
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağı

ŞEKİLLER DİZİNİ

<u>Sekil No:</u>	<u>Sayfa</u>
2.1: a) Kontrollü sınıflandırma. b) Kontrolsüz sınıflandırma.	6
2.2: Nesne tabanlı sınıflandırmanın aşamaları.	8
2.3: Kontrollü ve kontrolsüz sınıflandırma algoritmaları.	8
2.4: En kısa uzaklık sınıflandırma algoritmasının uygulaması.	9
2.5: Paralelkenar sınıflandırma algoritmasının uygulaması	10
2.6: Maksimum olabilirlik algoritması uygulaması.	11
2.7: Hata matrisinin matematiksel gösterimi.	17
3.1: Çok katmanlı algılayıcı.	23
3.2: Biyolojik sinir hücresi.	24
3.3: Yapay sinir hücresi	25
4.1: Derin öğrenme, makine öğrenmesi ve yapay zekâ arasındaki ilişki.	36
4.2: Evrimsel filtrenin uygulanması.	44
4.3: Ortaklama katmanının uygulanması.	47
4.4: Düzleştirme katmanının 2 boyutlu veriye uygulanması ve tek boyutlu vektör yapıda verinin oluşturulması.	48
4.5: Seyreltme katmanının uygulanması. a) Seyreltme katmanı kullanılmadan oluşturulmuş sinir ağ modeli. b) Seyreltme katmanı kullanılarak oluşturulmuş sinir ağ modeli.	49
4.6: Bazı aktivasyon fonksiyonlarının grafiksel gösterimi ve özellikleri.	50
4.7: Eğitim esnasında oluşturulan optimizasyon algoritması üzerinden öğrenme hızının gösterimi. a) Büyük öğrenme hızı. b) Küçük öğrenme hızı.	52
4.8: a) Yetersiz öğrenme. b) İdeal öğrenme. c) Aşırı öğrenme.	53
4.9: Derin öğrenme tekniği ile uydu görüntüsünün sınıflandırılması.	60
4.10: Görüntü yorumlamasının aşamaları.	63
5.1: Pavia Üniversitesi çalışma alanı (Bant 50-Bant 27-Bant 17 sıralaması ile gerçek renk).	64
5.2: Pavia Üniversitesi yer doğrulama tematik haritası.	65
5.3: 1 Boyutlu ESA ile farklı eğitim verileriyle tematik haritalar. a) 50 örneklem. b) 100 örneklem. c) 200 örneklem. d) 400 örneklem.	71

5.4:	2 Boyutlu ESA ile farklı eğitim verileriyle tematik haritalar. a) 50 örneklem. b) 100 örneklem. c) 200 örneklem. d) 400 örneklem.	75
5.5:	3 Boyutlu ESA ile farklı eğitim verileriyle tematik haritalar. a) 50 örneklem. b) 100 örneklem. c) 200 örneklem. d) 400 örneklem.	79
5.6:	15x15 görüntü parçacıkları kullanılarak 2B ESA ile farklı eğitim verileriyle tematik haritalar. a) 50 örneklem. b) 100 örneklem. c) 200 örneklem. d) 400 örneklem.	83
5.7:	21x21 görüntü parçacıkları kullanılarak 2B ESA ile farklı eğitim verileriyle tematik haritalar. a) 50 örneklem. b) 100 örneklem. c) 200 örneklem. d) 400 örneklem.	86
5.8:	27x27 görüntü parçacıkları kullanılarak 2B ESA ile farklı eğitim verileriyle tematik haritalar. a) 50 örneklem. b) 100 örneklem. c) 200 örneklem. d) 400 örneklem.	89
5.9:	15x15 görüntü parçacıkları kullanılarak 3B ESA ile farklı eğitim verileriyle tematik haritalar. a) 50 örneklem. b) 100 örneklem. c) 200 örneklem. d) 400 örneklem.	92
5.10:	21x21 görüntü parçacıkları kullanılarak 3B ESA ile farklı eğitim verileriyle tematik haritalar. a) 50 örneklem. b) 100 örneklem. c) 200 örneklem. d) 400 örneklem.	94
5.11:	27x27 görüntü parçacıkları kullanılarak 3B ESA ile farklı eğitim verileriyle tematik haritalar. a) 50 örneklem. b) 100 örneklem. c) 200 örneklem. d) 400 örneklem.	96
5.12:	Farklı görüntü parçacıklarının kullanıldığı derin öğrenme modellerinin genel doğruluklarının farklı veri setleri ile olan ilişkisi.	100
5.13:	Başarım iyileştirme teknikleri kullanılmadan oluşturulmuş ESA'nın doğruluk/maliyet grafiği.	105
5.14:	Başarım iyileştirme teknikleri kullanılmadan oluşturulmuş 3 boyutlu ESA ile üretilmiş tematik harita.	106
5.15:	Erken durdurma tekniği kullanılarak oluşturulmuş ESA'nın doğruluk/maliyet grafiği.	109
5.16:	Erken durdurma tekniği kullanılarak oluşturulmuş 3 boyutlu ESA ile üretilmiş tematik harita.	110

5.17:	Düğüm seyreltme tekniği kullanılarak oluşturulmuş ESA'nın doğruluk/maliyet grafiği.	113
5.18:	Düğüm seyreltme tekniği kullanılarak oluşturulmuş 3 boyutlu ESA ile üretilmiş tematik harita.	114
5.19:	Standart başarımla iyileştirme parametresi kullanılarak oluşturulmuş ESA'nın doğruluk/maliyet grafiği.	117
5.20:	Standart başarımla iyileştirme parametresi kullanılarak oluşturulmuş 3 boyutlu ESA ile üretilmiş tematik harita.	118
5.21:	Yığın normalizasyon tekniği kullanılarak oluşturulmuş ESA'nın doğruluk/maliyet grafiği	121
5.22:	Yığın normalizasyon tekniği kullanılarak oluşturulmuş 3 boyutlu ESA ile üretilmiş tematik harita.	122
5.23:	Başarımla iyileştirme tekniklerinin birlikte kullanılarak oluşturulmuş ESA'nın doğruluk/maliyet grafiği	125
5.24:	Başarımla iyileştirme tekniklerinin birlikte kullanılarak oluşturulmuş 3 boyutlu ESA ile üretilmiş tematik harita.	126

TABLÖLAR DİZİNİ

<u>Tablo No:</u>	<u>Sayfa</u>
2.1: Kontrollü ve kontrolsüz sınıflandırmanın avantajlar ve dezavantajlar.	7
2.2: İki sınıflı tanımlanmış bir hata matrisi.	19
2.3: Diğer doğruluk ölçütleri.	20
3.1: Yapay sinir ağların avantajları ve dezavantajları.	25
5.1: Arazi referans verisi örneklem sayısı.	66
5.2: Arazi referans verisi örneklem sayısı, eğitim, test ve doğrulama verisi.	67
5.3: Eğitim verisi örneklem sayıları.	68
5.4: Model: "1 Boyutlu ESA".	69
5.5: 1 Boyutlu ESA için arazi sınıflarının F-skör doğruluk değerleri.	72
5.6: Model: "2 Boyutlu ESA".	74
5.7: 2 Boyutlu ESA için arazi sınıflarının F-skör doğruluk değerleri.	76
5.8: Model: "3 Boyutlu ESA".	78
5.9: 3 Boyutlu ESA için arazi sınıflarının F-skör doğruluk değerleri.	80
5.10: 15x15 görüntü parçacıkları kullanılarak eğitilmiş 2 Boyutlu ESA için arazi sınıflarının F-skör doğruluk değerleri.	84
5.11: 21x21 görüntü parçacıkları kullanılarak eğitilmiş 2 Boyutlu ESA için arazi sınıflarının F-skör doğruluk değerleri.	87
5.12: 27x27 görüntü parçacıkları kullanılarak eğitilmiş 2 Boyutlu ESA için arazi sınıflarının F-skör doğruluk değerleri.	90
5.13: 15x15 görüntü parçacıkları kullanılarak eğitilmiş 3 Boyutlu ESA için arazi sınıflarının F-skör doğruluk değerleri.	93
5.14: 21x21 görüntü parçacıkları kullanılarak eğitilmiş 3 Boyutlu ESA için arazi sınıflarının F-skör doğruluk değerleri.	95
5.15: 27x27 görüntü parçacıkları kullanılarak eğitilmiş 3 Boyutlu ESA için arazi sınıflarının F-skör doğruluk değerleri.	97
5.16: 15x15 görüntü parçacıkları kullanılarak eğitilmiş 2 ve 3 Boyutlu ESA'ların genel ve Kappa doğrulukları.	98
5.17: 21x21 görüntü parçacıkları kullanılarak eğitilmiş 2 ve 3 Boyutlu ESA'ların genel ve Kappa doğrulukları.	99

5.18:	27x27 görüntü parçacıkları kullanılarak eğitilmiş 2 ve 3 Boyutlu ESA'ların genel ve Kappa doğrulukları.	99
5.19:	2 Boyutlu ESA'lara uygulanmış McNemar testi.	101
5.20:	3 Boyutlu ESA'lara uygulanmış McNemar testi.	102
5.21:	Model: "Başarım iyileştirme teknikleri kullanılmadan oluşturulmuş ESA"	104
5.22:	Arazi sınıflarının F-skor doğruluk değerleri.	107
5.23:	Model: "Erken durdurma tekniği kullanılarak oluşturulmuş ESA"	108
5.24:	Arazi sınıflarının F-skor doğruluk değerleri.	111
5.25:	Model: "Düğüm seyreltme tekniği kullanılarak oluşturulmuş ESA".	112
5.26:	Arazi sınıflarının F-skor doğruluk değerleri.	115
5.27:	Model: "Standart başarım iyileştirme parametresi kullanılarak oluşturulmuş ESA.	116
5.28:	Arazi sınıflarının F-skor doğruluk değerleri.	119
5.29:	Model: "Yığın normalizasyon tekniği kullanılarak oluşturulmuş ESA".	120
5.30:	Arazi sınıflarının F-skor doğruluk değerleri .	123
5.31:	Model: "Başarım iyileştirme tekniklerinin birlikte kullanılarak oluşturulmuş ESA".	124
5.32:	Arazi sınıflarının F-skor doğruluk değerleri.	127

1. GİRİŞ

Günümüzün popüler araştırma konularından biri olan büyük veri kavramı birçok alanda yaygın olarak kullanılmaya başlanılmıştır. Teknolojinin gelişmesiyle çok miktarda uzaktan algılama verileri elde edilmektedir. Uzaktan algılama, herhangi bir fiziksel temas olmaksızın Dünya gözleminde kullanılan bilgi kaynaklarından biri olduğu için bu bilim dalıyla ilgili hem verilerin nasıl üretileceği/toplanacağı hem de üretilen/toplanan verilerin nasıl analiz edileceği üzerine birçok çalışma yapılmaktadır. Yıllar geçtikçe, Dünya'yı veya çevresindeki gezegenleri gözleyen sensörler veya uydular artmaktadır, böylelikle uzaktan algılanarak toplanan veriler de doğrusal olarak çoğalmaktadır [Chi et al., 2016]. Uzaktan algılama ile elde edilen bu veriler, büyük veri özelliklerini göstermektedir. Büyük veri kavramı ile ilgili, ilk girişim 2012 yılında ABD tarafından dünya gözlem sistemlerinden elde edilen büyük veri kavramı ortaya atılmasıyla başlatılmıştır ve konuyla ilgili NASA gibi birçok bilim topluluğu tarafından çalışmalar yapmaya başlamıştır. Ayrıca bu konuyla ilgili çeşitli konferanslar düzenlenmiştir [Liu et al., 2018]. Günümüzde, bu kavram üzerinde çeşitli bilimsel veya ticari çalışmalar halen gerçekleştirilmektedir.

Uzaktan algılamada büyük verileri yönetmek, kullanmak ve analiz etmek için çeşitli yöntem ve uygulamalar geliştirilmeye başlanmıştır. Uzaktan algılamada kullanılan veriler çok kaynaklı, farklı ölçekte, doğrusal ve dinamik olmayan özellikler gibi çok fazla özelliklere sahiptir. Çeşitli çalışmalarda kullanılan uzaktan algılanmış veri setleri boyut olarak büyük olmakla beraber karmaşık bir yapıya da sahiptir. Bu nedenle, geleneksel yöntemlerle bu veri setlerini, çeşitli uygulamalarda kullanmak oldukça zordur. Ayrıca, bu verilerin analizinde, gerçek zamanlı olarak yüksek bir verimlilik ve doğruluk üretebilmek için makine öğrenmesine dayalı karmaşık algoritmalara ihtiyaç duyulmaktadır. Çünkü bu veri setlerinin işlenmesi için kullanılan geleneksel yöntemlerde çeşitli kısıtlamalar mevcuttur [Chebbi et al., 2019]. Bu kısıtlamalar nedeniyle, birçok yapay zekâ çalışmalarında makine öğrenmesi aktif olarak rol oynamaya başlamıştır. Çünkü bu alanda yapılan uygulamalarda makine öğrenimi yaklaşımının kullanımı insan faktörü içermemektedir. Böylece insan bağlı hatalar elimine edilebilir [Ball et al., 2018].

Makine öğrenmesi, çok çeşitli karmaşık aşamaları içeren ve biyolojik öğrenme sürecine dayanan yapay zekanın bir alt bölümüdür. Makine öğrenmesi yaklaşımı,

makine tarafından okunabilen verilerden öğrenmek için çeşitli algoritmaların tasarlanması ile üretilir. Bu tabanlı yöntemlerin modelleme yetenekleri nedeniyle bilim ve mühendislikte birçok uygulama alanı mevcuttur. Bu yöntemin uzaktan algılama problemleri çözüme konusunda etkili bir yaklaşım olacağı vurgulanmıştır [Lary et al., 2016]. Makine öğrenmesinin uzaktan algılama alanında ilk kullanımı 1990'lı yılların sonlarında arazi örtüsü tahmini ve deniz yüzeyindeki petrol sızıntılarının tespiti amacıyla kullanılmıştır. 2000 yılının başlarında ise makine öğrenmesi ile uzaktan algılanmış görüntülerle ilgili sorunlara dikkat çekilmiştir [Giannopoulos, Aidini et al., 2019].

Gelişen teknoloji sayesinde, makine öğrenmesinin bir alt kolu olan derin öğrenme kavramı da ortaya çıkmıştır. Bilgisayarlarda artan işlem gücü ve işlemcilerindeki ilerlemelerle derin öğrenme metodu yaygın olarak kullanılmaya başlanılmıştır. Derin öğrenme, görüntü sınıflandırması, obje tespiti, ses tanıma gibi uygulamalarda analitik çözüm sağladığı için özellikle, günümüzde yapılan birçok çalışmalarda aktif bir rol oynamaktadır [Kussul et al., 2017]. Derin öğrenme algoritmasında, girdi ve etiketli veriler arasındaki karmaşık ilişkilerle başa çıkmak için derin ağ mimarileri kullanılmaktadır. Özellikle uzaktan algılamada kullanılan radar, multi-spektral ve hiperspektral görüntülerde, geleneksel yöntemlere göre daha derin öğrenme metotları daha iyi performans göstermektedir oynamaktadır [Kussul et al., 2017]. Derin öğrenme algoritması, sinir ağlarını içeren ve çeşitli katmanları olan bir mimari yapıdır. Derin öğrenme mimarisindeki bu katmanlar da arttıkça derinlik kavramı ortaya çıkmıştır. Kısacası, çalışma algoritması insan beyninden esinlenerek oluşturulmuştur. Uzaktan algılamada derin öğrenme metodu görüntü birleştirme, görüntü sınıflandırma, görüntü ön işleminde, obje tespiti, arazi kullanımı ve arazi örtüsü haritası üretme, görüntü segmentasyonu, obje tabanlı görüntü analizi ve doğruluk analizi gibi birçok uygulama alanında kullanılmaktadır. [Ma et al., 2019].

Uzaktan algılamada uydu görüntüsü sınıflandırma prosesinin en büyük amacı, sıklıkla güncellenen yeryüzünün arazi kullanımı ve örtüsü bilgileri, şehir/kırsal gelişimini inceleme, doğal kaynaklar, bölgede gerçekleşmiş doğal afetler öncesi/sonrası gibi bilgiler dahil olmak üzere birçok sosyo-ekonomik ve çevresel faaliyetler için bu bilgilerin toplanmasıdır [Li et al., 2014]. Bu bilgilerin elde edilebilmesi için günümüzde kadar birçok farklı yöntemle uzaktan algılama görüntüleri sınıflandırma işlemine tabi tutulmuştur. Sınıflandırma algoritmaları, yapılacak uygulamanın amacına göre seçilmektedir. Sınıflandırma işlemlerinde

geleneksel yöntemler bazı konularda yetersiz kaldığı için bu uygulamalarda makine öğrenmesi algoritmaları kullanılmaya başlanılmıştır. Çünkü makine öğrenimi, uzaktan algılanmış görüntülerin etkili ve verimli bir şekilde sınıflandırma potansiyeli taşımaktadır. Sınıflandırma işlemi için en yaygın olarak kullanılan makine öğrenme yaklaşımları, destek vektör makineleri, rastgele orman ve yapay sinir ağları örnek olarak gösterilebilir. Bu algoritmalar arasında seçim yapılırken, eğitim veri seti gereksinimleri, kullanıcı tanımlı parametre seçimi, optimizasyon ve algoritma içindeki hesaplama maliyetlerine dikkat edilmelidir [Maxwell et al., 2018]. Büyük uzaktan algılama verilerinin analizi için görüntü sınıflandırmasında derin öğrenme yaklaşımları kullanılmaya başlanılmıştır. Çünkü yüksek boyutlu görüntü verilerini, nispeten küçük miktarda etiketlenmiş örnekleme sınıflandırma işlemini gerçekleştirmek mümkün kılınmıştır. Son yıllarda yeni derin öğrenme modellerinin artması, uzaktan algılanmış görüntüler için sınıflandırma yaklaşımlarının geliştirilmesine olanak tanınmıştır [Li et al., 2018].

Bu tez çalışması kapsamında hiperspektral görüntü kullanılarak, derin öğrenme methodology ile arazi kullanımı ve örtüsünün sınıflandırması gerçekleştirilmiştir. Tezin ilk bölümde uzaktan algılamada kullanılan geleneksel ve makine öğrenmesini içeren sınıflandırma tekniklerinin literatür taraması yapılmıştır. Ardından yapay sinir ağlarını kavramının tarihsel gelişiminden, genel özelliklerinden, ağ çeşitlerinden ve uygulama alanlarından bahsedilmiştir. Ayrıca bu bölümde yapay sinir ağlarının uzaktan algılama olan kullanımı incelenmiştir. Bu bölümden sonra ise derin öğrenme algoritmasının temeli incelenmiştir. İlk olarak derin öğrenme ile ilgili bir literatür taraması yapılmış ve ardından öğrenme yaklaşımları ve öğrenme modellerinden bahsedilmiştir. Bunlara müteakiben de evrimsel sinir ağının mimarisi ve özellikleri araştırılmıştır. Ayrıca bir derin öğrenme modelinde ortaya çıkabilecek aşırı ve yetersiz öğrenme durumu irdelenmiştir ve bu durumu çözmek için kullanılan optimizasyon ve başarımlar iyileştirme tekniklerinden bahsedilmiştir. İlâveten derin öğrenmede kullanılan kütüphanelerden en popüler olanları da bu başlık altına eklenmiştir. Son olarak da uzaktan algılamada derin öğrenme örnekleri ve uygulama alanları incelenmiştir. Tezin uygulama bölümünde ise öncelikle farklı boyutlardaki evrimsel sinir ağları kullanılarak hiperspektral görüntü arazi kullanımı ve örtüsü sınıflandırılması yapılmıştır. Bu görüntü sınıflandırma uygulamasında farklı sayıda örneklemler kullanılarak sınıflandırmaya olan etkileri üretilen tematik haritalar üzerinde incelenmiştir. Diğer bir uygulamada ise eğitim aşamasında oluşturulan farklı sayıda örneklemlerle oluşturulmuş veri setleri

iin farklı boyutlu grnt paracıklarının, grnt sınıflandırmasına olan etkisi 2 ve 3 boyutlu evriřimsel sinir aęlarında ayrı ayrı olacak řekilde incelenmiřtir. Uygulamanın son blmde, bir derin ęrenme aęının optimizasyonu iin bařarım iyileřtirme tekniklerinin, grnt sınıflandırmasına olan etkisi ayrı ayrı incelenmiřtir.

2. UZAKTAN ALGILAMADA SINIFLANDIRMA TEKNİKLERİ

Uzaktan algılanmış görüntüleri, fiziksel olarak temas edilmeden algılanan, yapay veya doğal oluşumları içeren yeryüzünün bir temsili olarak tanımlanabilir. Bu görüntüler, doğa olaylarını izleme, kentsel yapılaşmayı takip etme, yer kaynaklarını inceleme veya askeri amaçlı olarak kullanılabilir. Yeryüzündeki nesnelerin elektromanyetik spektrumda yer alan kendi özelliklerine göre değişebilen spektral yansıtımları mevcuttur. Bu yansıtım değerleri uygu görüntülerinde kayıt altına alınmaktadır. Bu nedenle, uydu görüntüleri içerik olarak çok zengindir. Bu verilerin değerlendirilebilmesi için gelişmiş tekniklere ihtiyaç duyulmaktadır. Görüntü sınıflandırması, bu önemli bilgilerin çıkarılmasında ve analizinde yaygın olarak kullanılan bir yöntemdir [Dhingra and Kumar, 2019].

Uydu görüntüleri sınıflandırılması, aynı özelliklerine sahip piksellerin gruplandırılması yani bu piksellerin anlamlı olacak şekilde kategorize edilmesiyle gerçekleştirilmektedir [Abburu and Babu Golla, 2015]. Sınıflandırma sonucunda arazi kullanımını ve örtüsünü içeren tematik bir harita üretilir. Arazi örtüsü, bölgeye ait sulak alanları, ormanları, tarım alanlarını gibi yeryüzünün fiziksel özelliklerini gösterirken, arazi kullanımı ise o bölgenin insanlar tarafından arazinin nasıl kullanıldığını ve insan faaliyetlerinin yeryüzündeki gelişimini göstermektedir. Arazi kullanımına örnek olarak, kentsel ve sanayi bölgeleri örnek olarak gösterilebilir [Kavzoglu et al., 2019].


2.1. Sınıflandırma Algoritmaları

Sınıflandırma işlemlerinde kontrollü (denetimli) ve kontrolsüz (denetimsiz) olmak üzere iki farklı yaklaşım mevcuttur. Kontrollü sınıflandırmada, sınıflandırma öncesi eğitim verileri toplanır ve bu veriler arazi sınıfına göre kategorize edilir. Ardından bu veriler kullanılarak sınıflandırma işlemi gerçekleştirilir [Abburu and Babu Golla, 2015]. Kontrollü sınıflandırmada her arazi sınıfına ait piksel değerleri analizi edildikten sonra o arazi sınıfı için istatistiksel bir alt yapı oluşturulur. Uzaktan algılanmış görüntünün tamamında pikseller hangi arazi sınıfının istatistiksel özelliklerini gösterir veya en yakın hangisine ise o arazi sınıfına atanır. Sınıflandırma

Tablo 2.1: Kontrollü ve kontrolsüz sınıflandırmanın avantajlar ve dezavantajlar.


Yöntem	Avantajlar	Dezavantajlar
Kontrolsüz Sınıflandırma	Öncül bilgiye ihtiyaç yoktur	Spektral sınıflar, görüntüdeki her sınıfı ifade etmeyebilir
	İnsan hatası elimine edilir	Görüntüdeki verilerin mekânsal ilişkileri kullanılmaz
	Özgün spektral sınıflar oluşturulabilir	Spektral sınıfların yorumlanması zaman alabilir
	Uygulaması kolaydır	Düşük doğruluk verir
Kontrollü Sınıflandırma	Kullanıcının kontrolü altındadır	Veri toplamak zaman alıcıdır
	Eğitim verileri tekrardan kullanılabilir	Arazi sınıfları, belirlenen spektral sınıflarla eşleşmeyebilir
	Arazi sınıfları, yeryüzü objelerinin özelliklerini taşımaktadır	Eğitim ve test veri seti oluşturmak zaman alabilir
	Yüksek doğruluk verir	-

Kontrollü ve kontrolsüz sınıflandırma için piksel veya nesne tabanlı sınıflandırmada algoritmaları kullanılmaktadır. Nesne tabanlı sınıflandırma algoritmasında ilk uygulamalarda parsel tabanlı sınıflandırmalar gerçekleştirilmiştir. Parsel tabanlı sınıflandırma, piksel tabanlı sınıflandırmaya alternatif olarak geliştirilmiştir. Bu yöntemde alansal objelerin şekilsel sınırları hakkında genel bilgilere ihtiyaç duyurulur. Nesne tabanlı sınıflandırmanın temel prensibi ise görüntüdeki pikselleri gruplandırarak segmentlere (komşu piksel gruplarına) ayırır. Görüntü segmentleri, yeryüzü objesinin şekline, dokusuna, komşuluk ilişkilerine, spektral özelliklerine veya geometrik konumuna bağlı olarak oluşturulabilir [Tonbul ve Kavzoğlu, 2017]. Ardından her arazi sınıfı için bir özellik uzayı oluşturulur. Sonraki adımda görüntü içinden test ve eğitim veri setleri belirlenir. En son kısmında oluşturulan bu veri seti kullanılarak tematik harita üretilir ve sınıflandırma aşaması tamamlanır [Çölkesen, 2015]. Nesne tabanlı sınıflandırma işlem adımları Şekil 2.2’de adım adım gösterilmektedir.



Şekil 2.2: Nesne tabanlı sınıflandırmanın aşamaları.

Şekil 2.3'te sınıflandırma algoritmalarının bazılarını gösteren bir şekil verilmiştir. Ek olarak, uydu görüntülerinin sınıflandırılması için yöntemler; performansı veri dağılımına bağlı olan istatistiksel yöntemler ve makine öğrenme yöntemleri olarak da incelenmektedir [Borra et al., 2019]. İstatistiksel yöntemler, anlamlı sınıflandırma çıktıları için arazi sınıfları arasındaki ilişkiyi matematiksel teorilere dayandırmaktadır. Bu sınıflandırma algoritmaları, az öznitelik içeren küçük boyutlu veri kümelerine uygulanırken, büyük hacimli uydu görüntüleri için uygun değildir. İstatistiksel sınıflandırma yöntemlerine örnek; Maksimum Olabilirlik, En Kısa Mesafe ve Mahalanobis Uzaklığı gösterilebilir. Makine öğrenmeleri için ise Yapay Sinir Ağları ve destek vektör makineleri örnek olarak verilebilir. Makine öğrenmeleri, istatistiksel metotlara göre daha iyi performans gösterdiği için son yıllarda yaygın olarak kullanılmaktadır [Dey et al., 2018].




Şekil 2.3: Kontrollü ve kontrolsüz sınıflandırma algoritmaları.

2.2. Kontrollü Sınıflandırma Algoritmaları

2.2.1. En Kısa Uzaklık Sınıflandırma Algoritması

En kısa uzaklık sınıflandırma algoritmasında her arazi sınıfı için pikseller seçilir ve bu eğitim verisinin parlaklık değerleri ve ortalama vektörü kullanılarak spektral sınıfların özellikleri belirlenir. Sınıflandırma aşamasında, sınıfı bilinmeyen piksellerden her arazi sınıfı için ortalama vektöre olan Öklid mesafesi hesaplanır. Eğer arazi sınıflarına ait bir eşik belirlenmediyse tüm kalan atanmamış pikseller en yakın arazi sınıfına yerleştirilir. Bunların yanında belirlenen kriterlere uygun olmayan pikseller belirli bir mesafe sınırı tanımlanır, bu sınır aşılsa diğer sınıfa atanır ya da tematik haritada sınıflandırılmadan gösterilir. [Al-Ahmadi and Hames, 2009].




Şekil 2.4: En kısa uzaklık sınıflandırma algoritmasının uygulaması.

Şekil 2.4'te en kısa uzaklık algoritmasına ait örnek bir grafik gösterilmiştir. Her arazi sınıfı için belirlenen ortalama vektöre göre sınıflandırma yapılmıştır. Atanmamış olan piksellerin, ortalama vektör olan minimum uzaklıkları hesaplanır ve en yakın sınıfa o pikseller atanır. Bu sınıflandırma yöntemiyle yapılan bir çalışmada, 1972 ve 1998 yılında alınmış Landsat görüntü setleri kullanılmıştır ve diğer sınıflandırma yöntemleri ile karşılaştırılmıştır [Gonçalves et al., 2009]. Bu yöntem en basit ve ilkel yöntemlerden biri olup bilimsel çalışmalarda pek kullanılmaz.

2.2.2. Paralelkenar Sınıflandırma Algoritması

Paralelkenar sınıflandırması çok bantlı verileri sınıflandırmak için basit seviye bir karar kuralı uygular. Karar sınırları, uzaktan algılanmış görüntünün veri uzayında bant sayısına göre bir kutu ile oluşturulur. Bu kutunun sınırları, seçilen her arazi sınıfının ortalamasından standart sapma eşiğine göre belirlenir. Eğer sınıflandırılmamış bir piksel değeri, sınıflandırılan tüm bantlar için düşük eşiğin üstünde ve yüksek eşiğin altındaysa, bu arazi sınıfa atanır. Piksel değeri düşük çıkarsa, piksel eşleşen başka bir sınıfa atanır. Bu kutucukların içine girmeyen pikseller sınıflandırılmamış olarak gösterilir [Xiang et al., 2005]. Şekil 2.5'te Paralelkenar Sınıflandırılması gösterilmiştir. Eğitim veri seti istatistiksel yöntemler kullanılarak gruplandırılmış ve arazi sınıfları oluşturulmuştur. Kalan diğer piksellerde bu sınıflara atanarak sınıflandırma işlemi tamamlanır.




Şekil 2.5: Paralelkenar sınıflandırma algoritmasının uygulaması.

Lü and Tang [2012] tarafından yapılan bir çalışmada, kivi ağaçlarının sağlık durumunu incelemek için hiperspektral görüntüler üzerinden Paralelkenar Sınıflandırma Algoritması kullanılarak %85,5'lik bir doğruluk ile çalışma yapılmıştır. Vanitha et al., [2013] yaptığı başka bir çalışmada ise Sentetik Açıklı Radar görüntüleri kullanılarak buz haritası oluşturulmuştur. Ön işlem olarak, radar görüntüsüne Gram-Schmidt spektral keskinleştirme uygulanmıştır. Bu çalışmada hem kontrollü hem de

kontROLSÜZ sınıflandırma yapılmıştır. Kontrollü sınıflandırmanın doğruluğu diğer sınıflandırmaya göre daha yüksek çıkmıştır.

2.2.3. Maksimum Olabilirlik Sınıflandırma Algoritması

Maksimum olabilirlik sınıflandırma algoritması, kontrollü sınıflandırmada kullanılan istatistiksel bir yaklaşıma dayanmaktadır. Önceden tanımlanmış bir arazi sınıfı kümelerinin her birine ait piksel olasılığı hesaplanır ve diğer pikseller daha sonra olasılığın en yüksek olduğu arazi sınıfına atanır. Bayes olasılık temeline dayandırılır [Mather and Tso, 2016]. Literatürde en çok kullanılan istatistiksel sınıflandırma metodudur. Sınıflandırma esnasında arazi sınıfları oluşturulurken piksellerin parlaklık değerlerinin varyans ve kovaryans kullanılır. Her arazi sınıf için normal dağılım eğrisi oluşturulur, ortalama vektör ve kovaryans matrisi ile arazi sınıfının özellikleri belirlenir. Görüntüdeki diğer pikseller, bu özellikler dikkate alınarak hangi arazi sınıfına ait olduğunu belirlemek için istatistiksel olasılık hesaplanır. Bu piksellerin, arazi sınıfına ait olma olasılığının en yüksek olduğu sınıfa atanır [Sisodia, et al., 2014].



Şekil 2.6: Maksimum olabilirlik algoritması uygulaması.

Şekil 2.6'da üç farklı arazi örtüsünün maksimum olabilirlik algoritmasının uygulandığı bir örnek gösterilmektedir. Benzer spektral özelliklere sahip eğitim verisi kullanılarak her arazi sınıfı özellikleri belirlenmiştir ve ardından diğer pikseller ait

olabilme ihtimali yüksek olan sınıflara atanmıştır. Bu sınıflandırma yöntemi kullanılarak birçok çalışma yapılmıştır. Jia, [1997] yaptığı bir çalışmada AVIRIS hiperspektral görüntüsünü ve blok tabanlı maksimum olabilirlik yöntemi kullanılmıştır. Öncelikle, tüm bant setini birbirleri ile yüksek dereceli ilişkili birkaç alt gruba ayırılmıştır. Her alt grup için düşük korelasyonlar göz ardı edilerek bağımsız maksimum olabilirlik yöntemi uygulanmıştır. Böylece maksimum olabilirlik algoritması farklı yöntemlerle çoğaltılabilir. Diğer bir çalışmada ise, Landsat ETM+ görüntüsü kullanılmıştır. Öncelikle eğitim veri seti oluşturulmuştur ve sınıflandırma işlemi gerçekleştirilmiştir. Maksimum Olabilirlik sınıflandırma algoritmasının sağlam bir teknik olduğu ve çok az miktarda yanlış sınıflandırma yaptığı vurgulanmıştır. Genel ve Kappa doğruluğu %90 üzeri olduğu gösterilmiştir [Sisodia, et al., 2014].

2.2.4. Mahalanobis Uzaklığı Sınıflandırma Algoritması

Mahalanobis Uzaklığı Sınıflandırması, her arazi sınıfı için istatistikleri kullanan yöne duyarlı bir uzaklık sınıflandırıcısıdır. Maksimum Olabilirlik Sınıflandırma algoritmasına oldukça benzer bir metottur, ancak bu metot tüm sınıf kovaryanslarını eşit olarak kabul eder. Bu nedenle, daha hızlı sınıflandırma yöntemidir. Herhangi bir eşik belirlenmediği sürece en yakın pikseller en yakın kümeye atanır. Bu metotta, arazi sınıfına uymayan pikseller sınıflandırılmaz [Deer and Eklund 2002]. Mahalanobis sınıflandırmasını konu alan bir çalışmada hiperspektral görüntü kullanılarak Mahalanobis kernel filtre kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Regresyon yöntemi ile Mahalanobis Uzaklık sınıflandırma algoritması bir arada kullanılarak %93 üzeri genel doğruluk elde edilmiştir [Fauvel et al., 2010]. Diğer bir çalışmada ise dört farklı piksel tabanlı sınıflandırma yöntemi kullanılarak bu yöntemlerin performansları analiz edilmiştir. Sınıflandırma algoritmaları olarak Destek Vektör Makineleri, Maksimum Olabilirlik, En Kısa Mesafe ve Mahalanobis Uzaklığı sınıflandırma yöntemleri kullanılmıştır. Çalışmada Landsat-3 uydu görüntüsü kullanılmıştır. Dört farklı algoritma ile oluşturulmuş tematik haritaların ayrı ayrı doğruluk analizi yapılmış ve bu sonuçlar karşılaştırılmıştır. Destek Vektör Makinesi yöntemi kullanılarak üretilen haritanın doğruluğundan sonra en yüksek doğruluk Mahalanobis yöntemi ile üretilen tematik haritaya aittir. Genel doğruluk %92,19 iken Kappa katsayısı ise 0,8763 olarak bulunmuştur [Mahendra et al., 2019].

2.2.5. Yapay Sinir Ağları Sınıflandırma Algoritması

Yapay sinir ağları (artificial neural networks) uzaktan algılanmış verilerin sınıflandırılması için önemli bir potansiyele sahiptir [Atkinson and Tatnall, 1997]. Yapay sinir ağları (YSA), insan beynin çalışma prensibinden esinlenerek üretilmiş bir makine öğrenme algoritmasıdır. YSA, normal dağıtılmış veri varsayımlarına bağlı olmadıkları için parametrik olmayan bir sınıflandırma tekniğidir [Kavzoğlu and Mather, 1998]. Literatürde farklı tipte birçok YSA mevcuttur. Bunlardan bazıları, Çok Katmanlı Algılayıcı (Multilayer Perceptron) Evrimsel Sinir Ağları (Convolutional Neural Network) ve Tekrarlayan Sinir Ağlarıdır (Recurrent Neural Network). YSA'lar gürültülü veri, bulanık veri veya tutarsız verileri ele alma kapasitesine ve önceden programlanmış talimatları kullanmadan yeni bir ortama uyum sağlama yeteneğine sahiptir [Yegnanarayana, 2006]. Bu avantajlarının yanında birçok dezavantajı da mevcuttur. Yeteri sayıda eğitim verisinin olması gerekir, işlem sırasından aşırı öğrenmeye gerçekleşebilir ve kara kutuya benzetildiği için iç yapısının açıklanamaz olması gibi olumsuz yönleri vardır [Lakshmi, 2019]. Sınıflandırma işlemi için kullanıcının bir sinir ağı tasarlaması gerekmektedir. Ayrıca eğitim süresi, performansı ve yakınsama oranını etkileyen öğrenme hızı gibi parametrelerde YSA içinde yaygın olarak kullanılmaktadır [Kavzoğlu and Mather, 2002]. Ağ tasarımı için belli başlı kurallar yoktur, bu nedenle kullanıcı ağ parametrelerini seçerken deneme-yanılma yöntemini kullanması gerekir [Mather and Tso, 2016]. Bu nedenle aynı veri seti için farklı kullanıcılar tarafından deneyim seviyelerine ve parametre tercihlerine bağlı olarak farklı sonuçlar elde edilebilir.

YSA'lar genellikle girdi, gizli ve çıktı katmanları olmak üzere üç katmandan oluşmaktadır. Ağ tasarımı tamamlandıktan sonra, girdi katmanına eğitim verisi olarak görüntü bantları, bant oranları, çeşitli indeksler vb. verilir, gizli katmanda arazi sınıfı özelliklerine göre bunların özellik haritası çıkartılır ve diğer veriler bu özelliklere göre gruplandırılır [Kavzoğlu, 2001]. Ardından çıktı katmanında ise her bir arazi örtüsü türü temsil edilir [Ndehedehe et al., 2013]. Bu algoritma ile ilgili birçok çalışma literatürde mevcuttur. Bu çalışmalarının birinde, iki farklı tarihe ait SPOT görüntüsü kullanılarak küçük bir sinir ağı tasarımı ile %80-90 arası doğrulukla 20 adet arazi sınıfı ile sınıflandırma işlemi gerçekleştirilmiştir [Kanellopoulos et al., 1991]. Diğer bir

çalışmada ise YSA kullanılarak %90 genel doğrulukla heyelan duyarlılık haritası üretilmiştir [Kavzoğlu and Gomez, 2005]. Ayrıca başka bir çalışmada, başka bir çalışmada ise pan-kromatik görüntü sınıflandırması gerçekleştirilmiştir. Bu çalışmada geri yayılım algoritması ile yapılandırılmış bir sinir ağı kullanılmıştır. Dört arazi sınıfı için eğitim verisi oluşturulmuş %99,68 doğrulukla sınıflandırma gerçekleştirilmiştir. Özellikle, bu çalışmada geleneksel sınıflandırma yöntemlerine göre sınıflandırma doğruluğunun %10'luk bir artış olduğu vurgulanmıştır [Zou et al., 2012]. Literatürdeki başka bir çalışmada, IKONOS görüntüsünün hem Maksimum Olabilirlik sınıflandırma algoritması hem Destek Vektör Makineleri hem de çok katmanlı algılayıcı ile sınıflandırması yapılmış ve bunların sonuçları karşılaştırılmıştır. Sinir ağı ile üretilmiş tematik haritanın sonuçlarının diğer yöntemlere göre daha yüksek olduğu gösterilmiştir [Ojaghi et al., 2015]. Sınıflandırma yaklaşımlarının çoğunda spektral veya uzamsal özellikler kullanılmaktadır. Hem mekânsal hem de spektral özelliklerin bir arada kullanılarak yapılan sınıflandırmaların doğrulukları diğerlerine göre daha yüksek çıkmaktadır [Borra et al., 2019]. YSA yapısını kullanarak oluşturulan model tasarımını optimize etmek için çeşitli çalışmalarda yapılmaktadır. Bu çalışmalardan bir tanesinde Pavia ve Indian Pines görüntüleri kullanılarak sınıflandırma işlemi yapılmıştır [Sildir et al., 2020]. Görüntüye ait özelliklerin etkin bir şekilde kullanılması için YSA'ların derinleştirilmesine üzerine çalışılmış ve konu ile ilgili birçok çalışma yapılmıştır. Böylece derin öğrenme kavramı literatüre kazandırılmıştır.

2.2.6. Doğrusal Ayrıcı Sınıflandırma Algoritması

Doğrusal Ayrıcı (Linear Discriminant) Sınıflandırma Algoritması, istatistiksel tabanlı görüntüden özellik çıkartmak için yaygın olarak kullanılan bir yöntemdir [Switzer, 1980]. Özellikle bu yöntem hiper spektral sınıflandırma veri boyutunu azaltmak için kullanılmaktadır [Chen et al., 2018]. Kısaca bu algoritma, veri ögelerinin maksimum ayrımcılığına göre verilerin boyutlarını azaltan kontrollü bir yöntemdir. Bu metot ile iki farklı sınıfa ait pikseller doğru bir şekilde ayırt edilebilir.

Bu sınıflandırma algoritması, sınıf içi varyansı azaltırken, sınıflar arası varyansı artırma prensibi ile çalışmaktadır. Bu işlem ile sınıflara ait öznelikler üretilir ve sınıfları birbirinden ayırt edecek özellikler ortaya çıkartılır. Bu algoritmanın çalışabilmesi için yer referans verilerine yani eğitim veri setine ihtiyaç vardır, bu

nedenle kontrollü bir sınıflandırma yöntemi olarak kullanılmaktadır [Sağlam ve Baykan, 2018].

2.2.7. Destek Vektör Makineleri Sınıflandırma Algoritması

Destek Vektör Makinesi (Support Vector Machine), genellikle karmaşık ve gürültülü verilerden iyi sınıflandırma sonuçları veren ve istatistiksel öğrenme teorisinden üretilmiş bir kontrollü sınıflandırma yöntemidir [Kavzoğlu and Çölkesen, 2005]. Bu sınıflandırma algoritması, veriyi kullanarak bir hiper-düzlem ile iki arazi sınıfını birbirlerinden ayırır. Ancak bu hiper-düzlem oluşturulurken sınıflandırma için kullanılacak veri yüksek bir boyuta farklı özelliklere sahip fonksiyonlar ile dönüştürülür. Ayrıca DVM algoritması hem doğrusal hem de doğrusal olmayan işlemlerde kullanılabilir [Kavzoğlu ve Cölkesen, 2010]. Pal ve Mather [2005] tarafından yapılan bir çalışmada ise multi-spektral ve hiper-spektral uydu görüntüleri kullanılmış ve yapay sinir ağları, maksimum olabilirlik ve DVM ile ayrı ayrı sınıflandırma yapılmış ve bu sınıflandırma sonuçları birbirleri ile karşılaştırılmıştır. En yüksek sınıflandırma doğruluğu DVM ile üretilmiş tematik harita ait olduğu belirtilmiştir. Bu algoritma kullanılarak yapılan diğer bir çalışmada, Landsat TM görüntüsü sınıflandırılmıştır. Çalışma alanı tropikal bir bölgedir bu nedenle ondan fazla arazi örtüsü sınıfı içermektedir. Genel doğruluğu %97,1 bulunurken Kappa doğruluğu da 0,96 olarak bulunmuştur [Bahari et al., 2014].

2.3. Kontrolsüz Sınıflandırma Algoritmaları

2.3.1. K-Ortalama Sınıflandırma Algoritması

K-Ortalama Sınıflandırma yöntemi, kontrolsüz bir sınıflandırma yöntemi olup görüntüdeki verileri eşit olarak dağıtılmış ilk sınıf özelliklerini hesaplar ardından minimum mesafe metoduyla görüntü piksellerini tekrarlı olacak şekilde en yakın arazi sınıfına atar. Her tekrarlama, sınıf özelliklerini yeniden hesaplanır ve yeni özelliklere göre pikselleri yeniden arazi sınıfına atar. Eğer bir standart sapma gibi bir eşik belirtilmediyse tüm pikseller en yakın arazi sınıfına atanır. Belirlenen eşik değerlere uymayan pikseller ise sınıflandırılmaz. Bu işlem süreci, her arazi

sınıfındaki piksel deęişim eřięinden daha az deęişene veya maksimum tekrarlama sayısına ulaşana kadar devam eder [Kulkarni, 2017]. Yapılan bir çalışmada, IRS uydusunun görüntüleri kullanılarak K-Ortalama kullanan farklı mesafe ölçütleri ile kontrolsüz sınıflandırma işlemi gerçekleştirilmiştir. Tüm sınıflandırma işlemlerinin doğruluęu %80 üzeri çıkmıştır. Ayrıca, öklid uzaklığı ile sınıflandırılmış uydu görüntülerinin sınıflandırma doğruluęu, dięer sınıflandırma sonuçlarının doğruluęuna göre daha yüksek olduęu görölmektedir. [Venkateswaran et al., 2013].

2.3.2. ISODATA Sınıflandırma Algoritması

ISODATA kontrolsüz bir sınıflandırma yöntemi olup veri uzayında eşit olarak dağıtılmış arazi sınıfı özellikleri hesaplar ve minimum mesafe teknikleri kullanarak dięer pikselleri tekrarlı olarak arazi sınıflarına atar. Her tekrarlama özelliği yeniden hesaplanır ve bu özellik uzayına göre pikselleri yeniden sınıflandırır. ISODATA, K-Ortalama Sınıflandırmasına benzer bir algoritma ile çalışır. Ancak K-Ortalama Sınıflandırması, sınıf içerisindeki deęişkenliği en aza indirir ve küme sayısını yineleme boyunca sabit tutar çalışır [Kulkarni, 2017]. Kısaca, ISODATA sınıflandırması, dięer sınıflandırma yöntemine göre daha esnektir. Pakistan Arazi Kullanım haritasını oluşturmak için yapıla bir çalışmada Hem ISODATA hem de K-Ortalama Sınıflandırma algoritması birlikte kullanılmıştır. Bu çalışmanın amacı, benzer spektral özelliklere sahip piksellerin kümeler halinde gruplandırılmasıdır ve bu iki algoritmanın sınıflandırma açısından farklı parametrelerle karşılaştırılmıştır [Abbas et al., 2016].

2.3.3. Bulanık Mantık Sınıflandırma Algoritması

Bulanık Mantık algoritması bilgi tabanlı bir yöntem olup kontrol sistemlerinde yaygın olarak kullanılmaktadır. Bu algoritma, belirli bir görev için insan eylemlerini taklit edebilen otomatik bir sistemdir. Bu yöntem, verilerin istatistiksel dağılımı hakkında herhangi bir varsayımda bulunmaz ve görüntü sınıflandırması gibi işlemlerde ayrıntılı sonuçlar elde edebilir. Ancak bazı durumlarda uzaktan algılanmış görüntülerde sınıf içi deęişkenlikten kaynaklı veya düzgün olarak tanımlanamayan piksellerden ötürü karmaşık bir yapıda olabilirler. İşte bu pikseller nedeniyle bulanık

mantık sınıflandırılması geliştirilmiştir. Sınıflandırma gerçekleştirilirken indeks veya yükseklik modeli gibi ek veriler de bu algoritmanın içine dahil edebilir. Bulanık mantık yorumlanabilir bir yapıya sahiptir, be nedenle bilim insanı ile eğitim verileri bir arada kullanılabilir [Wang and Jamshidi, 2004].

2.4. Sınıflandırma Sonuçlarının Değerlendirilmesi

Üretilen tematik haritaların doğruluğunun değerlendirilmesi gerekir, bu nedenle doğruluk analizi yöntemleri geliştirilmiştir. Sınıflandırma işlemi gerçekleştirilirken ekstra olarak kullanıcı tarafından doğruluk değerlendirmesi yapmak için doğrulama seti oluşturulması gerekir. Aşağıda, doğruluk analizi için kullanılan ölçütler mevcuttur. Bu ölçütlerin hesaplanabilmesi için üretilen tematik haritanın hata matrisinin oluşturulması gerekmektedir. [Borra et al., 2019]. Şekil 2.7’deki hata matrisinde i ifadesi sınıflandırılan örneklem sayısı diğer bir deyişle, sütun değerleri gösterirken j ifadesi ise referans örneklem sayısını, kısaca satır değerlerini göstermektedir [Foody, 2002].

		Referans			Toplam
		1	2	k	Satır n_{i+}
Sınıflandırma:	1	n_{11}	n_{12}	n_{1k}	n_{1+}
	2	n_{21}	n_{22}	n_{2k}	n_{2+}
	k	n_{k1}	n_{k2}	n_{kk}	n_{k+}
Toplam Sütun n_{+j}		n_{+1}	n_{+2}	n_{+k}	n

Şekil 2.7: Hata matrisinin matematiksel gösterimi.

Sınıflandırma işlemi yapılmış olan veride i sınıfındaki toplam örneklem sayısı:

$$n_{i+} = \sum_{j=1}^k n_{ij} \quad (2.1)$$

Referans olarak kullanılan veri setinde j sınıfındaki toplam örneklem sayısı:

$$n_{+j} = \sum_{i=1}^k n_{ij} \quad (2.2)$$

Genel doğruluk, sınıflandırma işlemi sonucunda doğru sınıflara atanmış piksellerin görüntü içindeki tüm piksellere oranı olacak şekilde aşağıdaki gibi hesaplanabilir:

$$\text{Genel doğruluk} = \frac{\sum_{i=1}^k n_{ii}}{n} \quad (2.3)$$

Üretici doğruluğu, referans verilerinde o arazi sınıfının toplam piksellerine göre, belirli bir sınıfta doğru olarak sınıflandırılan piksel sayısının oranını gösterir. Üretici doğruluğu şu formül ile tanımlanmaktadır:

$$\text{Üretici doğruluğu}_j = \frac{n_{jj}}{n_{+j}} \quad (2.4)$$

Kullanıcı doğruluğu, sınıflandırma modeli tarafından o arazi sınıfının altında sınıflandırılan toplam piksellere göre, belirli bir sınıfta doğru olarak sınıflandırılan piksel sayısının oranını gösterir. Kullanıcı doğruluğu şu şekilde hesaplanabilir:

$$\text{Kullanıcı doğruluğu}_i = \frac{n_{ii}}{n_{i+}} \quad (2.5)$$

Kappa katsayısı, hata matrisindeki diyagonal olmayan değerleri dikkate alan bir ölçüttür. Bu değer şu formül ile hesaplanabilir:

$$\text{Kappa} = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{i+} n_{+i}}{n^2 - \sum_{i=1}^k n_{i+} n_{+i}} \quad (2.6)$$

n = Bütün sınıflardaki örneklem toplamı

$$\sum_{i=1}^k n_{ii} = \text{Doğru sınıfa atanmış örneklem sayısı}$$

$$\sum_{i=1}^k n_{i+} n_{+i} = \text{Hata matrisindeki tüm sınıflara ait satır ve sütun örneklem toplamı}$$

Sınıflandırma performansını ölçmek için oluşturulan hata matrisini kullanarak Duyarlılık (Sensitivity), Özgüllük (Specificity), Hassasiyet (Precision) ve Geri Çağırma (Recall) ölçütleri de hesaplanabilir. Tablo 2.3’de iki arazi sınıfı kullanılarak oluşturulmuş bir hata matrisi mevcuttur. Sınıflandırılmış A verisi, referans A verisi ile aynı sınıfta ise Doğru Pozitif (DP) olarak adlandırılır. Sınıflandırılmış A verisi, başka bir referans verisi (B) ile aynı grupta ise Yanlış Pozitif (YP) olarak tanımlanır. Sınıflandırılmış B verisi, referans A verisinin içinde ise Yanlış Negatif (YN) olarak adlandırılırken, sınıflandırılmış B verisi, referans B verisinin sınıfında yer alıyorsa Doğru Negatif (DN) olarak tanımlanır. Hata matrisi hızlı incelemenin bir yolu diyagonalı üst köşeden taramaktır. İdeal bir hata matrisinde diyagonalde bulunan elemanlar haricinde diğer elemanların sıfır olması beklenir [Kotu and Deshpande, 2019].

Tablo 2.2: İki sınıflı tanımlanmış bir hata matrisi.

	Referans Verisi		
	Arazi Sınıfları	A	B
Sınıflandırılmış Veri	A	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
	B	Yanlış Negatif (YN)	Doğru Negatif (DN)

Duyarlılık, bir sınıflandırıcının gereken tüm durumları seçebilmesini tanımlar. Yüzdesel veya oransal olarak $DP/(DP+YN)$ şeklinde formülize edilebilir. Geri çağırma ölçütü ve üretici doğruluğu, Duyarlılık ölçütü ile aynı matematiksel formülasyona sahiptir. Özgüllük sınıflandırılmış verinin gerçekten referans verisi ile aynı sınıfta olup olmadığının ölçütüdür. $DN/(DN+YP)$ şeklinde formülize edilir. Hassasiyet ölçütü kullanıcı doğruluğu ile aynıdır. Bir arazi sınıfına atanan verilerin o

sınıfa gerçekten ait olma doğruluğudur. $DP/(DP+YP)$ şeklinde bir oranlama yapılarak hesaplanır [Barsi et al., 2018].

Bu sınıflandırma doğruluğu ölçütlerinin dışında, başka doğruluk ölçütleri de vardır. Özellikle, bulanık mantık gibi sınıflandırma algoritmasıyla üretilmiş haritaların doğruluğunu bulmak için hata matrisi oluşturmak uygun bir yaklaşım olmayabilir. Bunun gibi yumuşak sınıflandırıcıların performansını değerlendirmek için literatürde birçok farklı yöntemle oluşturulmuş ölçütler bulunmaktadır. Bu ölçütlerin kullanılması esnasında yaşanan problemlerden biri de doğruluk analizi için referans verilerini elde etmenin zor olmasıdır. [Borra et al., 2019]. Tablo 2.4'te ise bu ölçütlerden bahsedilmektedir.

Tablo 2.3: Diğer doğruluk ölçütleri.

Doğruluk Ölçütleri	Açıklaması
Koşullu Entropi	Bu doğruluk ölçütü verilen piksellerin sınıf tanımlamasının belirsizliğini gösterir [Maselli et al., 1994].
Karşılıklı Bilgi (Mutual Information)	Uydu görüntülerindeki var olan değişiklikleri tespitini inceleyip, sınıflandırma bilgilerinin doğru kullanıp kullanılmadığını kontrol eden bir doğruluk ölçütüdür [Finn, 1993].
Bilgi Yaklaşımının Simetrik İndeksi	Sınıflandırma çıktısı tarafından sağlanan verilerin, gerçek verilerle olan benzerliği, karşılıklı bilgi içeriğinin değerlendirilmesiyle ölçülür. Esas olarak arazi örtüsü tespitinin sınıflandırma doğruluğunun değerlendirilmesinde kullanılır [Finn, 1993].
Morisita İndeksi	Uydu görüntüsündeki iki farklı arazi sınıfının arasındaki benzerliği ölçmek için kullanılan bir indekstir [Hayes and Castillo, 2017].
ROC Eğrisi	Obje tespiti gibi bilimsek çalışmalarda kullanılan bir doğruluk ölçüdür. Özellikle, ikili sınıflandırmada kullanılmaktadır. İki sınıfı birbirinden ayıran bir eşik değeri belirlenir ve eşik değerinin altında veya üstünde kalmasına göre sınıflandırma doğruluğu ölçülür. Bu ölçüt özellikle yapay sinir ağı ile yapılmış uygulamalarda kullanılmaktadır [Chen et al., 2019].
AUC Eğrisi	Yapılan sınıflandırmanın doğruluğu, iki farklı sınıfı birbirinden ne kadar ayırdığı ile ilgilidir. Bu ölçüt ROC eğrisi ile beraber kullanılır. Tüm sınıflandırma eşik değerlerinin performansını ölçen bir ölçüttür [Web 1, 2020].

Tablo 2.3: Devam.

Cohen Kappa Katsayısı	İki sınıf arasındaki tutarlılığı gösteren bir ölçüttür. Bu katsayı, iki sınıflandırmanın sonuçlarını değerlendirir ve tutarlılığını hesaplayan bir algoritmadır [Chen et al., 2019].
Z-Skor	Bir arazi sınıfına ait verilerin, o sınıfa ait örneklemin ortalamadan ne kadar üstünde veya altında standart sapma sayısıdır. Bu ölçüt literatürde kullanılan bir istatistiksel bir doğruluk ölçütü olarak kullanılmaktadır [Belwalkar et al., 2018].


Bahsedilen doğruluk ölçütlerinin yanında son yıllarda farklı yaklaşımlarla türetilmiş doğruluk ölçütleri de mevcuttur. Yapılan bir çalışmada arazi kullanımı/örtüsü haritası oluşturulurken eğitim verisi ve sınıflara ait örneklem olarak kullanılan veriler arasında belirsizlik olduğu gösterilmiştir. Bu durumu engellemek için sınıflandırma sonuçlarındaki belirsizliği gidermek ve eğitim ve referans verisi seçiminin sınıflandırma doğruluğu üzerine çalışılmıştır [Cheng et al., 2019].

3. YAPAY SİNİR AĞLARI

3.1. Yapay Sinir Ağların Tarihsel Gelişimi

İnsan beynini simüle eden bir mekanizma üretmek için ilk olarak beyin içerisinde gerçekleşen bilişsel işlevliği anlamak gerekir. Bu nedenle, bu konunun kökenlere inmek gerekirse, bu alandaki ilk çalışma M.Ö. 300 yıllarında Aristotile tarafından insan beynini anlamaya yönelik olarak yapılmıştır. 1873'te Alexander Bain çalışmasında günümüzün sinir ağına benzeyen bir yapıyı tarif etmiştir. Bu yapının bir grup sinir hücresinden oluştuğunu ve hücreler arası ilişkilerin çeşitli bağlantı parametreleri kullanarak gerçekleştiğini öne sürmüştür [Wang and Raj, 2017]. 1943 yılında McCulloch ve Pitts [1943], ikili eşik (binary threshold) yani ya hep ya hiç (all or none) ilkesi çalışma prensibine ait nöronları incelenmiştir. Burada sinirsel olayları ve bunlar arasındaki ilişkileri önermeli mantık yoluyla nasıl ele alınabileceği gösterilmiştir. 1949'da Donald Hebb, günümüzde birçok öğrenme yaklaşımının alt yapısı oluşturacak olan Hebbian yaklaşımını ortaya koymuştur. Bu metotta, sinir ağındaki parametrelerin değişebileceğini ifade etmiştir [Hebb, 1949]. Ardından 1958'de Rosenblatt, bir sinir hücresi türü olan tek katmanlı algılayıcı modelini (Perceptron) birçok amaçla kullanılabileceği üzerine incelemelerde bulunmuştur. Bu model de algılayıcının birden fazla girdi verisini alarak bir çıktı verisi oluşturması prensibi ile çalışmaktadır. Model içindeki çıktı verisi, girdi verisinin ağırlıklarının toplamını eşik değeri ile karşılaştırarak bir sonuç elde edilmiştir. Rosenblatt'ın algılayıcı modelinde, duyuşal birim, projeksiyon birim, ilişkilendirme birimi ve yanıt birimi bulunmaktadır. Duyuşal birimden algılanan girdiler, projeksiyon biriminden alınıp farklı ağırlıklarla birlikte ilişkilendirme birimine gönderilir ardında bir eşik yardımı ile üretilen sonuç veri yanıt birimine gönderilir [Rosenblatt, 1958]. Bu yapı, günümüz sinir ağı yapısına oldukça benzemektedir ancak bu iki yapıyı birbirinden ayıran en büyük faktör lineer olmayan aktivasyon fonksiyonlarının kullanılmasıdır. Rosenblatt'ın algılayıcı modelinde sadece lineer fonksiyonlar kullanıldığı için kullanımı birçok alanda sınırlı kalmış olmasıyla birçok çok katmanlı algılayıcıların temelini oluşturmaktadır. 1960'lı yılların başında Windrof ve Hoff tarafından algılayıcıya göre daha gelişmiş bir öğrenme metoduna sahip ADALINE (Adaptive Linear Neuron) modeli üretilmiştir. Bu çalışmalardan sonra ilk defa yapay zekâ

kavramı ortaya çıkmıştır. Bu sebeple, sinir ağlarına olan ilgi azalmış ve bilim insanları yapay zekâ kavramları üzerinde durmuştur [Widrow and Walach, 2008]. Daha sonra Minsky ve Papert tarafından 1969 yılında yapılan çalışmada, mantıksal operasyonlardan olan NOT, AND ve OR problemlerine çözüm üretebileceğini belirtirken, XOR ve NXOR gibi doğrusal olmayan problemler konusunda bu algılayıcının kısıtlı kaldığını vurgulamıştır. Tek katmanlı algılayıcıların ardında çok katmanlı algılayıcılar ortaya çıkmıştır. Bu sinir ağının içinde birden fazla gizli katman olabileceğini öne sürülmüştür. Böylece karmaşık yapıdaki problemler çok katmanlı algılayıcı ile çözülebilmektedir. Bu sinir ağının, en önemli özelliği lineer olmayan aktivasyon fonksiyonları içermesidir (Şekil 3.1). Girdiler için ayrı ayrı ağırlık tanımlanır ve lineer olmayan aktivasyon fonksiyonundan geçirilir [Marius et al.,2009].




Şekil 3.1: Çok katmanlı algılayıcı.

1970 yıllarında, Kohonen ve Anderson kontrolsüz öğrenmenin temellerini atmıştır ve Grosberg, mühendislik gibi birçok uygulamada yapay sinir ağlarının kullanabileceğini göstermiştir. 1980’lerde Hopfield tarafından, Boltzman makinesinin temel yapıtaşını oluşturan, sinir ağlarının geliştirilebileceği üzerine çeşitli çalışmalar yapılmıştır. İlerleyen süreçte, Rumelhart ve arkadaşları, tek katmanlı algılayıcıların çözemediği XOR probleminin ve daha önceden üretilmiş ağların kısıtlı kaldığı birçok noktanın aşılmasına yardımcı olmuştur [Keskenler ve Keskenler, 2017]. 1990’ların başlarında radyal temelli fonksiyon modelleri geliştirildi, bu da sinir ağlarının gelişmesine katkı sağlamıştır. Ayrıca bu zamanlarda Yann LeCun tarafından geri yayılımın ilk pratik denemesini uygulanmıştır. Bu uygulamayı, el yazısı ile yazılmış rakamları kullanarak gerçekleştirmiştir [LeCun et al., 1990].


3.1. Yapay Sinir Ağı ve Genel Özellikler

Yapay sinir ağları, biyolojik canların öğrenme mekanizmasının simüle edilmesi ile oluşturulan popüler bir makine öğrenme tekniğidir. Bu sistemler, öğrenebilen ve adapte olabilen karmaşık bir ağ oluşturmak için kullanılır. İnsan sinir sistemi, nöron adı verilen hücrelerden oluşmuştur. Bu nöronlar birbirine aksonlar ve dendritler aracılığıyla birbirlerine bağlanır ve bu bağlantı bölgelerine sinaps adı verilmektedir. Biyolojik sinir hücresinde girdiler dendritler ile sağlanırken, üretilen çıktılar aksonlar ile sağlanmaktadır (Şekil 3.2). Sinaptik bağlantıların gücü genellikle dış uyarılara bağlı olarak değişmektedir. Bu değişim ise öğrenmenin canlı organizmalarda nasıl gerçekleştiğini göstermektedir [Aggarwal, 2018]. Hesaplama birimleri, biyolojik sinir ağındaki sinaptik bağlantıların gücü ile aynı role sahip olan ağırlıklar yoluyla birbirine bağlıdır.



Şekil 3.2: Biyolojik sinir hücresi.

Yapay sinir ağındaki nöronlar için her bir girdi, o birimde hesaplanan işlevi etkileyen bir ağırlıklarla ölçeklendirilir (Şekil 3.3). Bir yapay sinir ağı; girdi katmanı, gizli katmanlar ve çıktı katmandan oluşmaktadır [Buduma, 2016]. Çıktı hücresi ağ için geri işlenen veri sağlamaktadır. Gizli katmanın iki önemli özelliği vardır. İlki, gizli katmanlar sadece diğer gizli katmanlardan veya girdi katmanından veri alır. İkincisi ise gizli katman, sadece çıktı katmanına veya diğer gizli katmanlara veri sağlar. Gizli katmanlar, sinir ağının girdiyi anlamasına yardımcı olur ve çıktı oluştururlar. Bilim insanları, sinir ağ kalıpları öğrenmelerinde yardımcı olmak için gürültü (bias) eklerler [Mukhopadhyay and Mukhopadhyay, 2018].



Şekil 3.3: Yapay sinir hücresi.

Yapay sinir ağlarının birçok temel özelliği mevcuttur. Bu nedenle, veri analizi ile ilgili birçok alanda ve tahmin amaçlı birçok karmaşık uygulamada kullanılmaktadır. Bu özelliklerden bazıları; genelleştirebilir olması, uyarlanabilir olması, doğrusal olmaması, fazla miktarda değişken ve parametre kullanabilmesi, öğrenebilmedir [Öztürk ve Şahin, 2018].

Yapay sinir ağları doğrusal fonksiyon içermediği için birçok alanda kullanılabilir. Bu nedenle, bu uygulamaların gerçekleştirme sürecinde yapay sinir ağlarının birçok avantajı ve dezavantajı bulunmaktadır [Yazıcı vd., 2007]. Bu özellikler modeli etkileyen ve modelin analizi için bilinmesi gereken önemli faktörlerdir. Bunlar sırasıyla gruplandırılmış ve Tablo 3.1’de gösterilmiştir [Mijwel, 2018]. Yapılacak çalışmanın amacına göre bu avantaj ve dezavantajların göz önüne alınması gerekir.

Tablo 3.1: Yapay sinir ağların temel avantajları ve dezavantajları.

Avantajlar	Dezavantajlar
Makine öğrenmesi yapabilir	Ağ kara kutu gibi davranır
Daha önce görmediği örneklem hakkında bilgi üretebilir	Modelin eğitim süresinin bilinmemesidir
Bilgiler oluşturulan ağda saklanabilir	Girdi verisinin sinir ağının anlayacağı bir şekilde düzenlenmesi gerekir
Kendi kendine öğrenebilir	Model üretilirken belirli kurallar yoktur
Hataları tolere edebilir	Güçlü donanım gerektirir
Paralel işlem yapabilme kapasitesine sahiptir	-
Sinir ağı genelleştirilebilir	-

3.3. Yapay Sinir Ağ Çeşitleri

Literatürde karşımıza birçok yapay sinir ağı çeşidi çıkmaktadır. Sinir ağı çeşitlerine örnek olarak, algılayıcılar, ileri beslemeli ağlar, tekrarlayan sinir ağları, uzun/kısa süreli bellek, Markov Zinciri, Boltzman Makinesi, Hopfield Ağı, Evrimsel Sinir Ağları (Convolutional Neural Network) ve derin inanç ağlarıdır [Bermejo et al., 2019]. Bunların içindeki en temel sinir ağı algılayıcılardır. Algılayıcılarda öğrenme prensibi nispeten basittir. Çok veya tek katmanlı yapıya sahip olan sinir ağlarında girdi verisi bir yönde yayılır [Noriega, 2005]. Kısaca, ileri beslemeli bir ağı prensibi ile çalışmaktadır [Alsmadi et al., 2009].

Sinir hücreleri, belirli bir katmanının tüm hücrelerinin sadece bir sonraki katmanının tüm hücreleri ile bağlanacağı şekilde bir sistem oluşturulur. Bu algılayıcılar girdi ve çıktı katmanlarına sahiptir. Ayrıca bu sistemlerde bir gizli katman veya bazı durumlarda birden fazla gizli katmanda görülmektedir. Eğer bir girdi katmanına bir veri gönderilirse, belirli bir katmanın her hücresinde sadece bir kez uyarılır ve bu veri bir sonraki katmanın hücrelerinin girişine gönderilir. Sonuç olarak çıktı verisi, en son çıkış katmanında verilir [Bielecki, 2019]. İlave, bu yöntem geri yayılım algoritmasını ile aktivasyon fonksiyonları kullanılır. Algılayıcılarda kullanılan her sinyalin farklı bir ağırlığı mevcuttur. Çok katmanlı basit sistemler problemlerin çözümü için daha karmaşık hale getirilebilir. Üç katmanlı algılayıcılar sığ sinir ağları (shallow neural network) olarak literatürde geçerken dört ve dörtten daha fazla katmanlı algılayıcıların oluşturduğu ağlarda derin sinir ağı olarak karşımıza çıkmaktadır. Çok katmanlı algılayıcıların diğer ağlardan en büyük farkı karar fonksiyonunun olması ve çıktının ikili (binary) olmasıdır [Marius et al., 2009]. Çok katmanlı algılayıcıların, lineer olmayan modelleri öğrenebilmesi ve gerçek zamanlı öğrenme becerisi gibi en önemli iki avantajı mevcuttur. Çok katmanlı algılayıcıların dezavantajları ise öğrenme esnasında hesaplanan maliyet fonksiyonunun (dışbükey bir şekil oluşturur) birden fazla yerel minimum değeri vardır. Bu sebeple, rastgele ağırlıklarla başlatılan öğrenme işlemleri farklı doğruluk sonuçlarına neden olmaktadır. Diğer bir dezavantaj ise ağı içerisinde kullanılan hiper-parametrelerin ayarlanması gerekmektedir [Kavzoglu and Mather, 2003].

3.4. Yapay Sinir Ağlarının Uygulama Alanları

Sinir ağları birçok alanda ve uygulamada yaygın olarak kullanılmaktadır. Bu uygulama alanlarından bir tanesi karakter sınıflandırılması ve gruplandırılmasıdır [Vieira and Moura, 2017]. Metin sınıflandırılması, web araması, dil tanıma ve bilgi filtreleme uygulamalarında kullanılmaktadır ve sinir ağları aktif olarak kullanılmaktadır. Bununla ilgili birçok çalışma mevcuttur [Zhang and LeCun, 2015].

Ses ve konuşma tanıma uygulamalarında da sinir ağları yaygın olarak tercih edilmektedir. Choon et al. [2004] tarafından yapılan çalışmada ise videolarda güvenlik nedeniyle kullanılan şifreleme yöntemleri incelenmiştir. Şifreleme için yapay sinir ağları kullanılmıştır ve tüm programlama işlemlerinde MATLAB yazılımı kullanılmıştır. İlaveten, bilim insanları evrimsel sinir ağlarını kullanarak konuşma hızını gibi değişkenleri göz önünde tutarak bu konuyla ilgili çalışma yapılmıştır [Abdel-Hamid et al., 2014]. YSA'lar bilgisayarların video veya görüntüleri verimli bir şekilde anlamalarını ve işlemlerini sağlamak amacıyla kullanılmaktadır. Buradaki en büyük amaç bilgisayarlara insan beyni işlevselliğinin yeteneğini kazandırmaktır. Teorik olarak, bilgisayarın veriyi anlayabilmesi için mantıksal bir kontrol edinmesi gerekir. Böylece bilgisayarlara görmenin alt alanları olan nesne algılama, nesnenin konumunu algılama, görüntü düzenleme, video düzenleme ve bu görselleri amaca uygun işlemler uygulatabilme yeteneği kazandırılabilir. Bu gibi uygulamalarda çoğunlukla YSA'lar çok yaygın olarak kullanılmaktadır [Abiodun et al., 2018]. Yapılan bir çalışmada girdi verisi olarak verilen JPEG formatlı obje görüntülerinin en ayrıntılı bölümlerini tespit etmek için bir YSA modeli önermiştir [Cho et al., 2019].

YSA'lar tahmin ve ön görü çalışmalarında da kullanılmaktadır. Kişi [2008] tarafından yapılan bir çalışmada, ileri beslemeli sinir ağı, genelleştirilmiş sinir ağı ve radyal bazlı YSA tekniği kullanılarak Türkiye'deki Doğu Karadeniz bölgesinde bulunan Göksudere Nehri üzerinden aylık akış tahminleri yapılmıştır ve bu üç farklı tekniklerin performansı değerlendirilmiştir. Ayrıca başka bir çalışmada ise YSA hava tahmini için kullanılmıştır. İlk başlarda birçok araştırmacı hava durumu verilerini girdi olarak kullanıp, çıktı verileri ile arasında doğrusal bir ilişki kurmaya çalışmıştır. Ancak, hava durumu verilerinin doğasında doğrusallık olmaması keşfi ile bu verilerin doğrusal olmayan tahminlere kaydığı gözlenmiştir. YSA ile veriler arası ilişkiyi doğrusal olmayan modellerle ifade edilebileceği gösterilmiştir. Bu çalışmada YSA

yaklaşımının uygulanabilirliği ve performansı incelenmiştir [Abhishek et al., 2012]. Başka bir çalışmada ise fırtına tahmini üzerine yapılmıştır. Mayıs 2009 yılında Hindistan'da meydana gelen gök gürültülü fırtınaları, fırtınadan etkilenen meteorolojik parametreler kullanılarak tahmin etmek için yapay sinir ağı modeli ile deneyler yapılmış ve bir YSA modeli geliştirilmiştir [Litta et al., 2013]. Literatürdeki başka bir çalışmada ise toplu taşıma sistemleri alanının da YSA'nın uygulanması araştırılmıştır. Bu çalışmada, Türkiye'nin de içinde bulunduğu 13 farklı ülkede, trafik akıcılığı, seyahat süresi, yolcu akışı, rota seçimi ve bekleme süresi gibi parametreler YSA yardımıyla öngörülme istenmiştir [Pekel, ve Soner Kara, 2017].

Obje tespiti uygulamalarında algılama yeteneği, hedeflenen görüntü nesnelerini saptamayı, bulmayı, sınıflandırmayı veya ayırt etmeyi amaçlayan bilgisayar görüşünde yaygın olarak YSA'lar kullanılmaktadır [Abiodun et al., 2018]. Eğitim amaçlı bir veri seti hazırlanır. Özellikle, objelere ait renk, doku ve geometrik özellikler eğitim sırasında modelin eğitilmesi için kullanılır [Szegedy et al., 2013]. Ayrıca YSA modellerindeki son gelişmelerden biri de örüntü tanıma sorununa yeni yaklaşımlar getirilmiştir. Örüntü veya desen tanıma yaklaşımları ilk zamanlarda sadece istatistiksel yöntemlerle kullanılmıştır. Ancak YSA'ların gündeme gelmesi ile beraber örüntü konusunda çalışmalar başlatılmıştır. Tanıma sistemi tasarımı için örüntü sınıf tasarımı, örüntü gösterimi, sınıflandırıcı tasarımı ve öğrenmesi gibi önemli noktalar mevcuttur. Ancak hala bu konuyla ilgili karmaşık kalıp, ölçek veya yönelim gibi problemler halen günümüzde incelenmektedir [Basu et al., 2011]. Başka bir uygulama alanı ise yüz tanıma uygulamalarında kullanılan insan yüzü hizalamadır. Bununla ilgili bir çalışma yapılmış ve yüz hizalaması için YSA'lardan üretilmiş bir regresyon yaklaşımı kullanılmıştır. Oluşturulan ağ, küresel bir katman ve çok aşamalı yerel katmanlardan oluşmaktadır. Ayrıca bu çalışmada oluşturulan ağ optimize etmek için çeşitli stratejilerde uygulanmıştır [Shi et al., 2014].

Dikkat çeken diğer alanların başında sağlık sektörü gelmektedir. İnsana ait tansiyon, kan basıncı ve solunum hızı gibi verilerin değerlendirilmesi ile kişinin hastalığının iyileşme süreci takip edilebilir ve hastalığı ile ilgili modeller yapay sinir ağları ile oluşturulabilir. Sinir ağları, farklı koşulları ve modelleri inceleyerek büyük resmi oluşturmak için bu verileri birleştirerek öğrenebilir ve daha sonra başka bir hastanın durumunu, modellere dayanarak teşhis edebilir [Web 2, 2000]. Bu konuyla ilgili başka bir çalışmada ise daha düşük maliyetle bakım hizmetlerini gerçekleştirmek için makine öğrenmesi tekniklerinden biri olan YSA'nın uygulanabilirliğini

incelemiştir. Özellikle bu kapsamlı çalışmada, bu tekniğin daha fazla benimsenerek sağlık hizmetlerinin kurumsal karar almasında YSA'nın temel özellikleri ve itici güçlerinden bahsedilmiştir [Shahid et al., 2019].

Enerji kaynakları, pazarlama gibi ekonomi alanında yapılan çalışmalarda da yapay sinir ağları kullanılmaktadır. Meireles et al., [2003] tarafından yapılan bir çalışmada, endüstri sektöründeki endüstriyel yöntemi yardımcı olmak amacıyla YSA'ların kullanımı kapsamlı olarak araştırılmıştır. Bunların yanında YSA'lar bankacılık uygulamalarında, pazarlama ve finans sektörü gibi birçok alanda kullanılmaktadır [Abiodun et al., 2018]. Ayrıca başka bir çalışmada rüzgâr, hidrolik ve diğer enerji kaynaklarının tahmin problemlerinde yapay sinir ağları kullanılmıştır [Babatunde et al., 2020].

3.5. Uzaktan Algılamada Yapay Sinir Ağları

YSA'lar uzaktan algılanmış uydu verilerinin işlenmesi için önemli bir potansiyele sahiptir [Foody et al., 1994]. Uydu görüntülerin analiz edilmesi veya işlenmesi için birçok teknik ve yöntem geliştirilmiştir. Bu geliştirilen teknikler uydu görüntüsü sayısının fazla olması ve bu görüntülerin büyük olması nedeniyle YSA'lar görüntü işlemleri için uygundur [Sheldon, 1990]. İstatistiksel yöntemlere göre YSA'ların tahmin etme ve sınıflandırma gibi uygulamalarda daha iyi sonuç verdiği gözlenmiştir. Ancak bu sonuçların istenilen seviyede olabilmesi için YSA'larda yapılacak işleme göre uygun bir ağ mimarisi ve algoritma seçimi büyük önem taşımaktadır [Mammadov et al., 2006]. YSA'lar uzaktan algılama görüntü sınıflandırması veya obje tespiti için popüler olarak kullanılan bir yöntemdir [Atkinson and Tatnall, 1997]. Bu yöntemin popüler olmasının ne büyük nedenlerinden biri ağda oluşan hataları tolere edebilmesidir. YSA'lar tüm veri tipleri için kullanabilmesi de başka nedenlerinden biridir [Dhingra and Kumar, 2019]. YSA'lar parametrik olmayan sınıflandırma yaklaşımı kullanır, bu sebeple, sınıflandırma doğruluğunu artırmak için sınıflandırma işlemine ek verilerin dahil edilmesi kolaydır [Lu and Weng, 2007]. YSA, eğitim esnasında eğitim veri setinde bulunan özellikleri öğrenir ve ardından geri kalan verilere uygulayabileceği kurallar oluşturur. YSA'ların karmaşık veri seti ile daha iyi sınıflandırma yaptığı gözlenmiştir [Salah, 2017]. İyi sınıflandırma sonuçları için sinir ağının, ağ mimarisinin ve ağ parametrelerinin en iyi şekilde belirlenmesi gerekir

[Kavzoglu and Mather, 2003]. YSA'lar ile arazi sınıflandırması, değişim analizi, bulut sınıflandırma, obje tespiti, ön işlem adımları, hava durumu ile ilgili tahmin çalışmaları yapılabilmektedir [Mas and Flores, 2008]. Ayrıca bir YSA türü olan derin öğrenme ağlarıyla ilgili uzaktan algılama uygulamaları dördüncü bölüm Derin Öğrenme başlığı altında ayrıntılı olarak verilmiştir. Genel olarak bu bölümde, uzaktan algılamada YSA uygulamaları üç başlık halinde incelenmiştir.

3.5.1. Arazi Örtüsü/Kullanımı Sınıflandırılması ve Değişim Analizi Uygulamaları

YSA yıllardır birçok farklı çalışma alanı için uygulanan görüntü sınıflandırma algoritmalarının geliştirilmesinde yararlı olmuştur. Görüntü sınıflandırması, arazi kullanımı ve örtüsü gibi önemli mekânsal değişken parametrelerini çıkartmak için kullanılmaktadır. Sınıflandırma alanında, YSA'ların gücü, hızı ve performansı kullanıcıyı tatmin eden sonuçlar vermenin yanında kendi kendine öğrenme yeteneği olduğu için yaygın olarak kullanılmaktadır [Pradhan et al., 2010]. YSA'lar otomatik sınıflandırıcı olarak kullanılabilir ancak bu sinir ağlarının parametrelerinin belirlenmesi oldukça zorlu bir süreçtir. Bu sebeple, bu konuyla ilgili çok fazla deneyime sahip olunması gerekmektedir. Bu konuyla ilgili gelecek çalışmalara rehber olma amaçlı çalışmalar yapılmaktadır [Zhou and Yang, 2008].

YSA'lar veri dağıtımı hakkında bir hipotez gerektirmeden uydu görüntülerini sınıflandırmak için kullanılan değerli bir araçtır. Bir çalışmada arazi örtüsü sınıflandırması yapmak için NDVI ve EVI indekslerinin yanında Kırmızı ve Yakın Kızılötesi bantları gibi farklı girdi değişkenleri kullanılmış ve bu verileri değerlendirmek içinde bir sinir ağı modeli geliştirilmiştir ve sınıflandırma işlemi yapılmıştır. YSA'nın sınıflandırma performansında iyi sonuçlar verdiği gösterilmiştir [Bocco et al., 2007]. Başka bir çalışmada, Arjantin'deki sığ gölleri karakterize etmek ve bulanıklık seviyelerini ölçmek için Landsat görüntü setleri kullanılmıştır. Tasarlanan YSA modeli, çalışma alanındaki gölün askıda katı madde gibi içeriklerini incelemek için kullanılmıştır. YSA modelinin bu çalışma için en etkili bir araç olduğu kabul edilmiştir [Canziani et al., 2008]. Bu konuyla ilgili yapılan bir çalışmada YSA'ların Arazi Kullanımı/Örtüsü Haritalarının oluşturulup oluşturulmayacağı irdelenmiştir. Bu çalışmada geri yayılım ile prensibiyle çalışan çok katmanlı bir ağ tasarlanmıştır. İlk olarak bu ağın eğitim modeli oluşturması, ağ eğitimi ve ağ

genelleme görevlerini başarıyla yerine getirdiği gözlenmiştir. Ardından geleneksel sınıflandırma yöntemlerine göre YSA'ların sınıflandırma konusunda daha yararlı bir yöntem olduğu vurgulanmıştır [Yuan et al., 2009]. Yapılan bir çalışmada geri yayılım algoritması, Maksimum Olabilirlik algoritması, ISODATA ve K-ortalama algoritması gibi farklı sınıflandırma algoritması kullanılarak bir çalışma yapılmıştır ve çalışmada sınıflandırma doğrulukları karşılaştırılmıştır [Mahmon and Ya'Acob, 2014]. Moğolistan'daki Orman Çiftliği için yapılmış çalışmada geri yayılım algoritması kullanan bir yapay sinir ağı modeli tasarlanmış ve Orman alanının kalite değerlendirmesi yapılmıştır. Geleneksel yöntemlere göre doğrulukta %9,83'lük bir artış olduğu sapmıştır [Yan et al., 2015]. Başka bir çalışmada ise aynı şekilde geri yayılım yöntemi kullanılarak bir sinir ağı tasarlanmış ve ardından görüntü sınıflandırması için kullanılmıştır. Ayrıca bu çalışmada yardımcı veri olarak yükseklik modeli ve bitki indeksleri kullanılmıştır. Bu çalışmada üretilen tematik haritanın avantajlı ve dezavantajlı yönlerini incelemek için bir de geleneksel yöntemli kontrollü sınıflandırma yapılmış ve bu sonuçlar karşılaştırılmıştır [Zhang and Chang, 2015].

Yeryüzünde meydana gelen değişiklikleri tespit etmek, anlık gelişebilen doğal afetleri tahmin etmek ve bu durumlara karşı önlem almak için değişim tespit çalışmaları yapılmaktadır. Yeryüzünden bu verileri toplamak için uzaktan algılama yaygın olarak kullanılan bir bilim dalıdır. Makine öğrenimi tabanlı yaklaşımlar değişik algılama konusunda daha yüksek doğruluk sağlamaktadır [Radhika and Varadarajan, 2018]. Bu konuyla ilgili yapılan çalışmada ise uydu görüntülerinde değişim analizi için yapay sinir ağı önerilmiştir. Oluşturulan makine öğrenmesi algoritması ile otomatik bir şekilde arazi örtüsündeki değişiklikleri tespit edilebilmektedir. Çalışma sonucunda %95,6'lık genel doğrulukla arazi örtüsü değişiklikleri tespit edilmiştir. Ayrıca, aynı çalışma alanına ait görüntüler kullanılarak kontrollü maksimum olabilirlik sınıflandırması da yapılmış ve %86,5'lik bir doğruluk elde edilmiştir. Bu iki sınıflandırma sonuçları karşılaştırılmıştır [Dai and Khorram, 1999]. Başka bir çalışmada ise zaman tahmin serisi kullanılarak çalışma alanındaki bitki örtüsünde gerçekleşen ani değişiklikleri tespit eden bir sinir ağı modellenmiştir. Çalışmada kullanılan sentetik veriler EVI indeksi ile üretilmiş ve sinir ağı bu veri setine uygulanmıştır. Ardından, nicel ve nitel analiz teknikleri ile önerilen yaklaşımın performansı incelenmiştir. Ayrıca önerilen performansın sonucu, daha önce bu alanda kullanılan yöntemlerle karşılaştırılmıştır [Panigrahi et al., 2019].

YSA'lar arazi kullanımı/örtüsü ile ilgili tahmin çalışmalarda da kullanılmaktadır. Bu konuyla ilgili yapılan bir çalışmada arazi örtüsü/kullanımı haritaları oluşturularak bu bölgenin yönetimini etkileyen faktörler incelenmiştir. 1996 ve 2006 yılları arasında olan değişimler YSA analizi ile incelenerek gelecekteki arazi örtüsü/kullanımı senaryoları simüle edilmiştir. Sonuç olarak bu çalışmada sulak ve orman alanında bir kayıp olacağı öngörülmektedir. Böylece bu çalışma bölgesinin daha iyi planlaması ve yönetimi için karar verici kişilere faydalı bilgiler sağlanmıştır [Qiang and Lam, 2015]. Türkiye'nin Kuzeybatısında yer alan bölgenin 1997 ile 2007 arasındaki yıllara ait arazi örtüsü haritası çıkartılmıştır. Bu çalışmada nüfus faktörü de göz önüne alınmıştır. Bu yıllar arasındaki değişimler tespit edilmiş ve ardından 2027 yılında arazi örtüsünün nasıl değişeceği YSA yaklaşımı ile değerlendirilmiştir. Değişimi tespit edilen bölgeler YSA'da eğitim verisi olarak kullanılmış ve sonuçları incelenmiştir. Nüfus hareketleri beraber gözlemlenerek YSA'ların planlama gibi faaliyetlerde kullanılması önerilmiştir [Buğday ve Buğday, 2019]. Değişim analizi yapılan başka bir çalışmada ise 2005 ve 2012 arasında Türkiye'de bulunan bataklık alanları incelenmiştir. Bu çalışmada ASTER uydu görüntüsü ve Maksimum olabilirlik, çok katmanlı sinir ağı ve destek vektör makineleri sınıflandırma yöntemleri kullanılmıştır. Sınıflandırma işlemleri bu üç farklı yöntemle ayrı ayrı gerçekleştirilmiş ve karşılaştırması yapılmıştır.

3.5.2. Karışık Piksel Uygulamaları

Küresel veya kıtasal ölçekte arazi örtüsü sınıflandırması yapılırken kullanılan uydu görüntülerinin mekânsal çözünürlükleri sınırlı olmaktadır. Bu gibi çalışmalarda çözünürlükleri farklı olan uydular birlikte kullanılabilir. Ancak bu durum ise farklı mekânsal çözünürlüklerle baş edilmesi gerekir [Mas and Flores, 2008]. Kısaca ortaya çıkan problemi tanımlamak gerekirse, orta çözünürlükteki bir uydu görüntüsündeki tek bir piksel içerisinde birden fazla farklı arazi örtüsüne ait obje bulundururken, mekânsal çözünürlük arttıkça bu farklı arazi örtüsüne ait pikseller ayrı ayrı gösterilebilir. Bu karışık piksel sorununu çözmek için birçok teknik önerilmiştir. Bunların başında doğrusal regresyon tabanlı teknikler gelmektedir [Bastin, 1997]. Ancak bu gibi çalışmalarda doğrusal tabanlı yaklaşımların uygun olmadığı ve bu

yaklaşımların yerine YSA'ların daha yararlı olabileceği vurgulanmıştır [Mas and Flores, 2008].

Karışık pikseller uzaktan algılanan verilerin analizinde önemli bir problem olabilir [Foody and Mathur, 2006]. Örnek olarak, bir arazi örtüsü sınıflandırmasında piksellerin saf olduğunu varsayılır ve her bir pikse tek bir arazi sınıfına atanır. Ancak, karışık piksellere böyle bir sınıflandırma uygulaması yapıldığı zaman yeryüzünde temsil etmesi gereken arazi sınıfını temsil edemez. Bu durum ise sınıflandırmada hatalı tahminlere yol açmaktadır [Foody, 1996]. Bu konuyla ilgili bir çalışmada, Landsat uydu görüntüsü hem maksimum olabilirlik hem de YSA yaklaşımı ile sınıflandırılmış ve karşılaştırılmıştır. Bu çalışmada, iki yaklaşım içinde aynı eğitim ve test veri seti kullanılarak sekiz arazi örtüsü/kullanımı sınıfı içeren birer tematik harita üretilmiştir. Bu çalışmayı, diğer çalışmadan ayıran en büyük özellik eğitim veya test veri seti için seçilen birçok pikselin, karışık piksel özelliğe sahip olmasıdır. YSA ile gerçekleştirilen sınıflandırma işlemini, diğer geleneksel sınıflandırma işlemine göre daha iyi performans gösterdiği belirtilmiştir [Kavzoglu and Reis, 2008]. 2010 yılında gerçekleştirilen başka bir çalışmada ise çok katmanlı algılayıcı kullanarak sınıflandırma esnasında oluşan piksellerdeki spektral karışmayı engelleyen bir uygulama yapılmıştır. Bu çalışmada ise CHRIS - PROBA uydusunun hiper-spektral görüntüleri kullanılmıştır ve doğrusal yöntemlerle sonuçlar karşılaştırılmıştır [Licciardi and Frate, 2010]. Başka bir çalışmada ise yapay sinir ağlarının bir kolu olan derin öğrenme ağı, hiperspektral görüntü sınıflandırması için kullanılmıştır. Salinas veri seti kullanılan bu çalışmada, eğitim setini karışık pikseller oluşturarak büyütme amaçlanmıştır. Daha fazla eğitim verisi sağlamak amacıyla farklı miktarlarda karıştırma oranları kullanılmıştır [Ball and Wei, 2018]. Ayrıca yapılan diğer bir çalışmada ise Maksimum Olabilirlik algoritması ile YSA algoritması karşılaştırılmıştır ve bu karşılaştırma sonucunda sınıflandırma esnasında oluşabilen karışık piksel probleminin YSA ile azaltılabileceği gösterilmiştir. Bunlardan yanında üretilen tematik haritaların doğruluğu YSA ile üretilende daha yüksek çıkmıştır [Mustapha et al., 2010].

3.5.3. Obje Tespiti Uygulamaları

YSA'lar uzaktan algılanmış görüntülerde nesne/obje tanıma ve tespiti için yaygın olarak kullanılmaktadır. Ancak bu konuyla ilgili hala eksik noktalar bulunmaktadır ve bilim insanları bu noktalara yoğunlaşmakta ve bunlarla ilgili bilimsel çalışmalarını sürdürmektedir. Bu konuyla ilgi yapılmış çalışmalar bir derleme makale toplanmış ve detaylı şekilde tartışılmıştır [Cheng and Han, 2016]. Obje tespiti konusunda genellikle, yol, bina, araç, gemi ve havaalanı gibi nesneler tespit edilmesi hedeflenmiştir.

Literatürde bu gibi çalışmaları gerçekleştirmek için bilim insanlarına veya araştırmacılara açık veri setleri paylaşılmıştır ve konuda yapılan çalışmalarından arttırılması hedeflenmiştir. Obje tespiti ile ilgili yapılan bir çalışmada uydu görüntüleri ile birlikte görüntü içindeki nesnelerin özelliklerini öğrenen ve bu özellikleri kullanarak diğer nesnelerden ayıran bir algoritma kullanılmıştır. Bu çalışmada görüntü içinde bulunan göl, nehir gibi su kütlelerinin, insanın herhangi bir müdahalesi olmadan uydu görüntülerinden otomatik olarak tespit edebilen birçok katmanlı olan bir YSA tasarlanmıştır. Çalışma sonunda doğruluk değerlendirmesi için hata matrisi ve Kappa katsayısı hesaplanmıştır. Ayrıca YSA'nın doğruluğunun büyük ölçüde eğitim veri kümesinin kalitesine bağlı olduğu belirtilmiştir [Goswami, 2014]. Başka bir çalışmada ise uzaktan algılanmış ortofotolar kullanılmış ve görüntülerde kentsel alandaki ağaçlar tespit edilmeye çalışılmıştır. YSA'nın bir türü olan Evrimsel Sinir Ağının girdi verisi olarak Almanya'daki bir şehrin sokak ağacı envanteri kullanılmıştır. Sonuç olarak ağaç cinslerinin sınıflandırılmasında %72'lik bir doğruluk elde edilmiştir [Haas et al., 2016]. Başka bir çalışmada orman yangınlarından çıkan dumanı tanımlamak için YSA tabanlı bir algoritma oluşturulmuştur. Çok eşikli olan bu algoritma, görüntüde bulunan duman, bulut veya açık hava şeklinde sınıflandırma yapmayacak aynı zamanda bu nesnelerin karışımını temsil eden sürekli çıktılar üretecek şekilde tasarlanmıştır. Bu çalışmada AVHRR görüntüleri kullanılmıştır [Li et al., 2001].

Yapılan başka bir çalışmada, uydu görüntülerinden sinir ağlarına dayanan bir yol algılama modeli önerilmiştir. Oluşturulan bu model, sınıflandırma ve tahmin problemlerinde en çok tercih edilen YSA mimarilerinden biri olan Çok Katmanlı Algılayıcıya dayanmaktadır. Görüntünün kırmızı-yeşil-mavi değerleri pikselin yola ait olup olmadığına karar vermek için kullanılır ve bulunan yol pikselleri çıktı

görüntüsünde işaretlenmiştir [Kahraman vd., 2015]. Başka bir çalışmada ise yasadışı petrol döküntüsü tespiti uygulaması yapılmıştır. Bu çalışmada Sentetik Açıklıklı Radar görüntüleri ile birlikte YSA'nın bir türü olan Radyal Temelli Fonksiyon (RTF) içeren Sinir Ağı kullanılmıştır ve önceki çalışmalarda kullanılan çok katmanlı algılayıcı olan sinir ağına performans karşılaştırılmıştır. Sonuç olarak, SAR görüntülerinde petrol tespit etmede çok katmanlı algılayıcıların RTF'ye göre daha iyi performans gösterdiği görülmüştür [Topouzelis et al., 2004]. Son yıllarda bu alanda yapılan çalışmaların çoğunda YSA'nın bir alt kümesi olan derin öğrenme teknikleri yaygın bir şekilde kullanılmıştır. Bu durum literatür araştırması ile desteklenebilir. Örneğin, bir çalışmada Evrişimsel Sinir Ağı kullanılarak özellik çıkarımı ve sınıflandırma performansı ile nesne algılama probleminin çözülmesi hedeflenmiştir. Bu nedenle, araç tespit eden bir ağ tasarlanmıştır ve nesneye ait özellikler istatistiksel hesaplamalarla belirlenmiştir. Ayrıca literatürdeki diğer ağlar ile oluşturulan sinir ağlarının karşılaştırılması yapılmıştır [Yang et al., 2018]. Bu konuyla ilgili çalışmalar birçok konuda çeşitlendirilebilir. Sonuç olarak bu bölüm derin öğrenme kısmında daha ayrıntılı olarak verilmiştir.

4. DERİN ÖĞRENME

4.1. Yapay Sinir Ağlarından Derin Öğrenmeye Tarihsel Bakış

Yapay zekanın, insan hayatına girmesi ile sinir ağlarını ve derin öğrenme çalışmalarında büyük gelişmeler yaşanmıştır. Google'un ürettiği, akıllı ses asistanları, sürücüsüz araba, yapay zekadaki son yapılan çalışmalardır. Derin öğrenme, makine öğrenmesinin bir alt kümesi olmakla beraber makine öğrenmesi de yapay zekanın bir alt kümesidir (Şekil 4.1). Derin öğrenme, nesne algılama, konuşma tanıma, yüz tanıma, makine çevrisi gibi birçok farklı alanda kullanılan yapay zekâ ile en son teknolojiyi önemli ölçüde etkilemiştir [LeCun et al.,2015]. Derin öğrenme mimarisi kullanılarak karmaşık yapay zekâ problemlerini çözmeye imkânı sağlamaktadır. Derin öğrenmeyi, geleneksel makine öğrenme metotlarından ayıran en temel özellik, insan yardımı olmadan görüntü, ses veya metin veri setlerinden otomatik bir şekilde temsillerini öğrenebilmesidir. Derin öğrenme mimarilerinin yapıları esnek olduğu için ham verilerden özellik öğrenmenin yanında, veri sayısı arttıkça öngörme doğruluğu da artmaktadır. Derin öğrenme konusunun bu kadar yaygın kullanılmasının başlıca sebeplerinden biri bilgisayarlara ait GPU (Graphics Processing Unit) donanımlarının hızının artmasıdır.



Şekil 4.1: Derin öğrenme, makine öğrenmesi ve yapay zekâ arasındaki ilişki.

Derin öğrenme, yapay sinir ağlarının gelişmesinin ardından ortaya atılmış bir kavramdır. Hayatımıza ilk kez giren yapay zekâ kavramı, derin öğrenme ve yapay sinir

ağları araştırmalarını büyük ölçüde etkilemiştir. Bu da bilim insanları arasında büyük bir rekabet ortamı olmuştur. 1990 yılında LeCun tarafından LeNet mimarisi oluşturulmuştur ve derin öğrenme ile ilgili uygulamalar yapılmıştır. Yapay sinir ağlarının gelişmesinin yanında Dana Cortes ve Vladimir Vapnik tarafından 1995 yılında destek vektör makineleri geliştirilmiştir [Cortes and Vapnik, 1995]. Derin öğrenme uygulamalarında en önemli adım, bilgisayarların grafik işlem birimleri (GPU) gelişmesidir. GPU'ların gelişmesi bu noktada önemli bir adım olmuştur. Çünkü görüntü veri setleri kullanılarak oluşturulan derin öğrenme modellerinin öğrenme hızını artmıştır. Bu aşama sonrasında destek vektör makineleri, yapay sinir ağları ile yarışmaya başlamıştır. Bu aşamalardan sonra Schmidhuber ve Hochreiter tarafından tekrarlayan sinir ağ yapısına sahip olan uzun/kısa-sürelili hafıza (Long Short-Term Memory) üretilmiştir. Bu sinir ağı ile problem çözme verimliliğini artmıştır [Hochreiter and Schmidhuber, 1997]. Derin öğrenmedeki diğer önemli avantaj ise LeCun tarafından ifade edilmiştir. Sonrasında rastgele gradyan iniş algoritması ile geri yayılım algoritması birleştirilmiştir. Böylece derin öğrenmeye dair başarılı bir yaklaşım için bir adım daha atılmıştır [LeCun et al., 1998]. Ardından, 2009 yılında Stanford Üniversitesindeki bilim insanları, yapay sinir ağ uygulamalarında kullanmak üzere oluşturulmuş çok miktarda etiketli görüntüler içeren ImageNET verisetini araştırmacılara sunmuştur [Deng et al., 2009]. Daha sonraki çalışmalarda ise uluslararası makine ve derin öğrenme yarışmalarında başarı elde eden AlexNet ilk üretilen evrimsel sinir ağı modeli olarak literatüre geçmiştir [Krizhevsky et al., 2017]. Böylece, yapılan bu uygulamalar ve üretilen sinir ağları ile modern derin öğrenme dönemi başlamıştır.

4.2. Derin Öğrenme Yaklaşımları

Derin öğrenme yaklaşımları, kontrollü (supervised), yarı kontrollü (semi-supervised) ve kontrolsüz (unsupervised) olacak şekilde üç grupta kategorize edilebilir. Bunlara ek olarak, başka bir yaklaşım olan Pekiştirmeli Öğrenme (Reinforcement Learning) yaklaşımı da yarı kontrollü veya kontrolsüz öğrenmenin bir alt dalı olarak geçmektedir. Kontrollü derin öğrenme, eğitim esnasında etiketli veriyi kullanan bir yaklaşımdır. Ağıdaki parametreler daha iyi bir tahmin için tekrar tekrar değişmektedir. Derin Sinir Ağı (Deep Neural Network), Evrimsel Sinir Ağı

(Convolutional Neural Network), Tekrarlayan Sinir Ağı (Recurrent Neural Network) bu yaklaşım içinde yer almaktadır. Yarı kontrollü öğrenme, kısmen etiketlenmiş veri kümelerine dayalı olarak gerçekleşen bir metottur. Bu yaklaşım etiketli verinin yeterli gelmemesi halinde kullanılır [Kuznietsov et al., 2017]. Çekişmeli Üretici ağlar (Generative Adversarial Networks) bu metoda örnek olarak verilebilir. Kontrolsüz derin öğrenmede ise veri setine ait etiket bilgisi kullanmadan gerçekleştirilen bir öğrenme sistemidir. Bu yaklaşımda etiketli veri olmadığı için sinir ağının girdilere ait temsili parametreleri ve önemli özellikleri keşfetmesi gerekir. Genellikle kümeleme, boyut azaltma gibi teknikler kontrolsüz öğrenme yaklaşımının içine girmektedir [Alom et al.,2019].

4.3. Derin Öğrenme Modelleri

Oluşturulan ilk derin öğrenme modelleri üzerinde önemli gelişmeler olmuştur. Derin öğrenme yaklaşımı, mühendislik, sağlık, güvenlik gibi birçok alanda kullanımı genişlemiş ve yayılmıştır. Böylece araştırmacılar tarafından derin öğrenmeye olan ilgi büyük ölçüde artmıştır ve literatürde birçok derin öğrenme modelleri, yapılan çalışmanın amacına göre çeşitlendirilmiştir. Gürültü Giderici Otomatik Kodlayıcı (Denoising Autoencoder), Tekrarlayan Sinir Ağları (Recurrent Neural Networks), Derin İnanç Ağları (Deep Belief Networks), Uzun Kısa Vadeli Bellek (Long Short-Term Memory) ve Evrimsel Sinir Ağı (Convolutional Neural Network) en popüler olan derin öğrenme modelleridir [Mosavi et al., 2019].

4.3.1. Gürültü Giderici Otomatik Kodlayıcı

Gürültü giderici otomatik kodlayıcılar (Denoising Autoencoder) gürültülü veri setlerinin özelliklerin ile üç ana katmandan oluşur [Mosavi et al., 2019]. Bu sinir ağları, özellik çıkarımın yayınında sınıflandırma işlemleri ve görüntüden gürültü ayıklamak için de kullanılmaktadır. Literatürdeki bir çalışmada, bu derin öğrenme ağı konuşma geliştirmek için kullanılmıştır. Bu çalışmanın amacı temiz konuşma çıkartmaktır [Lu et al., 2014].

Uzaktan algılama konusunda yapılmış bir çalışmada, sınıflandırma yapmak için gürültü giderici otomatik kodlayıcı ile bir sinir ağı oluşturulmuştur. Bu çalışmadaki

sinir ağıının eğitim için kontrolsüz sınıflandırma işlemi gerçekleştirilmiştir ve geri yayılım algoritması ile modelde oluşan hatayı gidermek için sinir ağı optimize edilmiştir. Bu derin öğrenme çeşidinin kullanılmasının en önemli tarafı, objeye veya sınıfa ait özellikleri iyi bir şekilde çıkartabilmesi ve daha yüksek sonuç vermesidir. Bu da gürültünün verilere eklenmesi ile daha sağlam bir model oluşmasını sağlamaktadır [Liang et al., 2017]. Ayrıca başka bir çalışma ise hiperspektral görüntüler kullanılarak bu sinir ağı ile bir sınıflandırma işlemi gerçekleştirilmiştir. Bu çalışmada veri çoğultma işlemi yapılmış ve karışık pikseller üretilmiştir. Böylece yapılan sınıflandırma işleminin yüksek bir performans gösterdiği belirtilmiştir [Ball and Wei, 2018]. Diğer bir çalışmada ise hiperspektral görüntünün yapısını bozmadan gürültü gidermek için bir sinir ağı tasarlanmıştır. Oluşturulan model ile modelin sinyal-gürültü oranı ve görüntü kalitesi indeksi gibi kapsamlı olarak değerlendirmesi amaçlanmıştır [Shivakumar and Prakash, 2018]. Kısacası gürültü giderici otomatik kodlayıcı sinir ağları birçok konuda yaygın olarak kullanılmaktadır.

4.3.2. Tekrarlayan Sinir Ağları

Tekrarlayan sinir ağları (Recurrent Neural Networks) konuşma, el yazısı gibi uygulamalarda dizi ve kalıpları tanımak için kullanılmaktadır. Bu sinir ağları, giriş verilerini sırayla işlemek için tekrarlayan hesaplamalar kullanan yapıdaki tekrarlanan bağlantılardan yararlanır. Kısaca bu sistemle, her hücreden bir geri bildirim alırlar. Bu sinir ağları, ekonomi ile ilgili tahmin uygulamalarında ve enerji uygulamalarında kullanılmıştır [Mosavi et al., 2019]. Uzaktan algılama ise bu konuyla ilgili yapılan çalışmada UC-Merced veri seti kullanılarak arazi kullanımı/örtüsü haritası oluşturulmuştur. Tekrarlayan sinir ağı modeli ile üretilen haritanın doğruluğu %97,29 olarak bulunmuş ve diğer metotlarla üretilen tematik haritaların doğrulukları karşılaştırılmıştır. [Lakhal et al., 2018]. Başka bir çalışmada ise tarımsal arazi örtüsünü haritalamak için tekrarlayan sinir ağı modeli kullanılmıştır. Bu çalışmanın diğerlerinden en büyük farkı radar görüntüsünün kullanılmasıdır. Bu derin öğrenme metodunun yanında bir de DVM ve en yakın komşuluk sınıflandırma gibi klasik makine öğrenme metotları kullanılmıştır. Ancak bu çalışma sonucunda derin öğrenme yaklaşımının daha yüksek performans sergilediği gösterilmiştir. Özellikle pirinç sınıfının %96 F-skor doğruluğu ile tekrarlayan sinir ağının daha yüksek doğruluk

verdiği gözlenmiştir ve bu sinir ağının uzaktan algılama zaman serilerinin analizinde önemli bir rol oynayacağı vurgulanmıştır [Ndikumana et al., 2018]. Diğer bir çalışmada ise hiperspektral görüntü piksellerini sıralı veri olarak etkin bir şekilde analiz edebilen ve ardından oluşturulan ağın akıl yürütmesi yoluyla arazi sınıflarının belirleyebilen bir model tasarlanmıştır. Ayrıca bu çalışmada, ardışık veri analizi için yeni bir aktivasyon (PRetanh) fonksiyonu önerilmiştir. Önerilen aktivasyon fonksiyonu, eğitim aşamasında sapma riski olmadan oldukça yüksek öğrenme hızı kullanılmasına olanak sağlamıştır [Mou et al., 2017]. Hiperspektral görüntü içeren başka bir çalışmada ise bir verileri analiz etmek için bir adet tekrarlayan sinir ağı önerilmiş ve geleneksel öğrenme metotlarına göre F-skor doğruluklarını daha yüksek olduğu belirtilmiştir [Venkatesan and Prabu, 2019]. Ayrıca, tekrarlayan sinir ağları nesne tespiti çalışmalarında da tercih edilmektedir. Özellikle, evrimsel sinir ağlarının nesne ana hatlarını çıkartması konusunda yetersiz kaldığı durumlarda, tekrarlayan sinir ağları kullanılmaktadır. Bu ağ modelinde, yinelemeli gerçekleşen eğitim doğrudan izlenilebildiği için tekrarlayan sinir ağı tercih edilmiştir. Böylece bu çalışmada, görüntülerin sınıflandırılması sonucu üretilen haritanın doğruluğunu önemli ölçüde arttırdığı gözlenmiştir [Maggiori and Charpiat, 2017].

4.3.3. Derin İnanç Ağları

Derin inanç ağları (Deep Belief Networks) diğer sinir ağlarına göre daha fazla katman ve kısıtlı Boltzmann makinelerini içerir. Bu sebeple, bu sinir ağı karma çok katmanlı bir yapıdır. Bu Boltzmann makineleri hem önceki hem de sonraki katmanlarla iletişim kurar [Hinton, 2009]. Bu sinir ağı hesaplama verimliliği ve yüksek doğruluk ile en güvenilir derin öğrenme modellerinden biridir. Bu özelliklerinden dolayı birçok mühendislik ve bilimsel alanda çeşitli uygulamalarda kullanılmaktadır. Bu uygulamalara, duygu tespiti, enerji tahmini, zaman serisi tahmini, kanser teşhisi ve kamusal uygulamalar örnek olarak verilebilir [Mosavi et al., 2019]. Bir uzaktan algılama uygulamasında, hiperspektral verilerin sınıflandırılması için Derin İnanç Ağını içeren bir derin öğrenme mimarisi kullanılmıştır. Bu ağ türü, ağ boyutunun ve ön-eğitim süresindeki etkin rolü, spektral verilerin çok arazi sınıfını birbirinden ayıran özelliklerin öğrenebilmesi nedeniyle seçilmiştir. Çalışmanın devamında ise sınıflandırma aşamasında hem spektral hem de mekânsal bilgilerin bir arada

kullanılması incelenmiştir. Ardından aynı görüntü için DVM kullanılmış ve derin inanç ağı ile üretilen tematik haritaların doğrulukları performansları karşılaştırılmıştır. Sonuç olarak, derin öğrenme ağı ile oluşturulan sınıflandırma sonucunun doğruluğunun daha yüksek olduğu gözlenmiştir [Le et al., 2015]. Başka bir çalışmada, çok değişkenli optik sensörlere dayanan ve kısıtlı Boltzmann makineleri tarafından istiflenmiş derin inanç ağı ile hiperspektral görüntü sınıflandırılma işlemi gerçekleştirilmiştir. Bir önceki çalışmada olduğu gibi sınıflandırma prosesi için hem mekânsal hem de spektral özellikler bir arada kullanılmıştır. Modelin eğitim aşamasında, ilk olarak oluşturulan ağa kontrolsüz ön eğitim yapılmış ardından ortaya çıkan sonuçlara göre ağ modelinde ince ayar yapılarak kontrollü öğrenme aşaması gerçekleştirilmiştir. Ayrıca sınıflandırma işlemi için son aşamaya lojistik regresyon katmanı da eklenmiştir. Genel olarak çalışma değerlendirildiğinde ön plana çıkan en önemli avantaj; ağ, derin bir yapıya sahip olduğu için özellik haritası çıkartma konusunda geleneksel yöntemlere göre daha iyi olduğunu belirtilmiştir [Li et al., 2019]. Derin inanç ağları sadece sınıflandırma işlemleri için değil nesne tespiti gibi uygulamalarda da kullanılmaktadır. Bununla ilgili bir çalışmada nesne tanımak için derin inanç ağlarına dayalı yeni bir piksel bazlı öğrenme yaklaşımı önerilmiştir. Bu çalışmada da eğitim aşaması hem kontrolsüz hem de kontrollü olarak üzere iki adımda gerçekleştirilmiştir. Ayrıca modelin eğitimi esnasında piksel olarak denetlenmeyen bir özellik öğrenme algoritması kullanılmıştır. QuickBird görüntüsü kullanılarak gerçekleştirilmiş bu çalışmada kullanılan yöntemin, doğruluğu ve verimliliği gösterilmiştir [Dai et al., 2020].

4.3.4. Uzun Kısa Vadeli Bellek

Uzun Kısa Vadeli Bellek (Long Short-Term Memory) derin öğrenme modeli, görüntü ve görüntü işleme uygulamalarında sıklıkla kullanılmaktadır. Tekrarlayan sinir ağından türetilmiş özel bir derin öğrenme modelidir. Bu yapıyı özelleştiren en büyük etmen tekrarlanan bilgilerin rastgele olarak seçilmesidir. Tekrarlayan sinir ağından en büyük farkı yapısında görülmektedir. Tekrar eden bölümlerin yapısı biraz daha farklıdır. [Hochreiter and Schmidhuber, 1997]. Uzun kısa vadeli bellek genel olarak, giriş, çıkış ve unutma katmanlarından oluşmaktadır. Bu yapı jeolojik modelleme, hava kalitesi gibi uygulamalarda büyük potansiyele sahiptir [Mosavi et al., 2019]. Ayrıca

bu sinir ağı modeli zaman serilerinde yaygın olarak kullanılmaktadır. Bir çalışmada, ekosistemde meydana gelen değişiklikleri incelemek için bu ağ modeli ile birlikte orman yangınları sonucunda oluşan değişimlerini içeren bir çalışma alanının orta çözünürlüklü görüntüleri kullanılmıştır. Önerilen derin öğrenme modeli, tarihsel zaman serilerinden yeni verileri tahmin etme prensibine dayandırılmıştır. Modelin sonucunda öngörülen veriler ile gerçek gözlem sonucu toplanan verilerle karşılaştırılmıştır ve üretilen tahmin verilerinin iyi bir performans sergilediği gösterilmiştir. Uzun kısa vadeli bellek algoritmasının uyarlanabilirliği ve sağlamlığı nedeniyle, bu yöntem farklı zaman serilerinin analizini desteklemek için genişletilebileceği ve farklı hedeflere göre, bu yöntemin, farklı mekânsal veya zamansal çözünürlüklerin uzaktan algılanan verileri için de özelleştirileceği gösterilmiştir [Kong et al., 2018]. Bu uygulamanın yanında arazi örtüsü harita oluşturulurken yeşil alanların, özellikle tarım ürünlerini içeren alanların, zaman içinde yansıtıcı özelliklerini değiştirerek belirli bir gözlem zamanında yapılacak olan sınıflandırmayı zorlaştırmaktadır. Buna karşılık, bu özellikler çok zamansal bir yaklaşımda değişebileceği için modelinde bu duruma uyum sağlaması gerektiği belirtilmiştir ve Sentinel 2A görüntülerinden zamansal özellikleri elde etmek için uzun kısa süreli bellek (LSTM) ağları kullanılmıştır. Çalışmanın sonucunda, bu ağ modelinin birçok bilim insanı için umut verici olduğu belirtilmiştir [Rubwurm and Korner, 2017].

4.3.5. Evrişimsel Sinir Ağları

Evrişimsel sinir ağları (Convolutional Neural Networks) görüntü/video işleme gibi amaçlarla kullanılan çok katmanlı özel bir sinir ağı türüdür. Bu sinir ağını diğer ağlardan ayıran en önemli fark, ağdaki katmanların her biriminde bir veya daha fazla evrişimsel filtrenin olmasıdır [Khan et al., 2018]. Evrişimsel sinir ağları (ESA) ile görüntü sınıflandırması ve segmentasyonu, obje tespiti, doğal dil işleme, video işleme ve konuşma tanıma gibi uygulamalar yapılmaktadır. ESA'larının kabiliyeti, verileri analiz ederek büyük ölçekte verilere ait özellikleri çıkarma aşamalarında kullanılmasından kaynaklanmaktadır. Bu tip ağların üretilmesinde ve ihtiyaç duyulmasında, teknolojik gelişmenin büyük ölçüde payı mevcuttur. Bu sebeple, kullanım amacına uygun birçok farklı ESA mimarisi oluşturulmuştur. ESA'nın


mimarisinde öğrenme aşamalarını gerçekleştirmek için genel olarak evrimsel katman, doğrusal olmayan işlem fonksiyonları ve diğer alt katmanlar mevcuttur [Khan et al., 2020]. Ayrıca, ESA'lar hem kontrollü hem de kontrolsüz öğrenme algoritmaları ile çalışabilir. Uzaktan algılama uygulamalarında özellikle, ESA kullanılarak sınıflandırılma konusunda birçok çalışma yapılmıştır. Bununla ilgili bir çalışmada görüntü sınıflandırılması için bir ESA mimarisi önerilmiştir. Özellikle, sinir ağındaki kullanılacak uygun parametreleri keşfetmek amacıyla gradyan inişi optimizasyon algoritması kullanılmıştır. Yapılan sınıflandırma çalışmaları sonucunda ESA mimarisinin önemi vurgulanmıştır [Chen et al., 2020]. Sınıflandırma konusunda yapılan başka bir çalışmada ise piksel tabanlı sınıflandırma algoritması prensibi ile çalışan bir ESA modeli önerilmiştir. Bu çalışmada iki aşamalı şekilde derin öğrenme modeli eğitilmiştir. Eğitim hatalı verisi seti ile başlatılmıştır, ardından az miktarda etiketlenmiş veriler kullanılmış ve sınıflandırma işlemi tamamlanmıştır. Bu çalışmada, önceden kullanılan sınıflandırma yaklaşımlarına göre bu derin öğrenme yaklaşımının daha iyi performans gösterdiği ve sınıflandırma doğruluğunun arttığı gözlenmiştir [Maggiori et al., 2017]. Diğer bir çalışmada ise hipespektral görüntülerin sınıflandırılması için derin özellik çıkartma yaklaşımı prensibi ile çalışan bir ESA modeli kullanılmıştır [Chen et al., 2016]. Görüntü sınıflandırması dışında heyecan tespiti gibi çalışmalarda da ESA'lar kullanılmaktadır. Heyelan tanıma uygulaması kapsayan bir çalışmada veri setindeki zamansal ve spektral özellikleri kullanarak bir ESA mimarisi önerilmiştir. Çin'nin bazı bölgelerinde gerçekleşen heyelan olayları girdi verisi olarak kullanılmış ve ESA modeli eğitilmiştir. Ardından Çin'deki başka bir bölgede gerçekleşen heyelan olayı ile oluşturulan ESA mimarisi test edilmiş ve doğrulanmıştır [Wang et al., 2019]. Bunlar gibi birçok çalışma literatürde yer almaktadır.

4.4. Evrimsel Sinir Ağı ve Mimarisi

ESA'lar, normalleştirme (normalization), ortaklama (pooling), seyreltme (dropout) evrimsel (convolution) ve tam bağlı (fully-connected) katmanların çeşitli kombinasyonları ile oluşturulan ileri beslemeli sinir ağlarıdır. Bu katmanlardaki nöronlar arasında bir bağlantı modeli uygulayarak uzaysal yerel korelasyondan yararlanarak öğrenme işlemini gerçekleştirir [Hu et al., 2015].

4.4.1. Evrişimsel Katman ve Çeşitleri

Evrişimsel katman, ESA'nın en önemli birimidir. Bu katmanda, içinde evrişim işlerini yapan filtreler kullanılmaktadır. Böylelikle, bu katman veriye ait özellikleri çıkararak bir özellik harita oluşturmak amaçlı kullanılmaktadır. Bu evrişim filtreleri, sayılardan oluşan bir filtre olarak görülmektedir [Bhandare et al., 2016]. Öğrenme esnasında her bir filtrenin ağırlıkları eğitim sırasında öğrenilir. Bu aşamanın, ilk bölümünde filtreye ait ağırlıklar rastgele olarak seçilmektedir ve ardından modelin içindeki matematiksel işlemde kullanılmaktadır. Evrişimsel filtreler, veri üzerinde kayarak işlemlerini gerçekleştirir. Kısaca görüntünün tamamını, her seferinde birkaç piksel tarayan bir filtre uygulayarak her özellik için sınıf olasılıklarını tahmin etmek üzere bir özellik haritası oluşturan katmandır [Khan et al., 2020]. Şekil 4.2'de evrişimsel filtrenin girdi verisi üzerinde uygulanma şekli gösterilmiştir.



Şekil 4.2: Evrişimsel filtrenin uygulanması.

ESA'lar veri çeşidi ve yapılacak olan işlemlere göre uyarlanabilir yapılardır. Bu sebeple, birçok farklı çeşitte ESA katmanlarının yapısını literatürde görülmektedir.

4.4.1.1. Bir Boyutlu Evrişimsel Katman

Bir boyutu bulunan ve zamansal değerlendirmeler için kullanılabilen basit bir sinir ağı katman çeşididir. Bu katman, çıktı üretmek için tek bir uzamsal veya zamansal

boyut üzerinde katman girişi ile sağlanır. Girdi verisi iki bölümden oluşurken, filtre boyutu ise bir olarak alınır [Web 4, 2019]. Diğer ESA'lara göre verilerdeki basit kalıpları tanımlamak için kullanılır. Bu verilerde konum bilgisi yüksek önemde değil ise 1 Boyutlu (1B) ESA'lar tercih edilebilir. Kısaca, bunlar zaman dizilimi veya sabit uzunluktaki herhangi bir sinyal verisinin analizi için kullanılmaktadır [Kiranyaz et al., 2019]. Bu sinir ağ türü, gerçek zamanlı olarak hızlı ve doğru bir şekilde yapısal hasar tespiti amacıyla kullanılmıştır. Bu çalışmada kullanılan veri seti ivme sinyallerinden oluşturulmuştur. Bu nedenle sisteme başka bir faktör dahil edilmediği için 1B ESA yeterli olduğu belirtilmiştir [Abdeljaber et al., 2017]. Yapılan başka bir çalışmada, 1B ESA'ların temel olarak, ham verileri işleyebilir ve diğer sinir ağ türleri ile birleştirildiğinde hem özellik haritası çıkartabilir hem de sınıflandırma işlemlerini yapabileceği bir sistem oluşturulmuş olur [Kiranyaz et al., 2019]. Bunların yanında, 1B ESA'lar görüntülerde spektral analiz için de kullanılmaktadır. Özellikle hiperspektral görüntülerde 1B ESA'lar kullanılarak piksel tabanlı sınıflandırma yapmak için tercih edilmektedir. Çünkü bu görüntülerin spektral çözünürlüğü yüksek iken mekânsal çözünürlükleri düşüktür. Her piksel, bir istatistiksel modelin sığabileceği, ayrık bir sinyal olan spektral imzaya karşılık gelmektedir [Li et al., 2019].

4.4.1.2. İki Boyutlu Evrişimsel Katman


İki boyutlu olan bu katman genellikle görüntü analizleri için kullanılmaktadır. Bu katmanın 2 boyutlu olarak adlandırılmasının sebebi, örneğin görüntü üzerinde kullanılan evrişim filtreleri 2 boyutlu görüntülerin üzerinde kayarak tüm görüntüyü dolaşır [Bhandare et al., 2016]. Bu katmanın en büyük avantajı diğer ağların veya katmanların yapmadığı filtre kullanarak uzamsal özellikleri veri içinden ayıklayabilmesidir [Zhang et al., 2018]. Bu yapıyı içeren ağlar, görüntü üzerinde obje tespiti, renk dağılımı gibi problemlere çözüm üretebilir. Bu yapıdan oluşturulan ağlarda girdi verisi 3 parametreden oluşmaktadır. Örneğin, bir görüntü ele alındığından, buna ait yükseklik, genişlik ve derinlik, 3 boyutlu girdi verisini oluşturur. 2 Boyutlu (2B) evrişim filtresi ise görüntü üzerinde yükseklik ve genişlik parametrelerinden oluşur. Görüntü derinliği ile filtrenin derinliği aynı kabul edilir [Tao and Xinjie, 2020].

4.4.1.3. Üç Boyutlu Evrişimsel Katman

Bu katman 3 boyutlu evrişim filtresi içermektedir. Özellikle, 3 boyutlu veri setleri için bu yapı kullanılır çünkü bu filtreler veri üzerinde kayarak tüm veriyi filtreden geçirir [Bhandare et al., 2016]. Özellikle manyetik rezonans (MR) görüntülemekten üretilen veri setlerini değerlendirmek için bu yapı tercih edilmektedir [Yamashita et al., 2018]. Sinir ağının eğitimi ve değerlendirilmesi için oluşturulan girdi 4 bağımsız parametreden oluşur. 3 boyutlu görüntülerde yükseklik, genişlik ve derinliğin yanında dördüncü boyut ise renk kanallarının sayısı olduğu belirtilmektedir. Burada kullanılan 3B evrişim katmanı yükseklik, genişlik ve derinlik parametrelerinden oluşurken, girdi verisinin dördüncü boyutu ile aynı olarak kabul edilerek işlem yapılır. Bu katmanı içeren sinir ağıları hiperspektral görüntü analizi için kullanılabileceği gösterilmiştir. Ancak, karmaşık ağ yapısı ile parametre sayısı doğru orantılı olarak artmaktadır. Bunun yanında başka nedenlerle beraber, birçok çalışmada diğer evrişim katmanı veya bu katmanların kombinasyonları hiperspektral görüntüler için kullanılmaktadır [Li et al., 2019].

4.4.2. Ortaklama Katmanı

Verideki her özellik için oluşturulan evrişimsel katmanın çıktısını örnekleme yaparak ölçeklendirir ve önemli bilgileri muhafaza eder. Böylece verideki önemli özellikleri kullanarak işlem yükünü azaltır. Maksimum ve ortalama ortaklama katmanı (Pooling Layer) türleri bu yöntem için de kullanılan özel ortaklama işlemleridir [Lee et al., 2016]. Şekil 4.3'te ortaklama katmanının nasıl uygulanacağına dair bir örnek mevcuttur. Özellik haritasını çıkartmak için çıktı katmanında 4 adet bölümden oluşan bir filtre kullanılmıştır. Girdi katmanındaki veri dörde bölünerek, dörtlü grup içindeki en büyük değer çıktı katmanının bir elemanı olarak kabul edilir. Aslında burada bir eşik değeri belirlenmiştir ve uygulanmıştır. Bu katman ile özellik katmanı oluşturulabilir.



Şekil 4.3: Ortaklama katmanının uygulanması.

4.4.3. Yığın Normalizasyon Katmanı


Sinir ağlarının eğitimi genel olarak karmaşık bir süreçtir. Bunun temel nedeni önceki katmanlarda sürekli olarak parametrelerin değişmesi ve katman girdilerinin dağılımının değişmesinden kaynaklanmaktadır. Bu problem, içsel kovaryans kayması (internal covariate shift) olarak literatürde geçmektedir. İçsel kovaryans kayması, YSA eğitimi esnasında ağıın yakınsamasını engellemektedir [Huang and Yu, 2020]. Örneğin, nesne tespiti için oluşturulan bir veri setinin içeriğinde siyah kedi ve kedi dışında ağaç, kartal, araba gibi nesneler bulunmaktadır ve bu nesneler ikili sınıflandırma için kullanılmaktadır. YSA’da siyah kedi çıktısı 1 olarak adlandırılırken diğer nesnelerin çıktıları ise 0 olarak adlandırılmaktadır. YSA, bu iki nesne sınıfı birbirinden ayırmak için bir özellik harita üretir. Aynı sinir ağından bu sefer farklı renk ve cinsteki kediler ile kedi dışındaki tüm nesnelerin içinde bulunduğu farklı bir veri seti oluşturulmuştur. Bu modelde de kedilerin çıktıları 1 olarak adlandırılırken kedi olmayan nesnelerde 0 olarak adlandırılmıştır. Kullanılan aynı YSA modelinde de ikinci veri setinden ötürü, birinci veri setinde oluşturulan özellik haritası daha farklı olarak üretilmiştir. Bu da içsel kovaryans kayması olarak adlandırılmaktadır [Bjorck et al., 2018].

Bu durumda verinin normalleştirilmesi, katmanlara girecek olan verilerin normalleştirilmesi, ile oluşan bu probleme çözüm bulunabilir. Böylelikle, oluşturulan sinir ağının doğruluğu artırılabilir. Yığın normalizasyonu (Batch Normalization) eğitim hızı artırırken öğrenme oranını da arttırmaktadır. Ayrıca, Ioffe ve Szegedy [2016], ImageNet üzerinde yapılan çalışmada da bu yöntemin iyi performans gösterdiği belirtmiştir. Sonuç olarak, YSA’larda modelin hızını, performansını ve

dayanıklılığını geliřtirmek için kullanılan bir tekniktir. Bu yöntem optimizasyon ve başarımları iyileřtirme yöntemleri içinde de yer almaktadır [Ioffe and Szegedy, 2016].

4.4.4. Düzleřtirme Katmanı

YSA modelini oluřturan katmanlar arasında bulunan özel bir katmandır. Örneğın, iki boyutlu bir özellik matrisini kendisinden sonraki katmanı beslemek için bir boyutlu vektöre dönüřtürür [Jin et al., 2015]. řekil 4.4'te düzeřtirme katmanının (Flattening Layer) nasıl çalıştığı görselleřtirilmiřtir. Buradaki ilk řekil 3x3'lük bir matristir. Matrisin ilk sol elemanından itibaren bařlanarak, matrise ait tüm elemanlar tek boyutlu bir vektöre yani 9x1'lik bir matrise dönüřtürülmüřtür.




řekil 4.4: Düzleřtirme katmanının 2 boyutlu veriye uygulanması ve tek boyutlu vektör yapıda verinin oluřturulması.

Düzleřtirme katmanı, ESA'larda tek boyutlu filtreler kullanılarak oluřturulmaktadır. Bununla ilgili yapılan bir çalışmada düzeřtirilmiř bir model kullanılmıř ve bu model sonucunda çıktı test edilmiřtir. Sonuç olarak bu çalışmada, düzeřtirme katmanı kullanılarak oluřturulmuř YSA'da, 3 boyutlu katmanların yerini alabileceğı gözlenmiřtir. Ayrıca düzeřtirme katmanı ile oluřturulan modelde öğrenme parametrelerinin azalması ile öğrenme hızının arttığı görülmüřtür [Jin et al., 2014].

4.4.5. Seyreltme Katmanı

Seyreltme katmanı (Dropout Layer) genellikle aşırı öğrenmeyi engellemek için kullanılır. řekil 4.5'te de gösterildiğı gibi katmanlar arası seyreltme işlemini gerçekteřtirir, böylece modelin aşırı öğrenmesi engellenir [Srivastava et al., 2014]. řekil 4.5'in ilk resminde tüm ağıın düğümlerinin çalıştığı görülmüřken, ikinci resimde

ise seyreltme katmanının uygulandığı görülmektedir. Çünkü modeldeki tüm katmanların yetkin bir şekilde kullanılması, modelin öğrenmesini ve süreci olumsuz etkileyebilir. Seyreltme işlemi rastgele olacak şekilde gerçekleşir [Hinton, 2014].




Şekil 4.5: Seyreltme katmanının uygulanması. a) Seyreltme katmanı kullanılmadan oluşturulmuş sinir ağ modeli. b) Seyreltme katmanı kullanılarak oluşturulmuş sinir ağ modeli.

Bu katmanın çalışma prensibinde her eğitim aşamasında hangi düğümlerin çalışıp çalışmayacağı olasılık hesabına dayanmaktadır. Seyreltme katmanının kullanılması modelin veri setini ezberlemesi engellenir. Eğer veri setinde ezberleme gerçekleşir ise modelin kötü bir performans gösterdiği söylenmektedir [Kulkarni and Satapathy, 2020].

4.4.6. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonu karar fonksiyonu olarak karmaşık ağ modellerin öğrenmesine yardımcı olur. Öğrenme aşamasında uygun aktivasyon fonksiyonun seçilmesi, öğrenme sürecine yardımcı olur ve bu süreci hızlandırır. Literatürde, birbirlerinden farklı birçok aktivasyon fonksiyonu bulunmaktadır. Bunlar; tanh, softmax, sigmoid, maxout, ReLU ve ReLU'nun farklı varyasyonlarıdır (PReLU, leakly ReLU ve ELU) [Khan et al., 2020]. Şekil 4.6'da bazı aktivasyon fonksiyonları gösterilmiştir [Nwankpa et al., 2018]. Yapılan uygulamaya göre aktivasyon fonksiyonları seçilir. Çünkü ReLU'nun iyi sonuçlar verdiği model de RReLU daha kötü sonuçlar verebilir [Moolayil, 2019].



Şekil 4.6: Bazı aktivasyon fonksiyonlarının grafiksel gösterimi ve özellikleri.

4.4.7. Maliyet Fonksiyonları


Maliyet fonksiyonu (Cost Function), derin öğrenme modelinin eğitimi sırasında modelin tahmini ile ilgili hedefin arasındaki yakınlık ölçüsünü temsil eden belirli objektif işlevi en az seviyeye indirme için kullanılır. Maliyet fonksiyonun, kayıp veya hata fonksiyonları gibi başka isimleri de mevcuttur [Calin, 2020]. Bu kavramı daha da ayrıntılı açıklanırsa öğrenme modeline başlangıç ağırlıkları rastgele olacak şekilde verilir. Ardından bu model eğitim verileri üzerinde tahmin yapmaya başlar. Bu modelde yapılan tahminlerin doğruya yakın olup olmadığı bir fonksiyon ile hesaplanabilir. Eğitim esnasında YSA modeli, tahminden ne kadar uzak olduğu maliyet fonksiyonu ile öğrenebilir. Böylece, eğitim verilerinin bir daha ki tekrarında modelde kullanılan ağırlıklar maliyet fonksiyonu sonucuna göre değiştirilir. Maliyet fonksiyonu, burada çok önemli bir görev almaktadır. Bu fonksiyon, öğrenme modeli tarafından tahmin edilen çıktıları ve modelin ne kadar hatalı olduğunu hesaplar. Modeldeki ağırlıklar bu parametreye göre güncellendikçe modelin maliyet fonksiyonunun verdiği hata azalır. Ancak her yinelemede bu hata azaltılamayabilir ve bu noktaya kadar ağırlıklar indirgenebilir. Bu da optimizasyon problemini ortaya çıkartan bir durumdur [Mehta et al., 2019].

4.4.8. Rastgele Gradyan İnişi Fonksiyonu

Rastgele Gradyan İnişi, derin öğrenme modellerini optimize etmek için kullanılan yaygın bir yöntemdir. Oluşan gradyanlar, rastgele seçilen eğitim verisi ile değerlendirilmektedir [Özbay, 2020]. Bu yöntemin kullanılmasının en temel sebebi, modelin maliyet fonksiyonunu en aza indirmektir. Böylece, bu yöntem sayesinde maliyet fonksiyonunda minimum hataya ulaşılabilir. Bu yöntem yinelemeli bir yol izler, yani eğitim sırasında her iterasyonda gradyanlara ait ağırlıklar güncellenir ve maliyet fonksiyonunda elde edilen hatalar en küçük seviyeye çekilir. Ayrıca Gradyan inişini optimize etmek için yaygın olarak kullanılan algoritmalar: Adagrad, Adam, Adadelat ve Nadam'dır [Ruder, 2016].

4.4.9. Öğrenme Hızı

Derin öğrenmedeki en önemli hiper-parametrelerden biri de öğrenme hızıdır. Eğitim başlamadan önce manuel olarak bu parametrenin ayarlanması gerekir. Manuel olarak ayarlanmasının en büyük sebebi, çok küçük bir öğrenme hızı kullanılırsa gradyan inişinde işlem çok fazla yavaşlar ve bu nedenle güncelleme işlemi de yavaşlar ve var olan problemi çözmek için çok fazla yineleme yapılması gerekir. Bu da aşırı öğrenmeye neden olur ve istenilen sonuca ulaşılması imkânsız bir hal alır. Eğer bunun tam tersi olursa yani öğrenme hızı büyük bir değer seçilirse, gradyan inişi grafiğinde yineleme yeteri kadar yapılamaz ve bu nedenle verimli bir eğitim olmayacağı için model öğrenmeyi gerçekleştiremez [Zhang et al., 2020]. Öğrenme hızının eğitim başarısına etkisi büyüktür. Kısaca uygun öğrenme hızını seçmek eğitim etkinliğini etkilemektedir. Öğrenme hızını düşük seçmek modelin eğitimi yavaşlatır ve öğrenme hızı büyük olduğu zaman ise model eğitimi daha kısa sürede tamamlar. Ancak öğrenme hızı, kullanıcı tarafından deneme-yanılma yöntemiyle seçilmesi gerekmektedir [Mukhopadhyay and Mukhopadhyay, 2018]. Şekil 4.7'de eğitim esnasında farklı öğrenme hızının optimizasyon algoritmasına etkisi gösterilmiştir. Büyük öğrenme hızının kullanıldığı eğitimde model öğrenme gerçekleştirememiştir. Küçük eğitim hızının olduğu model de ise eğitim süresi çok fazla uzadığı görülmektedir [Aggarwal, 2018].




Şekil 4.7: Eğitim esnasında oluşturulan optimizasyon algoritması üzerinden öğrenme hızının gösterimi. a) Büyük öğrenme hızı. b) Küçük öğrenme hızı.

4.5. Aşırı ve Yetersiz Öğrenme

Makine öğrenmesinin alt kümesi olan derin öğrenmede var olan hataları minimize etmek için birçok yöntem mevcuttur. Ancak öncelikle yapılması gereken işlem, hataya sebep olan parametrelerin değerlendirilmesidir. Buna sebep olan iki adet problem mevcuttur, bunlar: yetersiz öğrenme ve aşırı öğrenmedir. Yetersiz öğrenme de eğitim verileri modeli eğitmek için yeterli seviyede değildir ve eğitim esnasında öğrenme gerçekleşmez. Bunun yanında, eksik verilerle modelin genelleştirilmesi yapılamaz. Eksik verilerle üretilmiş model, eğitim için uygun değildir ve başka eğitim verilerinde düşük bir performans sergiler [Ghasemian al et., 2018]. Aşırı öğrenme ise yetersiz öğrenmenin tam tersi bir özelliğe sahiptir. Aşırı öğrenmiş model de eğitim verisindeki tüm detaylar ve gürültüler öğrenilir ve model eğitim verisine göre çok iyi bir model olur. Ancak bu modele yeni bir veri dahil edildiğinde model genelleme yeteneğini kaybettiği için performansında problemler oluşur. Eğer modelde eğitim hatası ile test hatası arasından büyük bir fark varsa burada aşırı öğrenme gerçekleşmiştir. Modelin ağ yapısını değiştirerek yetersiz öğrenmeyi veya aşırı öğrenmeyi engellenebilir [Lecun et al., 2015].

Şekil 4.8’de yetersiz, ideal ve aşırı öğrenmeye örnek verilmiştir. Örneğin, iki farklı veriyi içeren bir sınıflandırma problemini ele alındığında bu problemi çözmek için bir derin öğrenme modeli oluşturulmuştur. Bu veriler x ve o olarak şekilde gösterilmiştir. Sınıflandırma yapmak için bir model üretilmiştir. Şekil 4.8: a)’da üretilen model yetersiz öğrenmeye sahiptir. Bu sebeple grafikte iki sınıfı birbirinde ayırmayacak bir doğrusal çizgi çizilmiştir. Şekil 4.8: b)’de ideal bir öğrenme modeli mevcuttur. Çünkü, yüksek doğrulukta iki sınıfı birbirinden ayırdığı gözlenmektedir. Şekil 4.8: c)’de ise model aşırı eğitilmiştir yani modeli kompleks bir yapıya sahiptir.

Bu sebeple, en yüksek doğruluğa sahip olsa da genelleştirilemeyen bir modeldir. Bu da modelin performansını ve üretilen sonucun doğruluğunu büyük ölçüde etkilemektedir. Kısacası, derin öğrenme modelinde ne yetersiz öğrenme ne de aşırı öğrenme gözlenmemelidir.



Şekil 4.8: a) Yetersiz öğrenme. b) İdeal öğrenme. c) Aşırı öğrenme.

4.6. Başarım İyileştirme ve Optimizasyon

Başarım iyileştirme, aşırı öğrenmeyi engellemek amacıyla derin öğrenme modellerinde kullanılan yaygın bir iyileştirme metodudur. Bu terim, daha iyi bir model üretmeyi amaçlayan özel bir teknik olarak tanımlanabilir [Kukačka et al., 2017]. Aşırı öğrenme problemi, sinir ağı modellerinin, eğitim veri kümesinin özelliklerini öğrenme eğilimi göstermekten ziyade görülmeyen verilerle ilgili belirli bir özelliği öğrenme eğilimi gösterdiği bilinmektedir. Başarım iyileştirme ilk olarak istatistik alanında kullanılmaya başlanmıştır. Ardından, makine öğrenmesi, regresyon ve sınıflandırma gibi veri analizi için kullanılmıştır. Bu metot İstatistiksel Öğrenme Teorisi ve Düzenleme Teorisi (Statistical Learning Theory and Regularization Theory) üzerine kuruludur [Evgeniou et al., 2002]. Modelin öğrenmesi sürecinde, bias ve ağırlıklardan türetilen varyanslar gibi birçok bilinmeyen parametre kullanılır. Buradaki asıl amaç bias değerleri sabit tutulurken varyans değerini azaltmaktır. Böylece, başarım iyileştirme yöntemleri kullanılarak modelin aşırı öğrenmesi engellenmiş olur.

Derin öğrenme modelleri çok karmaşık problemleri çözmek için yüksek kapasiteli ağ modellerine sahiptir. Bu da aşırı öğrenme çok duyarlı olmaktadır [Khan et al., 2018]. Bu durumun birçok sebebi bulunmaktadır. Bunlardan ilki derin öğrenme modelini eğitmek için kullanılacak bir eğitim ve test veri seti eksikliğidir [Nusrat and Jang, 2018]. Diğer önemli etmen ise öğrenme modelinin, eğitim için yeterli bir şekilde tasarlanmamış olmasıdır. Yapay sinir ağ modelleri doğrusal ve doğrusal olmayan

fonksiyonlar içerebilir. Bu fonksiyonlara bağı olarak öğrenme modelinin karmaşıklığı artmaktadır. Bu sebeple, bu modellerin verilen problemleri çözebilmesi için birçok katmandan oluşturmaktadır, böylece başarımlar iyileştirme parametreleri kullanılmalıdır. Modelde kullanılan hiperparametrelerin ayarlanması gerekmektedir [Demyanov, 2015]. Bunu takiben, doğrusal olmayan fonksiyonlar sigmoid ve ReLU gibi aktivasyon parametrelerini kullanarak doğrusal fonksiyonlara dönüştürülür, böylece probleme uygun olacak şekilde model geliştirilebilir. Bunların yanında, başarımlar iyileştirme yöntemleri modelin performansını düşürmeden modelin karmaşıklığını azaltmak için de kullanılabilir. Bu yaklaşımlar, sinir ağlarının mimarisine ve eğitim veri setine uygulanabilir. Ayrıca, bu yöntemler öğrenme modeli için önemli bir aşamadır. Çünkü, eğitim ve test veri setlerine göre modelde birçok gizli katman ve ağırlık sayısı gibi çok fazla parametre içerir [Murugan and Durairaj, 2017]. Bunların düzenlenmesi ile ağ modelinin gerçek öğrenme görevine yardımcı olur ve bu ağdaki gürültüleri (bias) azaltılır [Khan et al., 2018].

Başarımlar iyileştirme metotlarının birçok önemli avantajları ve dezavantajları vardır. Üretilen ağ modeli, öğrenme esnasında aşırı öğrenmeyi engellerken, modelin mimarisini ve hesaplama verimliliğini artırır. Dezavantajlarından biri ise gürültüyü engellemek amacıyla ağdaki boyutsallığı azaltmaktır. Bu durumu engellemek için başarımlar iyileştirme yöntemlerini kullanmadan önce, balance bias ve varyans kullanılarak işlem yapılmalıdır. Kısacası ağ modelinin geliştirememesi problemini engellemek amacıyla öncelikle modelin kararsızlığını gidermek gerekir. Bunun da ancak başarımlar iyileştirme teknikleri ile üstesinden gelinebilir. Hem ağ mimarisine hem de veri setine uygulanabilen birçok başarımlar iyileştirme yöntemi literatürde geçmektedir. Ağ mimarisine uygulamak için L1 ve L2 kernel filtreleri kullanılabilir. Bunlar modeldeki ağırlıkları kullanarak işlem yapmaktadır [Kukačka et al., 2017]. Başarımlar iyileştirme yöntemlerinin en önemli parçalarından biri, derin öğrenme modellerindeki ağırlıklardır. Öğrenme modelinde, düzenleme parametreleri için bilinmeyen olarak kabul edilen ilk ağırlıklar ağ tarafından kendi başına belirlenir. Çünkü bu modeller kara kutu prensibi ile çalışmaktadır. Modelin yapısını etkileyecek birçok işlemde, bu yöntemler modeldeki düğümlerin ağırlıkları veya katsayıları ile ilgilidir. Bu nedenle, aşırı öğrenme gibi durumlarda bu ağırlıkları düzenlemek için modele başarımlar iyileştirme parametreleri eklenmelidir.

Birçok çalışmada bu yöntemler denenmiş ve karşılaştırılmıştır. Ancak, bu varsayımlar, ağ modellerinin türüne göre değişim göstermektedir. Bugün bu yöntemler

üzerine çalışmalar yapılmıştır [Smirnov et al., 2014] [Schmidt et al., 2007]. Ayrıca bu yöntemi geliştirmek için yeni yöntemler de üretilmiştir. Derin öğrenmede karşılaşılan en önemli zorluklardan biri aşırı öğrenmedir. Bu konuyla ilgili araştırmalar, başarıyı iyileştirme yöntemlerinin nasıl geliştirileceği üzerinde çalışmaktadır. Başarıyı iyileştirme için kullanılan teknikler aşağıda sıralanmıştır.

- Standart Başarıyı İyileştirme, literatürde sık kullanılan basit bir yöntemdir. Bu yöntem, modelde kullanılan ağırlıkları mümkün olduğunca küçük hale getiren ağırlık cezalandırmasını içerir, aynı zamanda başlangıç noktasından uzak olan ağırlıkları da ortadan kaldırır. Ağlarda büyük ağırlık varsa, sinir ağına aşırı eğitilmiş olduğu anlamına gelir. Standart regülasyon yönteminde L1 ve L2 regülasyon parametrelerinin parametreleri ağı optimize etmek için kullanılır. L1 ve L2 parametreleri, sırasıyla ağı ağırlıklarının mutlak ve kare değerlerinin toplamı kullanılarak hesaplanır. L2 parametresi aynı zamanda ağırlık azalması olarak da bilinir.
- Erken Durdurma, modelin eğitimi sırasında rastgele gradyan iniş değeri minimum seviyeye ulaştığında model öğrenme durdurulur. Bu yöntem modelde aşırı sığması önlenir [Prechelt, 1998].
- Veri Seti Genişletme, sinir ağını eğitmek için yeterli miktarda eğitim verisine ihtiyaç duyulur ancak bazı zamanlarda veri seti kısıtlı kalabilir. Bu nedenle sentetik veriler, veri yönünün dönüştürülmesi, küçük veri parçalarının kesilmesi ve veri RGB değerinin değiştirilmesi gibi çeşitli küçük dönüşümlerle aynı veri kümesi kullanılarak oluşturulur. Böylece, veri seti modeli eğitmek için genişletilir. [Goodfellow et al., 2016]. Ek olarak, temel bileşen analizi (PCA), veri artırımı için kullanılan başka bir tekniktir [Krizhevsky et al., 2017].
- Seyreltme Katmanı, Bu yöntem, sinir ağındaki bağlantılı birimleri her yinelemeye bağlı olarak rastgele olacak şekilde geçici olarak devre dışı bırakan bir çalışma prensibine sahiptir [Hinton, 2014]. Böylece, bu metod modelin aşırı öğrenmesini önler [Lemberger, 2017]. Oluşturulan öğrenme modeline göre seyreltme katmanı özelleştirilerek; dropout [Wang and Manning, 2012], dropConnect [Wan et al., 2013], Drop-Part [Tomczak, 2013], Standout [Lei et al., 2016], DropAll [Frazão and Alexandre, 2014], Random Dropout [Bouthillier et al., 2015], Curriculum Dropout [Morerio et al. 2017], Channel-Out [Wang and JaJa, 2014] katmanları oluşturulmuştur.

- Yığın Normalizasyonu, bu normalizasyon yöntemi, iç kovaryans algoritması kullanılarak sinir ağlarının performansını hızlandırmada önemli bir unsurdur. Sinirsel ağ modeline evrişim bağlı katman gibi bir katman olarak eklenebilecek bir özelliği vardır [Goodfellow et al., 2016].

4.7. Derin Öğrenmede Kullanılan Kütüphaneler

Kütüphaneler (Framework) yazılımcılar tarafından üretilmiş içerisinde önceden hazırlanmış kütüphaneleri barındıran ve onları geliştirilmesine veya değiştirilmesine izin veren yapılardır. Derin öğrenmede ise birçok kütüphane kullanılmaktadır. Böylece benzer işleri yapmak için oluşturulan yapılar bir kütüphane içene gömülü hale getirilir. Başka bir kullanıcı tarafından bu kütüphane kullanılarak yapı çekilir ve işlemleri tamamlayabilir. Kullanılan amaca ve yazılım diline göre kütüphaneler çeşitlendirilebilir. Derin öğrenmede kullanılan kütüphaneler destekledikleri algoritmaya veya uygulama kalitesine göre farklılık gösterebilir. Literatürde birçok derin öğrenme kütüphanesi bulunmaktadır. Bunlar Caffé, CNTK, PyTorch, TensorFlow ve Theano'dur ve bu yapıların her biri farklı özelliklere ve performansa sahiptir. Bu kütüphaneler, derin öğrenme algoritmalarının uygulanmasının optimize etmek için farklı teknikler kullanılır [Shatnawi et al., 2018]. Tablo 4.2'de derin öğrenmede sıklıkla kullanılan kütüphaneler tek tek açıklanmıştır. Derin öğrenme kütüphaneleri, Google, Facebook ve Microsoft gibi dünya çapındaki şirketler tarafından geliştirilmiştir. Derin öğrenmede GPU bellek kapasitesi ile ilgili hala sınırlamalar mevcuttur. Bu durumla ilgili birçok çalışma halen yürütülmektedir [Nguyen et al., 2019]. Derin öğrenmede kullanılan kütüphaneler aşağıda sıralanmıştır.

- TensorFlow, Google Brain Team tarafından üretilmiş tüm sayısal hesaplamalar için tek bir veri akışı kullanan açık kaynak kodlu bir kütüphanedir. Esnek bir mimariye sahip olan TensorFlow, birçok sinir ağı modellenmesinde kullanılmaktadır. Bu kütüphanede Python, C++ ve Java gibi programlama dilleri kullanılmaktadır [Web 3, 2020].
- PyTorch, GPU hızlandırmalı derin öğrenme kütüphanedir. Facebook AI tarafından 2016'da geliştirilmiştir. PyTorch, Python, C ve CUDA'da yazılmıştır. Bu kütüphane, karmaşık derin öğrenme modellerini kolayca inşa edebilir. Bu

kütüphane ücretsiz olarak sunulmuştur. Facebook, Twitter, NVIDIA ve birçok kuruluş tarafından desteklenmektedir. [Nguyen et al., 2019].

- Keras, Python'da geliştirilmiş açık kaynak koddur. TensorFlow, CNTK veya Theano üzerinde çalışabilen üst düzey bir YSA programlama ara yüzüdür. Kısa bir sürede gecikme yaşamadan araştırma yapmak için kullanılır. Tekrarlayan ve evrimsel sinir ağları üzerinde çalışmaktadır [Web 4, 2020].
- Caffe, BAIR (Berkeley Artificial Intelligence Research) tarafından üretilmiş bir derin öğrenme kütüphanesidir. Derin öğrenme modelleri Caffe'de katman katman tanımlanır. Her bir katman modelin özü ve temel hesaplama birimi olarak kabul edilir. Bu katmanlar verinin normalizasyonu sağlar. Bu katmanların özelleştirilmesi Python'da az desteklense de C++ CUDA'da yeni katmanlar yazılabilir [Nguyen et al., 2019].
- CNTK (Microsoft Cognitive Toolkit) açık kaynak olup Microsoft Research tarafından geliştirilmiş bir derin öğrenme kütüphanesidir. Evrimsel, tekrarlayan sinir ağı gibi birçok sinir ağının eğitiminde ve çoklu GPU ve sunucular içinde kullanılmaktadır. CNTK, gradyan iniş ve geriye hata yayma prensibi ile çalışmaktadır. Ayrıca bu kütüphane, Python, C# ve C++ programlama dilinde kullanılmaktadır [Web 5, 2017].
- Theano, Montreal Üniversitesinde geliştirilmiş bir kütüphanedir. Theano, çok boyutlu dizileri (Numpy kütüphanesini kullanır) içeren matematiksel ifadeleri tanımlamayı, optimize etmeyi ve değerlendirmeyi sağlayan bir Python kütüphanesidir. Bu kütüphane, C++ makine öğrenme dili kullanmaktadır [Shatnawi et al., 2018].

4.8. Uzaktan Algılamada Derin Öğrenme

Uzaktan algılama, afet izleme, savunma, tarım, güvenlik, kentsel faaliyetler gibi birçok uygulamada kullanılmaktadır. Bu alanlarda teknolojinin gelişmesiyle birlikte uzaktan algılama faaliyetlerine yeni bir soluk gelmiştir. En popüler alanlardan biri olan makine öğrenmesi bu uygulamalarda yaygın olarak kullanılmaya başlanmıştır. Derin öğrenmenin bu alanda kullanılmasının en temel nedenleri, uzaktan algılamanın fazla miktarda veri içermesi ve bu verilerin en ideal bir şekilde işlenmesine olanak tanımasıdır. Son zamanlarda uzaya gönderilen uyduların artması ile farklı spektral ve

uzamsal çözünürlüklere sahip görüntüler de dahil olmak üzere görüntü veri çeşidi ve miktarında artış bulunmaktadır. Geleneksel yöntemlerde bu artan veriyi en ideal şekilde kullanmak başarılı bir sonuç veremeyebilir. Geleneksel yöntemlerin bu gibi durumlarda yetersiz kalması nedeniyle derin öğrenme bu veriler için alternatif bir yöntem olarak karşımıza çıkmaktadır. Çünkü, uzaktan algılamada yapılan birçok çalışmada derin öğrenme otomatik olarak özellik çıkartarak veya öğrenerek, klasik yöntemlere göre daha iyi sonuç verdiği gözlenmektedir [Zhang et al., 2016], [Zhang et al., 2017]. Bunun yanında, geleneksel yöntemlerde insan müdahalesinin de önüne geçilmiş olup ve böylece objektif sonuçlar elde edilmeye başlanmıştır. Uydu görüntüleri birçok karmaşık veri içerebilir bu verileri uygulamalarda kullanmak için derin öğrenme yaklaşımı son zamanlarda yaygın olarak kullanılmaya başlanılmıştır. Uzaktan algılamada derin öğrenme uygulamalarını dört ana başlık etrafında toplanabilir. Bunlar; ön işlem, sınıflandırma, obje tanıma/tespit ve görüntü yorumlama [Zhang et al., 2016].


4.8.1. Ön İşleme Uygulamalarında Derin Öğrenme

Ön işlem bölümünde, uzaktan algılanmış görüntülerde sensor sınırlamaları veya ortamın etkisinden ötürü hatalar veya bozukluklar olabilir. Bunları gidermek ve görüntü kalitesini iyileştirmek için bu görüntülere ön işlem adımlarının uygulanması gerekir. Ön işleme uygulamaları, literatürde geçen görüntü düzeltme veya görüntü iyileştirme teknikleridir. Bu ön işleme teknikleri, standart tekniklere dayanmaktadır. Kısaca, bu işlemler çoğunlukla makine öğrenmesi kullanılmadan gerçekleştirilmektedir. Ancak, derin öğrenme ile bu teknikler beraber kullanılabilir. Örnek olarak, bir girdi veri ile çıktı verisi arasındaki iç korelasyon etkili bir biçimde modellenen biliniyorsa uzaktan algılanmış başka görüntüler için bu model kullanılarak ön işlem adımı uygulanabilir [Gu et al., 2019]. Bu modelleme işlemi derin öğrenme ile irdelenip oluşturulabilir. Başka bir örnek olarak, evrişimsel sinir ağları kullanılarak görüntüde oluşmuş olan gürültü giderilebilir veya düşük çözünürlükteki görüntülerden yüksek çözünürlüklü görüntüler elde edilebilir. Başka bir uygulamada, görüntülerin ağa sokulmadan önce belli kriterlere sahip olması gerekir. Bu kriterlerden biri boyuttur. Derin öğrenme modeli belli bir standarda sahip olduğu için görüntü boyutunun aynı olması gerekir. Bu neden ön işlem

adımı olarak görüntüler, derin öğrenme modeli ile uygun boyutlara dönüştürülebilir. Yeniden boyutlandırmanın yanında kırpma işlemi de bu prensiple çalışmaktadır [Web 6, 2020]. Yapılan başka bir çalışmada, PanNet adlı bir derin öğrenme modeli üretilmiştir. Bu modelin kullanım amacı görüntülerin kesinleştirilmesidir. Bu model tasarlanırken, görüntüye ait spektral ve uzamsal özelliklerin korunmasına dikkat edilmiştir. Spektral özellikleri korumak için, spektral bilgi yeni yapılandırılmış ve görüntüye doğrudan yayan ağ çıktısına örneklenmiş spektral görüntülere eklenmiştir. Uzamsal özelliği korumak için ise, yüksek geçişli filtreleme alanı kullanılmıştır. Böylece oluşturulan ve genelleştirilmiş ağ, farklı uydu görüntülerinin kullanılabileceği bir model olarak literatüre geçmiştir [Yang et al., 2017]. Başka bir çalışmada, hiperspektral görüntülerin yorumlanmasını ve uygulama performansını artırmak için bu görüntülerdeki gürültüyü arındırmak üzerine yapılmıştır. Bu uygulamada, spektral-uzamsal tabanlı bir derin öğrenme modeli kullanılmıştır. Gürültülü görüntüler ile gürültüsüz görüntüler arasında doğrusal olmayan bir ilişki bulunmaktadır. Bu ilişki, bir derin öğrenme ağı ile modellenirilmiş ve HSID-CNN oluşturulmuştur. Bu modelle üretilen görüntüler sınıflandırılmış ve sınıflandırma sonucunun daha iyi performans gösterdiği ispatlanmıştır [Ali et al., 2019].

4.8.2. Görüntü Sınıflandırma Uygulamalarında Derin Öğrenme

Uzaktan algılamada sınıflandırma popüler bir konudur. Birçok çalışmada, klasik yöntemlerin artık yerini makine öğrenmesine bırakmıştır. Derin öğrenme ile spektral, uzamsal özellikler veya spektral-uzamsal özellikler birlikte kullanılarak sınıflandırma yapılabilir. Sınıflandırmada derin öğrenme teknikleri kullanıldığında görüntüye ait belirgin soyut özellikler tespit edilebilir. Bu da sınıflandırma doğruluğunu arttıran bir etmendir. Sınıflandırma işleminin 3 ana temel adımı mevcuttur. Bunlar veri girişi, derin öğrenme modelinin eğitimi ve sınıflandırma şeklindedir. Şekil 4.9’da üç temel adım gösterilmiştir. Girdi verisi görüntüye ait spektral veya uzamsal özellikler alınabilir. Ardından, bu veriler gizli katmana verilir. Gizli katmanda girdi verilerinin özellik haritasını çıkartır ve modelin bunu öğrenmesini sağlar. Sonuç olarak da eğitilmiş ağ öğrenilen özellikleri kullanarak sınıflandırılmış bir görüntü oluşturur [Zhang et al., 2016].



Şekil 4.9: Derin öğrenme tekniği ile uydu görüntüsünün sınıflandırılması.

Spektral ve uzamsal özellikler kullanılarak sınıflandırma yapılabilir. Sadece spektral özellikler kullanılarak yapılan sınıflandırmalarda, spektral bilgi bol miktarda farklı bilgi içermektedir. Uzaktan algılamada, piksel tabanlı sınıflandırma sadece spektral özelliklere dayandırılarak yapılan yaygın bir sınıflandırmadır. Destek vektör makineleri veya en yakın komşu algoritmaları da sınıflandırma da kullanılmaktadır. Ancak bunları oluşturulan mimariler sığ bir yapıya sahiptir [Pasupa and Sunhem, 2016]. Ancak derin öğrenme modelinin mimarisi, girdi verisi ile etiketli veri arasındaki karmaşık ilişkiyi oluşturmaktadır. Modeli eğitmek için kullanılan girdi verisi, etiketli veriye ait spektral özellikleri taşımaktadır. Bu durumun yanında, hiperspektral görüntülerde spektral bilgi önemli bir rol oynamaktadır. Ancak bu görüntülerde fazla bant olduğu için bazı bantlar gereksiz bilgi içerebilmektedir. Bu nedenle, tüm bantların sınıflandırılma da kullanılması, algoritmanın sınıflandırma performansını düşürmektedir. Görüntü sınıflandırması için Temel Bileşen Analizi gibi yöntemlerle bilgi yoğunluğu fazla olan bantlar seçilir [Li et al., 2019]. Spektral özelliklerin kullanılarak yapılan sınıflandırma piksel tabanlı sınıflandırmaya benzemektedir. Örneğin, bir çalışmada evrişimsel sinir ağları kullanılarak hiperspektral görüntüler sınıflandırılmıştır. Öncelikle, çalışmada eğitim verisi ile derin öğrenme modeli eğitilmiştir. Ardından bu model tüm görüntüye uygulanmış ve sınıflandırma işlemi yapılmıştır. Bu çalışmada Pavia görüntüsü kullanılmış ve iki farklı modelde doğruluk %92,69 ve %94,71 olarak bulunmuştur [Zbakh et al., 2019].

Uzaktan algılanmış görüntüde arazi örtülerinin yeryüzünde sürekli bir yapıda olduğu bilinmektedir. Ayrıca uzaktan algılanmış görüntülerdeki bitişik piksellerin aynı arazi sınıfında olma olasılığı çok yüksektir. Günümüze kadar yapılan birçok çalışmada

spektral ve mekânsal özellikler bir arada kullanılmaktadır. Böylece oluşturulan tematik haritalardaki sınıflandırma doğruluğunun arttığı gözlenmiştir [Fauvel et al., 2013]. Klasik yöntemler içerdikleri yapı nedeniyle sığdır, bu nedenle derin öğrenme, klasik yöntemlere göre daha fazla özellik çıkartabilir. Spektral-mekansal özellikleri birlikte değerlendirerek derin öğrenme yaklaşımı ile sınıflandırma yöntemi olarak önerilmiştir [Zhao and Du, 2016]. Bazı görüntü sınıflandırması uygulamalarında sınırlı sayıda eğitim verisi kullanılarak model eğitilmiş ve sınıflandırma aşaması gerçekleştirilmiştir. Bir çalışmada 11 katmanlı R-HybridSN modeli önerilmiş ve bu model 3B ve 2B ESA ile oluşturulmuştur. Bu model sayesinde spektral-uzamsal özelliklerin daha iyi öğrenilebileceğini savunmuşlardır. Farklı miktarda eğitim veri setleri kullanılmış ve görüntü olarak da Indian Pines, Pavia ve Salinas verileri tercih edilmiştir. Tüm görüntülerde sınıflandırma doğruluğu %96 üzerindedir [Feng et al., 2019].

4.8.3. Obje Tespiti/Tanıma Uygulamalarında Derin Öğrenme


Kaggle gibi birçok internet sitesinde obje tanıma ile ilgili birçok yarışmalar düzenlenmektedir. Gemi, uçak gibi araçların tespiti uydu görüntüleri üzerinden yapılabilmektedir. Bu objelerin büyüklük, görüntülerdeki yönü, sayıları ve çevresindeki cisimler ile karışması gibi problemler mevcuttur. Bu problemler de obje veya hedefin tespitini olumsuz olarak etkilemektedir. Obje tanıma algoritmaları temel olarak belirli tür nesneye ait olan uzaktan algılanmış görüntüler kullanarak hedefin veya objenin konumu, pozunu ve sınıfını belirleme işlemine sahiptir [Gezahegn and Chakraborty, 2019]. Uzaktan algılanmış görüntülerin içindeki tüm objelerin tespiti henüz çözülememiş bir sorundur. Kısaca, obje tanıma, hedefin bulunduğu ortam ile karmaşık bir yapıda olabilir. Bu da hedefin tespit edilmesini zorlaştırmaktadır [Zhang et al., 2016]. Obje veya hedef tanıma ile ilgili birçok çalışma yapılmıştır. Bunların bazılarında RADAR görüntüleri kullanılmıştır. Örneğin, literatürdeki bir çalışmada otomatik hedef tanıma standardından bahsedilmiştir. Bu standart, algılama, ayırmacılık ve sınıflandırma olmak üzere üç aşamadan oluşmaktadır. Bu çalışmada, derin ağ modeli olarak evrimsel sinir ağlarının kullanımı önerilmektedir. Modeli eğitmek için tüm sınıflara ait eğitim verisi oluşturulmuştur. Bu model sonucunda elde edilen obje tespiti/tanıma doğruluğu %99,55'tir [Furukawa, 2018].

Kontrolsüz ve kontrollü yöntemler olarak hedef tanıma yaklaşımlarını ikiye ayrılabilir. Kontrolsüz yöntemlerde etiketli veriler veya ön bilgiler kullanılmadan gerçekleştirilirken, kontrollü yöntemlerde verilerin birbirinden ayrılması için etiketli veriler kullanılır [Zhang et al., 2016]. Obje tanıma uygulamalarında öncelikle uydu görüntülerinde birtakım ön işlemler gerçekleştirilir. Bu ön işlemler ile görüntü içindeki gürültüleri veya eksik/tutarsız veriler elenebilir. Regresyon, kümeleme, eşikleme ve filtreleme gibi ön işlem adımları gerçekleştirilebilir. Görüntünün özelliklerine göre ön işlemler algoritmalarından bir tanesi yeterli olmayabilir, bu nedenle birden fazla ön işlem adımı gerçekleştirilebilir. Objeye ait özniteliklerin çıkartılması ön işlem aşamalarından sonra gelir. Objenin tanımlama bilmesi için öznitelik özelliklerinin matematiksel algoritmalarla ifade edilmesi gerekir. Algılama aşamasında uydu görüntüsünün neler içerdiğini ve bu görüntüden çeşitli çıkarımlar yapılır. Görüntünün ne içerdiği algoritma tarafından algılandıktan sonra sınıflandırma işlemi yapılır ve görüntüdeki objeler tespit edilebilir [Daş et al., 2019]. Görüntü içindeki objelerin sınıflandırılması için nesneyi çerçeveleyen bir kutu çizilir. Bu kutunun nesneyi tam olarak kapsayabilmesi gerekir. Kontrolsüz yaklaşımda ise yeterli kadar etiketli veri olmadığı zaman kullanılır. Bu yaklaşımda tipik kontrolsüz özellik öğrenme algoritmaları uygulanır [Zhang et al., 2016].

4.8.4. Görüntü Yorumlama Uygulamalarında Derin Öğrenme

Uydu görüntüleri teknolojinin gelişmesiyle çözünürlükleri de artmıştır. Yüksek çözünürlüklü görüntüler bol miktarda detaylı bilgi ve yapısal bir görüntü içermektedir. Uydu görüntülerinin büyük olması ve karmaşık kompozisyonundan ötürü çok fazla veri içermesi nedeniyle görüntünün yorumlanması zordur. Bu da uzaktan algılama biliminde çeşitli problemlere yol açmaktadır. Uydu görüntülerindeki içeriklere bakarak özellik temsillerini öğrenmeye yönelik fazla sayıda çalışmalar yapılmaktadır. Görüntü verisinin içinde hiyerarşik bir yapı mevcuttur. Bu hiyerarşik yapı piksellerden ve görüntü parçacıkları oluşmuştur. Görüntü parçacıklarının birleşmesi ile nesneler ortaya çıkmaktadır. Çeşitli derin öğrenme algoritmaları ile görüntülerdeki hiyerarşi öğrenilebilir [Zhang et al., 2016]. Görüntü sınıflandırması, yorumlanması için önemli bir uygulamadır. Görüntünün yorumlanması için birçok derin öğrenme algoritması kullanılmıştır. Yapılan bir çalışmada görüntüdeki nesneler ve içerdiği başka öğeler ile

aralarında ilişki kurulmaktadır. Böyle görüntüye ait arazi kullanım bilgisi çıkartılabilir. Örneğin, biri ticaret bölgesinden diğeri ise yerleşim bölgesinden alınmış iki farklı görüntülerin arazi kullanımı birbirinden farklıdır. Ancak, bu iki görüntüde yol veya bina ögesini içerebilir. Bu da oluşturulan derin öğrenme modelinin iki sahneyi ayırt etmek zordur. Bunun gibi birçok zorlukla karşılaşılmaktadır. Bu sebeple, birçok derin öğrenme modeli oluşturulmuştur. GoogleNet’de bu modellerden birine örnektir [Li et al., 2017].



Şekil 4.10: Görüntü yorumlamasının aşamaları.

Literatürde görüntü yorumlanması için farklı üç alt görevi mevcuttur. Şekil 4.10’da her bir alt görevin işlevi gösterilmiştir. Bu görevlerin ortak özelliği hepsi görüntü içindeki anlamsal bir temsilin alt yapısıdır. İlk olarak, girdi verileri ile görüntü sınıflandırılır. Diğer aşamada, görüntü içindeki objelerin tespiti yapılır. Ardından, görüntüdeki arazi kullanım için belli sorgular gerçekleşir. Görüntü içindeki nesnelerin arazi kullanımı ile ilgili ilişkilerin algılanmasını göstermektedir. Bu misyonlar birleştirildiğinde uydu görüntüsünün yorumlanması gerçekleştirilir [Gu et al., 2019].

5. UYGULAMA

5.1. Çalışma Alanı ve Veri Seti


Bu tez çalışması kapsamında web ortamında sunulan Pavia hiperspektral görüntüsü kullanılmıştır. Bu görüntünün seçilmesinin en büyük sebebi hiperspektral özelliklere sahip olmasıdır. Çalışma alanı, İtalya'nın kuzeyinde bulunmaktadır ve bu çalışmada Reflective Optics System Imaging Spectrometer (ROSIS) görüntüsü kullanılmıştır (Şekil 5.1).



Şekil 5.1: Pavia Üniversitesi çalışma alanı (Bant 50-Bant 27-Bant 17 sıralaması ile gerçek renk).

ROSIS sensörü ile ilk uçuşlar 1992'de gerçekleştirilirken, mevcut sürüm ROSIS-03 1999'dan beri kullanılmaktadır. ROSIS görüntüleri 115 bant içerirken,

sensörün spektral aralığı 430 - 860 nm arasındadır. Bant genişliği ise 4,0 nm'ye eşittir [Web 7, 2020]. Pavia verisi, uzaktan algılanmış bir hiperspektral görüntü olmakla birlikte, düzeltmeleri yapıldıktan ve gürültü nedeniyle bazı bantları çıkartıldıktan sonra, 103 adet spektral banttan oluşmaktadır. 1,3 metre geometrik çözünürlüğe sahip görüntünün boyutları 610 x 340 pikseldir. Bu veri seti, 42.776 adet pikselden oluşturulmuş 9 farklı arazi sınıfını bulunduran yer doğrulama verisi mevcuttur (Şekil 5.2). Bu arazi sınıfları; asfalt, çayır, çakıl, ağaç, metal çatı, çıplak toprak, ziftli zemin, tuğla ve gölge sınıfıdır (Sildir et al., 2020). Arazi sınıflarına ait örneklem sayısı Tablo 5.1'de gösterilmiştir.



Şekil 5.2: Pavia Üniversitesi yer doğrulama tematik haritası.

Tablo 5.1: Arazi referans verisi örneklem sayısı.

Arazi Sınıfı	Örneklem Sayısı
Asfalt	6.631
Çayır	18.649
Çakıl	2.099
Ağaç	3.064
Metal Çatı	1.345
Çıplak Toprak	5.029
Ziftli Zemin	1.330
Tuğla	3.682
Gölge	947
Toplam	42.776

Derin öğrenme ile sınıflandırma işlemi, üretilen haritaların doğruluk analizleri Anaconda'nın Jupyter Notebook'u kullanılarak Python 2.7 dilinde gerçekleştirilmiştir. Python dilinde üretilen çıktıların görselleştirilmesi için ERDAS Image ve ArcGIS yazılımları kullanılmıştır. Derin öğrenme ile sınıflandırma yapmak için Python'nın Keras kütüphanesi kullanılmıştır. Eğitim, doğrulama ve test verisinin üretimi için ise Python'nın Numpy ve Random kütüphaneleri kullanılmıştır. Veri setlerinin eğitim sırasında değerlendirmek için Matplotlib kütüphanesi kullanılmıştır. Son olarak da üretilen tematik haritaların doğruluk analizi için Skicit-learn kütüphanesi kullanılmıştır. Bu tematik haritaları üretmek için Python'dan alınan etiketli çıktı verileri txt formatın kayıt edilip ERDAS yazılımında img formatına çevrilmiştir. Ardından ArcGIS yazılımı ile son düzenlemeler yapılmıştır. Bunların yanında eğitim setlerinin oranına bağlı olarak 1B, 2B ve 3B evrimsel sinir ağlarında kullanılmıştır. Her derin öğrenme modeli için eğitim setleri oluşturulurken 9 arazi örtüsü sınıfının her biri için örneklem sayıları 50, 100, 200, 400 olacak şekilde hazırlanmıştır.

Bu uygulamada ve başarımların iyileştirme tekniklerinin uygulanmasında kullanılan bilgisayarın genel özellikleri, işlemcisi Intel(R) Core(TM) i7-9750H CPU @ 2.60GHz, RAM 8.00 GB ve işlem sistemi Windows 10 Pro olup 64-bit'tir ve ekran kartı olarak Intel(R) UHD Graphics 630 ve NVIDIA GeForce GTX 1650 kullanılmıştır.

5.2. Eğitim, Test ve Doğrulama Veri Setinin Oluşturulması

Bu uygulamada yer doğrulama verisinden eğitim, test ve doğrulama veri seti ayrıştırılmıştır. Pavia veri setinde toplam 42.776 adet pikselden oluşan yer doğrulama verisi bulunmaktadır. Bu veri setini ilk olarak Python dilinde Jupyter Notebook arayüzü kullanılarak 3 parçaya ayrılmıştır. Tüm arazi sınıflarına ait pikseller gruplandırılmıştır. Ardından tüm sınıfları için rastgele olacak şekilde %15'ini test ve %10'unu doğrulama (validation dataset) verisi olarak ayrıştırılmıştır (Tablo 5.2). Doğrulama verisi ile derin öğrenme modelinin doğruluğu hesaplanırken test verisi ile de üretilen tematik haritanın doğruluğu hesaplanmıştır. Tematik haritaya ait sınıf doğruluklarını üretmek için her arazi sınıfına ait F-skor doğrulukları hesaplanmıştır. Geri kalan her arazi sınıfı için örneklem eğitim verisi olarak kullanılmıştır.

Tablo 5.2: Arazi referans verisi örneklem sayısı, eğitim, test ve doğrulama verisi.

Arazi Sınıfı	Örneklem Sayısı	Eğitim Verisi	Test Verisi	Doğrulama Verisi
Asfalt	6.631	4.974	994	663
Çayır	18.649	13.987	2.797	1.865
Çakıl	2.099	1.575	314	210
Ağaç	3.064	2.298	460	306
Metal Çatı	1.345	1.009	202	134
Çıplak Toprak	5.029	3.772	754	503
Ziftli Zemin	1.330	998	199	133
Tuğla	3.682	2.762	552	368
Gölge	947	711	142	94
Toplam	42.776	32.082	6.414	4.276

Eğitim veri setleri oluşturulurken 4 farklı sayıda eğitim verisi belirlenmiştir. Ayrıştırılan eğitim verisi içinde her sınıf için 50, 100, 200 ve 400 örneklem rastgele olacak şekilde seçilmiştir (Tablo 5.3).

Tablo 5.3: Eğitim verisi örneklem sayıları.

Arazi Sınıfı	Eğitim İçin Kullanılacak Örneklem Sayısı			
	50 Örneklem	100 Örneklem	200 Örneklem	400 Örneklem
Asfalt	50	100	200	400
Çayır	50	100	200	400
Çakıl	50	100	200	400
Ağaç	50	100	200	400
Metal Çatı	50	100	200	400
Çıplak Toprak	50	100	200	400
Ziftli Zemin	50	100	200	400
Tuğla	50	100	200	400
Gölge	50	100	200	400
Toplam	450	900	1800	3600

5.3. Farklı Boyuttaki ESA'ların Performans Analizi

5.3.1. Bir Boyutlu ESA

5.3.1.1. Bir Boyutlu Derin Öğrenme Modelinin Performans Analizi

İlk olarak bu sinir ağı için dört farklı eğitim seti oluşturulmuştur. Bunlar 50, 100, 200 ve 400 örneklem rastgele olarak seçilerek uygulama için kullanılmıştır. 1 boyutlu evrişimsel sinir ağlarının girdi verisinin 2 bölümü mevcuttur. Bu bölümlerden ilki, öğrenme işlemlerinde kullanılacak özellikleri içerirken diğeri ise çıktıya ait bölümü içermektedir. Bu ağdaki sınıflandırma işlemi, piksel tabanlı sınıflandırma benzerdir. Çünkü eğitim esnasında sadece piksellerin spektral değerleri kullanılmaktadır. Eğitime başlanmadan önce, eğitim veri setine normalleştirme (Batch Normalization) yapılmıştır. Ardından 3 adet evrişimsel katman kullanılmıştır. Burada kullanılan filtrelerin boyutları 16 ve 8 olarak seçilmiştir. Ayrıca, aktivasyon fonksiyonu olarak da ReLU kullanılmıştır. Bu evrişimsel katmanlardan sonra düzleştirme katmanı kullanılmıştır. Bu katmandan sonra yoğunlaştırma katmanı (Dense Layer) ve seyreltme katmanı (Dropout Layer) kullanılmıştır. Yoğunlaştırma


katmanındaki parametre birimi 256, 64 ve 32 ve aktivasyon fonksiyonu ReLU olarak seçilmiştir. Seyreltme katmanındaki parametre ise 0,1 olarak seçilmiştir. Ağın en son bölümünde çıktı verisine softmax aktivasyon fonksiyonu kullanılarak eğitim tamamlanmıştır. Eğitim esnasında öğrenme hızı 0.001, sönüm (decay) parametresi 1e-06 olarak seçilmiştir. Maliyet fonksiyonunda Categorical Crossentropy kullanılmıştır. Optimizasyon parametresi olarak da ADAM kullanılmıştır. Epok sayısı, farklı eğitim seti oranlarında hepsi aynı tutulmuştur ve 500 olarak seçilmiştir. Batch size olarak da 256 seçilmiştir. Eğitim için kullanılan model Tablo 5.4'te özetlenmiştir. Bu tabloda gösterildiği gibi eğitim esnasında toplam parametre sayısı 23.613'tür. Eğitilebilir parametre sayısı 23.407 iken eğitilemeyen parametre sayısı 206'dır.

Tablo 5.4: Model: "1 Boyutlu ESA".

Katman(tipi)	Çıktı Boyutu	Parametre
Girdi Katmanı	(Yok, 1, 103)	0
Normalleştirme	(Yok, 1, 103)	412
1B ESA	(Yok, 1, 16)	1.664
1B ESA	(Yok, 1, 16)	272
1B ESA	(Yok, 1, 8)	136
Düzleştirme Katmanı	(Yok, 8)	0
Yoğunlaştırma Katmanı	(Yok, 256)	2.304
Seyreltme Katmanı	(Yok, 256)	0
Yoğunlaştırma Katmanı	(Yok, 64)	16.448
Seyreltme Katmanı	(Yok, 64)	0
Yoğunlaştırma Katmanı	(Yok, 32)	2.080
Seyreltme Katmanı	(Yok, 32)	0
Yoğunlaştırma Katmanı	(Yok, 9)	297
Toplam Parametre:	-	23.613
Eğitilebilir Parametre:	-	23.407
Eğitilemeyen Parametre:	-	206

5.3.1.2. Bir Boyutlu Derin Öğrenme Modelinin Sınıflandırma Sonuçları ve Doğruluk Değerlendirilmesi

Dört farklı eğitim örneklem sayısı (50, 100, 200, 400 örneklem sayısı) ile üretilen veri setleri ayrı ayrı 1 boyutlu derin öğrenme modelinde kullanılmıştır. Bu sebeple, derin öğrenme modeline veri seti uygulanarak görüntüye ilişkin 9 arazi sınıfını temsil eden dört adet tematik harita üretilmiştir (Şekil 5.3). Bu haritalar üretilirken eğitimden sonra üretilen tahmin verisini etiketli veri olarak txt olarak kayıt edilmiştir. Ardından ERDAS yazılımında çıktı verisi img olarak farklı kayıt edilmiştir. Son görselleştirme aşaması için ArcGIS yazılımı kullanılmıştır.



Şekil 5.3: 1 Boyutlu ESA ile farklı eğitim verileriyle tematik haritalar. a) 50 örneklem. b) 100 örneklem. c) 200 örneklem. d) 400 örneklem.

Sınıflandırma sonucu üretilen tematik haritaların doğruluğunu analiz etmek için test veri seti kullanılarak her tematik harita için hata matrisleri üretilmiştir. Farklı eğitim setleri (sırasıyla 50, 100, 200 ve 400 örneklem sayısı) ile üretilen haritaların

sırasıyla genel doğrulukları %74,84, %76,69, %81,81 ve %89,30 hesaplanmıştır. Kappa doğrulukları ise sırayla 0,68, 0,71, 0,77 ve 0,86 olarak hesaplanmıştır. Genel olarak bakıldığında örneklem sayısının artması ile birlikte Kappa ve genel doğruluğun arttığı gözlenmiştir. Tüm arazi sınıflarını değerlendirmek için kullanıcı ve üretici doğruluklarının harmonik ortalaması ile türetilen F-skor doğrulukları dört tematik harita için ayrı ayrı üretilmiştir (Tablo 5.5).

Tablo 5.5: 1 Boyutlu ESA için arazi sınıflarının F-skor doğruluk değerleri.

	Her Sınıf için Örneklem Sayısı			
Arazi Sınıfı	50	100	200	400
Asfalt	0,83	0,88	0,80	0,91
Çayır	0,76	0,77	0,88	0,92
Çakıl	0,71	0,74	0,58	0,77
Ağaç	0,80	0,88	0,80	0,85
Metal Çatı	0,99	0,99	1,00	1,00
Çıplak Toprak	0,54	0,59	0,75	0,84
Ziftli Zemin	0,66	0,74	0,65	0,80
Tuğla	0,80	0,75	0,79	0,86
Gölge	1,00	0,99	1,00	1,00
Genel Doğruluk (%)	74,84	76,69	81,81	89,30
Kappa Doğruluğu	0,68	0,71	0,77	0,86
Eğitim Süresi (sn)	3	18	61,2	1,2

Tüm tematik haritalarda Tablo 5.5'e göre en yüksek doğruluğa sahip arazi sınıfları %99 civarı F-skor doğruluğu ile metal çatı ve %100 civarı F-skor doğruluğu gölge sınıfına aittir. Tablo 5.5'e göre F-skor doğruluğu en düşük olan arazi sınıfları çıplak toprak, ziftli zemin ve çakıl sınıfına aittir. 50 örneklem ile üretilen tematik haritada çayır sınıfı, ağaç ve çıplak toprak ile karışmaktadır. Çıplak toprak sınıfı ise çayır sınıfı ile karışmaktadır. 100 örneklem ile üretilen tematik haritada ziftli zemin sınıfı, asfalt sınıfı ile karışmaktadır. Çakıl sınıfı ise tuğla sınıfı ile karışmaktadır. 200 örneklem ile üretilmiş tematik haritada çakıl sınıfının tuğla sınıfı ile karıştığı gözlenmiştir. Ziftli zemin sınıfı ise çakıl ve asfalt sınıfı ile karışmaktadır. 400

örneklem ile üretilmiş tematik harita ise çakıl sınıfı tuğla sınıfı ile karıştığı görülmüştür.

5.3.2. İki Boyutlu ESA

5.3.2.1. İki Boyutlu Derin Öğrenme Modelinin Performans Analizi


Dört farklı örneklem sayısı ile oluşturulan eğitim veri seti 2 boyutlu evrışimsel sinir ağlarının eğitimi için kullanılmıştır. Bu sinir ağlarında görüntü parçacıkları (patch) kullanılmaktadır. 2 boyut ESA'ların girdi verisi 3 bölümden oluşmaktadır. Bu ESA'da kullanılan görüntü parçacıklarının boyutu 5x5 olarak seçilmiştir. Bu sebeple girdi verisinin bir bölümü bant sayısını içermektedir. Girdi verisinin diğer bölümünü de görüntü parçacıklarının boyutu olarak değerlendirilmektedir. Sinir ağ modelinin eğitimine başlanmadan önce, eğitim veri setine normalleştirme yapılmıştır. Bu aşamanın ardından 2 adet evrışimsel katman kullanılmıştır. İlk katmandaki filtre sayısı 8 olarak seçilmiştir. Bu katmanda kullanılan çekirdek boyutu (kernel size) (5,5) olarak seçilmiştir. Diğer ESA'da ise filtre sayısı 8 olarak seçilirken çekirdek boyutunda (1,1) olarak tercih edilmiştir. Ardından düzleştirme katmanı kullanılmıştır. Yoğunlaştırma katmanındaki birim parametresi 64 ve 128 olarak belirlenmiştir. Seyreltme katmanındaki parametre ise 0,2 olarak kullanılmıştır. Çıktı katmanına kadar tüm katmanlardaki aktivasyon fonksiyonu ReLU kullanılmıştır. Son aşamada ise Softmax aktivasyonu kullanılmıştır. Eğitim esnasında öğrenme hızı 0,001 olarak seçilirken, sönüm parametresi 1e-06 olarak seçilmiştir. Maliyet fonksiyonunda Categorical Crossentropy kullanılmıştır. Optimizasyon parametresi olarak da ADAM kullanılmıştır. Epok sayısı, farklı eğitim seti oranlarında hepsi aynı tutulmuştur ve 500 olarak seçilmiştir. Batch size olarak da 256 seçilmiştir. Eğitim için kullanılan model Tablo 5.6'da özetlenmiştir. Bu tabloya, gösterildiği gibi eğitim esnasında toplam parametre sayısı 61.333'tür. Eğitilebilir parametre sayısı 61.323 iken eğitilemeyen parametre sayısı 10'dur.

Tablo 5.6: Model: "2 Boyutlu ESA".

Katman	Çıktı Boyutu	Parametre
Girdi Katmanı	(Yok, 103, 5, 5)	0
Normalleştirme	(Yok, 103, 5, 5)	20
2B ESA	(Yok, 99, 1, 8)	1.008
2B ESA	(Yok, 99, 1, 8)	72
Düzleştirme Katmanı	(Yok, 792)	0
Yoğunlaştırma Katmanı	(Yok, 64)	50.752
Seyreltme Katmanı	(Yok, 64)	0
Yoğunlaştırma Katmanı	(Yok, 128)	8.320
Seyreltme Katmanı	(Yok, 128)	0
Yoğunlaştırma Katmanı	(Yok, 9)	1.161
Toplam Parametre:	-	61.333
Eğitilebilir Parametre:	-	61.323
Eğitilemeyen Parametre:	-	10

5.3.2.2. İki Boyutlu Derin Öğrenme Modelinin Sınıflandırma Sonuçları ve Doğruluk değerlendirilmesi

Dört farklı eğitim örneklem sayısı (50, 100, 200, 400 örneklem sayısı) ile üretilen veri setleri ayrı ayrı 2 boyutlu derin öğrenme modelinde kullanılmıştır. Sonucunda, derin öğrenme modeline veri seti uygulanarak görüntüye ilişkin 9 arazi sınıfını temsil eden dört farklı tematik harita üretilmiştir (Şekil 5.4).



Şekil 5.4: 2 Boyutlu ESA ile farklı eğitim verileriyle tematik haritalar. a) 50 örneklem. b) 100 örneklem. c) 200 örneklem. d) 400 örneklem.

Sınıflandırma sonucu üretilen tematik haritaların doğruluğunu analiz etmek için yer doğrulama veri seti kullanılarak her tematik harita için hata matrisleri üretilmiştir. Farklı eğitim setleri (sırasıyla 50, 100, 200 ve 400 örneklem sayısı) ile üretilen haritaların sırasıyla genel doğrulukları %82,24, %89,34, %92,37 ve %93,97 hesaplanmıştır. Kappa doğrulukları ise sırayla %86,42, %91,84, %94,20 ve %95,36 olarak hesaplanmıştır. 1 boyutlu ESA'larda olduğu gibi genel olarak bakıldığında örneklem sayısının artması ile birlikte Kappa ve genel doğruluğun arttığı gözlenmiştir. Tüm arazi sınıflarını değerlendirmek için F-skor doğrulukları dört tematik harita için ayrı ayrı üretilmiştir (Tablo 5.7).

Tablo 5.7: 2 Boyutlu ESA için arazi sınıflarının F-skor doğruluk değerleri.

	Her Sınıf için Örneklem Sayısı			
Arazi Sınıfı	50	100	200	400
Asfalt	0,87	0,93	0,97	0,96
Çayır	0,91	0,94	0,95	0,96
Çakıl	0,77	0,87	0,91	0,95
Ağaç	0,93	0,95	0,95	0,97
Metal Çatı	1,00	1,00	1,00	1,00
Çıplak Toprak	0,68	0,82	0,85	0,89
Ziftli Zemin	0,79	0,82	0,91	0,91
Tuğla	0,87	0,91	0,94	0,97
Gölge	0,93	1,00	1,00	1,00
Genel Doğruluk (%)	86,42	91,84	94,20	95,36
Kappa Doğruluğu	0,82	0,89	0,92	0,94
Eğitim süresi (sn)	500,50	500,37	500,27	937,21

Tüm tematik haritalarda Tablo 5.7'ye göre en yüksek doğruluğa sahip arazi sınıfları metal çatı ve gölge sınıfına aittir. Hata matrisine göre F-skor doğruluğu en düşük olan arazi sınıfları çıplak toprak, ziftli zemin ve çakıl sınıfına aittir. 50 örneklem ile üretilen tematik haritada çakıl sınıfı, tuğla arazi sınıfı ile karışmaktadır. Çıplak toprak sınıfı ise çayır sınıfı ile karışmaktadır. 100 örneklem ile üretilen tematik haritada ziftli zemin sınıfı ve çıplak toprak ile en düşük doğruluğa sahiptir. 200

örneklem ile üretilmiş tematik haritada çıplak toprak sınıfı, çayır sınıfı ile karıştığı gözlenmiştir. 400 örneklem ile üretilmiş tematik harita ise 200 örneklem ile üretilen tematik haritada olduğu gibi çıplak toprak ve çayır sınıfı birbirlerine karışmıştır.

5.3.3. Üç Boyutlu ESA

5.3.3.1. Üç Boyutlu Derin Öğrenme Modelinin Performans Analizi

Rastgele olacak şekilde 50, 100, 200 ve 400 örneklemle oluşturulmuş dört farklı eğitim seti 3 boyutlu ESA’larda denenmiştir. 3 boyutlu ESA’ların giriş katmanı 3 bölümden oluşmaktadır. Bu modelde kullanılan girdi verisi (5, 5, 103, 1) şeklindedir. 5x5 görüntü parçacıklarını temsil ederken aynı zamanda uzamsal açıdan da veriyi değerlendirmemizi sağlar, 103 ise toplam bant sayısını temsil etmektedir. Bunun yanında girdi parametresinin son bölümündeki parametre ise değerlendirme için ele alınan bant sayısını temsil etmektedir. Çünkü, bu ESA’larda eğitim ve doğruluk verileri için tercih edilen veriler küp veri olarak adlandırılabilir. Yani, veriyi hem genişlik hem yükseklik hem de bant sayısı olarak değerlendirmek gerekir. Eğitim için üretilen görüntü boyutları 5x5 olarak ayarlanmıştır. Eğitimde kullanılacak veri setlerine normalleştirme yapılmıştır. Ardından 3 adet evrişimsel katman kullanılmıştır. Bu katmanda filtrelerin boyutu 4 olarak seçilirken çekirdek boyutu da 1x1x30 ve 1x1x20 olarak seçilmiştir. Görüntü parçacıklarının boyutu 1x1 olarak tercih edilmiştir. Aktivasyon fonksiyonu olarak ReLU kullanılmıştır. Bu evrişimsel katmanlardan sonra düzleştirme katmanı kullanılmıştır. Bu katmandan sonra yoğunlaştırma katmanı (Dense Layer) ve seyreltme katmanı (Dropout Layer) kullanılmıştır. Yoğunlaştırma katmanındaki parametre birimi 512 ve aktivasyon fonksiyonu ReLU olarak seçilmiştir. Seyreltme katmanındaki parametreler de 0,2, 0,3 ve 0,4 olarak tercih edilmiştir. Ağın en son bölümünde çıktı verisine softmax aktivasyon fonksiyonu kullanılarak eğitim tamamlanmıştır. Eğitim esnasında öğrenme hızı 0.001, sönüm (decay) parametresi 1e-06 olarak seçilmiştir. Maliyet fonksiyonunda Categorical Crossentropy kullanılmıştır. Optimizasyon parametresi olarak da ADAM kullanılmıştır. Epok sayısı, farklı eğitim seti oranlarında hepsi aynı tutulmuştur ve 500 olarak seçilmiştir. Batch size olarak da 256 seçilmiştir. Eğitim için kullanılan model Tablo 5.8’de özetlenmiştir. Bu tabloda


gösterildiği gibi eğitim esnasında toplam parametre sayısı 1.862.577'dir. Eğitilebilir parametre sayısı 1.862.575 iken eğitilemeyen parametre sayısı 2'dir.

Tablo 5.8: Model: "3 Boyutlu ESA".

Katman(tipi)	Çıktı Boyutu	Parametre
Girdi Katmanı	(Yok, 5, 5, 103, 1)	0
Normalleştirme	(Yok, 5, 5, 103, 1)	4
3B ESA	(Yok, 5, 5, 74, 4)	124
3B ESA	(Yok, 5, 5, 45, 4)	484
3B ESA	(Yok, 5, 5, 26, 4)	324
Düzleştirme Katmanı	(Yok, 2.600)	0
Yoğunlaştırma Katmanı	(Yok, 512)	1.331.712
Seyreltme Katmanı	(Yok, 512)	0
Yoğunlaştırma Katmanı	(Yok, 512)	262.656
Seyreltme Katmanı	(Yok, 512)	0
Yoğunlaştırma Katmanı	(Yok, 512)	262.656
Seyreltme Katmanı	(Yok, 512)	0
Yoğunlaştırma Katmanı	(Yok, 9)	4.617
Toplam Parametre:	-	1.862.577
Eğitilebilir Parametre:	-	1.862.575
Eğitilemeyen Parametre:	-	2

5.3.3.2. Üç Boyutlu Derin Öğrenme Modelinin Sınıflandırma Sonuçları ve Doğruluk değerlendirilmesi

Dört farklı üretilen eğitim setleri 3 boyutlu derin öğrenme modelinde kullanılmıştır. Bu eğitim veri setleri kullanılarak 4 adet tematik harita üretilmiştir. Şekil 5.5'te üretilen haritalar gösterilmiştir.



Şekil 5.5: 3 Boyutlu ESA ile farklı eğitim verileriyle tematik haritalar. a) 50 örneklem. b) 100 örneklem. c) 200 örneklem. d) 400 örneklem.

Doğruluk analizi yapmak için yer doğrulama verileri kullanılarak 4 tematik harita için hata matrisleri üretilmiştir. Farklı eğitim setleri (sırasıyla 50, 100, 200 ve 400 örneklem sayısı) ile üretilen haritaların sırasıyla genel doğrulukları %85,57, %91,78, %93,03 ve %97,52 hesaplanmıştır. Kappa doğrulukları ise sırayla %89,00, %93,70, %94,68 ve %98,12 olarak hesaplanmıştır. Bu sonuçlara göre eğitim verisi artması ile beraber genel ve Kappa doğruluğunun arttığı gözlenmiştir. Tablo 5.9’da gösterildiği gibi her tematik haritada bulunan 9 arazi sınıfı için F-skor hesaplanmıştır.

Tablo 5.9: 3 Boyutlu ESA için arazi sınıflarının F-skor doğruluk değerleri.

	Her Sınıf için Örneklem Sayısı			
Arazi Sınıfı	50	100	200	400
Asfalt	0,89	0,93	0,96	0,99
Çayır	0,94	0,97	0,96	0,99
Çakıl	0,85	0,83	0,91	0,95
Ağaç	0,83	0,95	0,94	0,98
Metal Çatı	1,00	1,00	1,00	1,00
Çıplak Toprak	0,79	0,91	0,90	0,96
Ziftli Zemin	0,91	0,87	0,94	0,99
Tuğla	0,81	0,88	0,92	0,96
Gölge	0,98	1,00	1,00	1,00
Genel Doğruluk (%)	89,00	93,70	94,68	98,12
Kappa Doğruluğu	0,86	0,92	0,93	0,98
Eğitim Süreleri (sn)	1138,67	1502,53	2007,01	3038

Tüm tematik haritalarda Tablo 5.9’a göre en yüksek doğruluğa sahip arazi sınıfları metal çatı ve gölge sınıfına aittir. Hata matrisine göre F-skor doğruluğu en düşük olan arazi sınıfları çıplak toprak, tuğla ve çakıl sınıfına aittir. 50 örneklem ile üretilen tematik haritada %84’ün altındaki F-skora sahip sınıflar ağaç, çıplak toprak ve tuğla sınıfıdır. Çıplak toprak sınıfı, çayır sınıfı ile karışmaktadır. Bu sebeple, diğer sınıflar arasında en düşük doğruluğa sahiptir. Ağaç sınıfı da çayır sınıfı ile karışmaktadır. Tuğla sınıfı ise çakıl sınıfı ile karışmaktadır. 100 örneklem ile üretilen tematik haritada %83 doğrulukla en düşük doğruluk çayır sınıfına aittir. Bu sınıf tuğla

sınıfı ile karışmaktadır. Ardından doğrulukları en düşük olan arazi sınıfları, ziftli zemin ve tuğla sınıfıdır. Ziftli zemin sınıfı asfalt sınıfı ile karışmıştır. Tuğla sınıfı ise çakıl ve asfalt sınıfı ile karışmaktadır. 200 örneklem ile üretilmiş tematik haritada en düşük doğruluk çıplak toprak arazi sınıfına aittir. Bu sınıf, çayır sınıfı ile karışmaktadır. 400 örneklem ile üretilmiş tematik harita arazi sınıflarının doğrulukları %95 ve üzeri doğruluğa sahiptir.

5.4. Görüntü Parçacıklarının ESA Performansına Etkisi


5.4.1. Görüntü Parçacık Boyutunun Belirlenmesi

İki veya üç boyutlu YSA uygulamalarında, modelin eğitim aşamasını gerçekleştirebilmesi için sınıflandırma işlemi uygulanacak görüntünün, örneklemelere ait görüntü parçacığı boyutunun belirlenmesi gerekmektedir. Bu durum bilim insanları açısından zorlu bir süreçtir. Bu nedenle tezin bu bölümünde daha önceden yapılmış çalışmalarda kullanılan görüntü parçacıklarının boyutları kullanılmıştır. Paoletti vd. [2018] tarafından yapılan derin öğrenme ile hızlı hiperspektral sınıflandırma uygulamasında Pavia görüntüsü için görüntü parçacıklarını ayrı ayrı 15x15, 21x21 ve 27x27 olarak seçmiş ve karşılaştırmıştır. Tezin bu bölümünde iki ve üç boyutlu ESA'lar için 50, 100, 200 ve 400 örneklem seçilerek farklı görüntü parçacıklarının derin öğrenme modeline olan etkisi incelenmiştir. Ayrıca hem modelin hem de üretilen tematik haritaların doğrulukları hesaplamak için test ve doğrulama veri seti oluşturulmuştur. Bu bölümde tematik haritaların doğruluklarını hesaplamak adına ArcGIS (10.6) yazılımı kullanılarak her arazi sınıfı için 600 adet yer doğrulama verisi seçilmiştir. Ardından bu veri seti ile her üretilen harita için ayrı ayrı Envi (5.1) yazılımı kullanılarak birleştirilmiş ve son olarak da Matlab (2019b) yazılımında ayrı ayrı her haritanın tematik doğruluğu hesaplanmıştır. Veri setlerinin farklı sayıda olmasının sonucunda ortaya çıkan tematik haritaların doğruluklarının anlamlı veya anlamsız olup olmadığı durumu McNemar testi ile test edilmiştir.

Sadece bu uygulamada kullanılan bilgisayarın genel özellikleri, işlemcisi Intel(R) Core(TM) i9-10940X CPU @ 3.30GHz, RAM 128 GB ve işlem sistemi Windows 10 Pro olup 64-bit'tir ve ekran kartı olarak NVIDIA GeForce RTX 2070 SUPER kullanılmıştır.

5.4.2. Görüntü Parçacık Boyutunun 2B ESA'ya Etkisi ve Doğruluk Analizi

Bu bölümde, ilk uygulamada oluşturulmuş iki boyutlu derin öğrenme modeli olan ESA kullanılmıştır. Aynı şekilde eğitim veri seti olarak ilk uygulamada da olduğu gibi 50, 100, 200, 400 olarak ayrılmış rastgele örneklemeler kullanılmıştır. Bu uygulamada, ilk uygulamada oluşturulan 2 boyutlu derin öğrenme modeli kullanılmıştır. 50, 100, 200 ve 400'lu eğitim veri seti için 15x15, 21x21 ve 27x27 görüntü parçacıklarını içeren örneklemeler hazırlanmıştır. Eğitim aşamasının durdurulması, modelin eğitime bağlı olarak, modelin doğruluğu ve maliyet fonksiyonun sonucuna göre gerçekleştirilmiştir. Çünkü görüntü parçacıklarının boyutları değiştiği için modelin eğitimi de değişmektedir. Bu nedenle, eğitim için belli bir epok sayısı belirlenmemiştir. Model aşırı öğrenmeye başlayınca eğitim kendi kendini durdurmuştur. 2 boyutlu ESA'lar ile ayrı ayrı 12 adet 9 arazi sınıfını temsil eden tematik haritalar üretilmiştir (Şekil 5.6). İlaveten, bu 12 tematik haritanın tüm arazi sınıflarının doğrulukları değerlendirmek için F-skor değerleri hesaplanmıştır. İlk olarak 15x15 görüntü parçacıklarının kullanıldığı tematik haritalar üretilmiştir.



Şekil 5.6: 15x15 görüntü parçacıkları kullanılarak 2B ESA ile farklı eğitim verileriyle tematik haritalar. a) 50 örneklem. b) 100 örneklem. c) 200 örneklem. d) 400 örneklem.


50, 100, 200 ve 400 eğitim örneklem sayısı ve 15x15 görüntü parçacıkları ile üretilen haritaların sırasıyla genel doğrulukları %88,06, %91,22, %95,06 ve %98,52 hesaplanmıştır. Kappa doğrulukları ise sırayla 0,87, 0,90, 0,94 ve 0,98 olarak hesaplanmıştır. Tüm modellerin eğitim süresi Tablo 5.10'da gösterilmektedir. Genel olarak bakıldığında örneklem sayısının artması doğruluklarında arttığı gözlenmiştir. Ayrıca, bu tabloda tüm arazi sınıflarının F-skor değerleri gösterilmiştir.

Tablo 5.10: 15x15 görüntü parçacıkları kullanılarak eğitilmiş 2 Boyutlu ESA için arazi sınıflarının F-skor doğruluk değerleri.

	Her Sınıf için Örneklem Sayısı			
Arazi Sınıfı	50	100	200	400
Asfalt	0,82	0,86	0,94	0,96
Çayır	0,86	0,91	0,90	0,99
Çakıl	0,75	0,82	0,92	0,96
Ağaç	0,99	0,96	0,99	1,00
Metal Çatı	0,99	0,99	1,00	1,00
Çıplak Toprak	0,82	0,87	0,89	0,99
Ziftli Zemin	0,86	0,91	0,96	0,97
Tuğla	0,81	0,86	0,92	0,97
Gölge	0,99	0,98	0,99	0,99
Genel Doğruluk (%)	88,06	91,22	95,06	98,52
Kappa Doğruluğu	0,87	0,90	0,94	0,98
Eğitim Süresi (saniye)	43,20	226,1391	144,05	172,04

15x15 görüntü parçacıkları ile üretilen tematik haritalarda en yüksek doğruluk metal çatı ve gölge sınıflarına aittir. Haritaların doğruluklarını kontrol etmek için oluşturulan hata matrisine göre 50 ve 100 örneklemle oluşturulmuş tematik haritalarda en düşük doğruluğa sahip arazi sınıfı çakıl sınıfıdır. Çakıl sınıfının özellikle asfalt, tuğla ve ziftli zemin sınıfları ile karıştığı hem tematik haritalarda hem de hata matrisinde gözükmemektedir. 200 örneklemle üretilmiş haritada ise en düşük doğruluğa sahip arazi sınıfı çıplak topraktır. Bu arazi sınıfının çayır sınıfı ile karıştığı gözlenmektedir. 400 örneklemle üretilmiş harita da ise tüm sınıfların F-Skor doğrulukları %96 üzerindedir.

Ardında eğitim ve test için seçilecek örneklemelerin görüntü boyutu 15x15'den 21x21'e çıkartılmıştır ve 2 boyutlu ESA'da kullanılmıştır. Eğitim aşaması tamamlandıktan sonra 4 farklı örneklem sayısı ile dokuz arazi sınıfını temsil eden 4 adet tematik harita üretilmiş ve tüm bu haritaların tematik doğrulukları hesaplanmıştır. Şekil 5.7'de 21x21 görüntü parçacıkları kullanılarak oluşturulmuş tematik haritalar gösterilmiştir. Tematik harita üretim aşaması ilk uygulamada olduğu gibidir.



Şekil 5.7: 21x21 görüntü parçacıkları kullanılarak 2B ESA ile farklı eğitim verileriyle tematik haritalar. a) 50 örneklem. b) 100 örneklem. c) 200 örneklem. d) 400 örneklem.

Sınıflandırma aşaması ardından bu haritaların genel ve Kappa doğrulukları hesaplanmıştır. Farklı eğitim setleri (sırasıyla 50, 100, 200 ve 400 örneklem sayısı) ile

retilen haritaların sırasıyla genel doęrulukları %86,63, %91,57, %95,85 ve %97,85 iken Kappa doęrulukları ise sırayla 0,85, 0,91, 0,95 ve 0,98 olarak hesaplanmıřtır. Bu sonulara gre rneklem sayısının artması retilen haritaların doęruluklarının etkilemiřtir. Her bir tematik harita iin 9 arazi sınıfını deęerlendirmek amacıyla kullanıcı ve retici doęruluklarının harmonik ortalaması ile tretilen F-skor doęrulukları drt tematik harita iin ayrı ayrı retilmiřtir (Tablo 5.11).


Tablo 5.11: 21x21 grnt paracıkları kullanılarak eęitilmiř 2 Boyutlu ESA iin arazi sınıflarının F-skor doęruluk deęerleri.

	Her Sınıf iin rneklem Sayısı			
Arazi Sınıfı	50	100	200	400
Asfalt	0,82	0,87	0,91	0,94
ayır	0,82	0,87	0,95	0,98
akıl	0,76	0,87	0,93	0,96
Aęa	0,98	0,98	0,99	0,99
Metal atı	0,99	1,00	1,00	1,00
ıplak Toprak	0,76	0,83	0,94	0,98
Ziftli Zemin	0,82	0,91	0,95	0,97
Tuęla	0,84	0,90	0,93	0,96
Glge	0,97	0,97	0,99	0,99
Genel Doęruluk (%)	86,63	91,57	95,85	97,85
Kappa Doęruluęu	0,85	0,91	0,95	0,98
Eęitim Sresi (sn)	205,41	167,167	129,08	170,04

Tm tematik haritalarda Tablo 5.11'e gre en yksek doęruluęa sahip arazi sınıfları metal atı sınıfına aittir. Arından en yksek doęruluęa sahip arazi sınıfının aęa ve metal atı sınıfları olduęu sylenebilir. Bu tabloya gre 50 rneklemle retilmiř haritada F-skor doęruluęu en dřk olan arazi sınıfları akıl ve ıplak topraktır. ıplak toprak sınıfı ayır arazi sınıfı ile karıřırken, akıl sınıfı ise ziftli zemin ve tuęla sınıfları ile karıřmaktadır. 100 rneklemle retilmiř tematik haritanın en dřk F-skor doęruluęuna sahip arazi sınıfı ise ıplak toprak sınıfıdır. Bu sınıf da ayır sınıfı ile karıřtıęı hem tematik haritada hem de hata matrisinde gzlenmektedir. 200

ve 400 örneklemele üretilmiş tematik haritalarda ise en düşük F-skor doğruluğu asfalt sınıfına aittir. Bu arazi sınıfı çakıl, ziftli zemin ve tuğla sınıfı ile karışmaktadır.

Bu aşamadan sonra 27x27'lik görüntü parçacıkları ile 2 Boyutlu ESA kullanılarak farklı örneklemlerle 4 farklı tematik harita üretilmiştir. İlaveten bu üretilen tematik haritaların genel ve Kappa doğrulukları hesaplanmıştır. Şekil 5.8'de 9 arazi sınıfını temsil eden 4 adet tematik harita gösterilmiştir.



Şekil 5.8: 27x27 görüntü parçacıkları kullanılarak 2B ESA ile farklı eğitim verileriyle tematik haritalar. a) 50 örneklem. b) 100 örneklem. c) 200 örneklem. d) 400 örneklem.

Sınıflandırma işlemi ardından üretilen tematik haritaların doğruluğunu analiz etmek için hata matrisleri üretilmiştir. Farklı sayıda eğitim setleri (sırasıyla 50, 100,

200 ve 400 örneklem sayısı) ile üretilen tematik haritaların sırasıyla genel doğrulukları %88,61, %94,28, %97,00 ve %98,59, Kappa doğrulukları ise sırayla 0,87, 0,94, 0,97 ve 0,98 olarak hesaplanmıştır. Örneklem sayısının artması haritaların doğruluklarını doğrudan olumlu olarak etkilenmiştir. Tüm arazi sınıflarını değerlendirmek için F-skor doğrulukları dört tematik harita için ayrı ayrı üretilmiştir (Tablo 5.12).

Tablo 5.12: 27x27 görüntü parçacıkları kullanılarak eğitilmiş 2 Boyutlu ESA için arazi sınıflarının F-skor doğruluk değerleri.


	Her Sınıf için Örneklem Sayısı			
Arazi Sınıfı	50	100	200	400
Asfalt	0,85	0,91	0,94	0,96
Çayır	0,78	0,90	0,95	0,98
Çakıl	0,85	0,91	0,97	0,97
Ağaç	0,98	0,97	0,98	0,99
Metal Çatı	1,00	1,00	1,00	1,00
Çıplak Toprak	0,75	0,90	0,94	0,98
Ziftli Zemin	0,92	0,92	0,96	0,97
Tuğla	0,84	0,95	0,96	0,98
Gölge	0,97	0,98	0,99	0,99
Genel Doğruluk (%)	88,61	94,28	97,00	98,59
Kappa Doğruluğu	0,87	0,94	0,97	0,98
Eğitim Süresi (sn)	188,56	228,244	200,1	306,10

Tüm tematik haritalarda Tablo 5.12'ye göre en yüksek doğruluğa sahip arazi sınıfları metal çatı ve gölge sınıflarına aittir. 50 ve 100 örneklemle üretilmiş haritada F-skor doğruluğu en düşük olan arazi sınıfları çayır ve çıplak topraktır. Bu iki arazi sınıfları birbirleri ile karışmaktadır. 200 ve 400 örneklemle üretilmiş tematik haritalarda ise en düşük F-skor doğruluğu asfalt sınıfına aittir. Bu arazi sınıfı, ziftli zemin ile karıştığı hata matrislerinden çıkartılmaktadır.

5.4.3. Görüntü Parçacık Boyutunun 3B ESA'ya Etkisi ve Doğruluk Analizi

Bu bölümde, ilk uygulamada oluşturulmuş üç boyutlu ESA modeli kullanılmıştır. Veri seti olarak Pavia Üniversitesinin hiperspektral görüntüsü seçilmiştir. Aynı şekilde eğitim veri seti olarak 50, 100, 200, 400 olarak ayrılmış rastgele örneklemeler kullanılmıştır. Bu uygulamada, ilk uygulamada oluşturulan 3 boyutlu ESA modeli kullanılmıştır. 50, 100, 200 ve 400'lu eğitim veri seti için 15x15, 21x21 ve 27x27 görüntü parçacıklarını içeren örneklemeler hazırlanmıştır. Eğitim aşamasının durdurulması, modelin eğitime bağlı olarak, modelin doğruluğu ve maliyet fonksiyonun sonucuna göre gerçekleştirilmiştir. Çünkü görüntü parçacıklarının boyutları değiştiği için modelin eğitimi de değişmektedir. Bu nedenle, eğitim için belli bir epok sayısı belirlenmemiştir. 3 boyutlu ESA'lar ile ayrı ayrı 12 adet 9 arazi sınıfını temsil eden tematik haritalar üretilmiştir. Ek olarak, bu üretilen 12 tematik haritanın tüm arazi sınıflarının doğrulukları değerlendirmek için F-skor değerleri hesaplanmıştır.

Uygulamanın bu bölümünde ilk olarak 15x15'lik görüntü parçacıkları ile 3 boyutlu ESA kullanılarak sınıflandırma işlemi yapılmıştır. Diğer uygulamalarda olduğu gibi farklı örneklemeler kullanılarak ayrı ayrı değerlendirilmiştir. 15x15'lik görüntü parçacıkları örneklemeler kullanılarak eğitim aşaması tamamlanmış ve farklı örneklem sayısı içeren 4 adet tematik harita üretilmiştir. Şekil 5.9'da 9 arazi sınıfını temsil eden tematik haritalar gösterilmiştir. Tematik haritaların doğrulukları incelemek için her bir haritaya ait genel ve Kappa doğrulukları hesaplanmıştır. Ayrıca tüm haritalarda bulunan arazi sınıflarının doğruluklarını incelemek içinde F-skor değerleri ayrı ayrı hesaplanmıştır.



Şekil 5.9: 15x15 görüntü parçacıkları kullanılarak 3B ESA ile farklı eğitim verileriyle tematik haritalar. a) 50 örneklem. b) 100 örneklem. c) 200 örneklem. d) 400 örneklem.

Tablo 5.13'e göre farklı eğitim setleri (sırasıyla 50, 100, 200 ve 400 örneklem sayısı) ile üretilen haritaların sırasıyla genel doğrulukları %91,37, %95,72, %97,06 ve


%99,35 hesaplanmıştır. Kappa doğrulukları ise sırayla 0,90, 0,95, 0,97 ve 0,99 olarak hesaplanmıştır. Tüm arazi sınıflarını değerlendirmek F-skor doğrulukları dört tematik harita için ayrı ayrı üretilmiştir (Tablo 5.13).

Tablo 5.13: 15x15 görüntü parçacıkları kullanılarak eğitilmiş 3 Boyutlu ESA için arazi sınıflarının F-skor doğruluk değerleri.

	Her Sınıf için Örneklem Sayısı			
Arazi Sınıfı	50	100	200	400
Asfalt	0,87	0,91	0,94	0,98
Çayır	0,91	0,99	0,96	1,00
Çakıl	0,83	0,90	0,95	0,99
Ağaç	0,97	0,99	0,99	1,00
Metal Çatı	1,00	1,00	1,00	1,00
Çıplak Toprak	0,88	0,98	0,96	0,99
Ziftli Zemin	0,92	0,94	0,96	0,99
Tuğla	0,83	0,89	0,94	0,98
Gölge	0,98	0,99	0,99	0,98
Genel Doğruluk (%)	91,37	95,72	97,06	99,35
Kappa Doğruluğu	0,90	0,95	0,97	0,99
Eğitim Süresi (sn)	362,72	302,30	101,07	198,05

Tüm tematik haritalarda Tablo 5.13'e göre en yüksek doğruluğa sahip arazi sınıfları metal çatı sınıfına aittir. Hata matrisine göre F-skor doğruluğu en düşük olan arazi sınıfları tuğla sınıfına aittir. Tematik haritalar ve hata matrisleri incelendiği vakit tuğla sınıfının çakıl sınıfı ile karıştığı gözlenmektedir. 400 örneklem haritalarda en düşük F-skor doğruluğu %98 civarındadır.

Ardından 3 boyutlu ESA'da 21x21'lik görüntü parçacıkları eğitim veri setinde kullanılmıştır. Farklı örneklem sayılarına kullanılarak ayrı ayrı sınıflandırma işlemi yapılmıştır. Bu aşama tamamlandıktan sonra 4 adet tematik harita üretilmiştir (Şekil 5.10).



Şekil 5.10: 21x21 görüntü parçacıkları kullanılarak 3B ESA ile farklı eğitim verileriyle tematik haritalar. a) 50 örneklem. b) 100 örneklem. c) 200 örneklem. d) 400 örneklem.

Üretilen her bir tematik harita için hata matrisi kullanılarak genel ve Kappa doğruluğu hesaplanmıştır. 50, 100, 200 ve 400 örneklem kullanılan haritalarda


sırasıyla genel doğrulukları %90,81, %96,24, %98,11 ve %99,52 olarak hesaplanmıştır. Kappa doğrulukları ise sırayla 0,90, 0,96, 0,98 ve 0,99 olarak hesaplanmıştır (Tablo 5.14).

Tablo 5.14: 21x21 görüntü parçacıkları kullanılarak eğitilmiş 3 Boyutlu ESA için arazi sınıflarının F-Skor doğruluk değerleri (%)

	Her Sınıf için Örneklem Sayısı			
Arazi Sınıfı	50	100	200	400
Asfalt	0,87	0,91	0,95	1,00
Çayır	0,82	0,99	0,99	0,99
Çakıl	0,90	0,92	0,98	0,99
Ağaç	0,97	0,98	0,98	0,99
Metal Çatı	0,99	0,99	1,00	1,00
Çıplak Toprak	0,80	0,98	0,99	0,99
Ziftli Zemin	0,93	0,96	0,96	0,99
Tuğla	0,87	0,91	0,95	0,98
Gölge	0,98	0,99	0,99	0,99
Genel Doğruluk (%)	90,81	96,24	98,11	99,52
Kappa Doğruluğu	0,90	0,96	0,98	0,99
Eğitim Süresi (sn)	484,45	321,00	202,10	226,07

Tüm arazi sınıflarının F-skor doğrulukları Tablo 5.14'te yer almaktadır. Bu tabloya göre en yüksek doğruluk metal çatı arazi sınıfına aittir. Tablo 5.14'e göre 50 örneklemle üretilmiş haritada F-skor doğruluğu en düşük olan arazi sınıfı çıplak topraktır. Çıplak toprak sınıfı çayır arazi sınıfı ile karışmaktadır. 100 örneklemle üretilmiş tematik haritanın en düşük F-skor doğruluğuna sahip arazi sınıfları ise tuğla ve asfalt sınıfıdır. Asfalt sınıfı, ziftli zemin arazi sınıfı ile karışırken, tuğla sınıfı ise çakıl arazi sınıfı ile karışmaktadır. 200 ve 400 örneklemli haritalarda sırasıyla en düşük F-skor değerleri ise %95 ve %98 civarındadır.

Son olarak 3 boyutlu ESA'da 27x27 görüntü parçacıkları kullanılarak eğitim aşaması tamamlanmıştır. Bu eğitim sonucunda 4 farklı tematik harita üretilmiştir. Şekil 5.11'de üretilen tematik haritalar ve lejantı yer almaktadır.



Şekil 5.11: 27x27 görüntü parçacıkları kullanılarak 3B ESA ile farklı eğitim verileriyle tematik haritalar. a) 50 örneklem. b) 100 örneklem. c) 200 örneklem. d) 400 örneklem.

Üretilen her bir tematik harita için genel ve Kappa doğrulukları hesaplanmıştır. Farklı eğitim setleri (sırasıyla 50, 100, 200 ve 400 örneklem sayısı) ile üretilen

haritaların sırasıyla genel doğrulukları %87,17, %95,98, %97,33 ve %99,43 iken Kappa doğrulukları ise sırayla 0,86, 0,95, 0,97 ve 0,99 olarak hesaplanmıştır (Tablo 5.15).

Tablo 5.15: 27x27 görüntü parçacıkları kullanılarak eğitilmiş 3 Boyutlu ESA için arazi sınıflarının F-Skor doğruluk değerleri.

	Her Sınıf için Örneklem Sayısı			
Arazi Sınıfı	50	100	200	400
Asfalt	0,76	0,92	0,91	0,98
Çayır	0,86	0,93	0,99	0,99
Çakıl	0,70	0,98	0,97	1,00
Ağaç	0,94	0,98	0,98	0,99
Metal Çatı	0,99	1,00	1,00	1,00
Çıplak Toprak	0,85	0,92	0,99	0,99
Ziftli Zemin	0,91	0,96	0,95	0,99
Tuğla	0,81	0,94	0,95	0,99
Gölge	0,99	0,97	0,98	0,99
Genel Doğruluk (%)	87,17	95,98	97,33	99,43
Kappa Doğruluğu	0,86	0,95	0,97	0,99
Eğitim Süresi (sn)	1001,50	657,66	234,15	345,07

Tablo 5.15'te yer alan diğer doğruluklar ise arazi sınıflarına ait F-skor doğruluklarıdır. 50 örneklem ile üretilmiş tematik haritada F-skor doğruluğu en yüksek olan arazi sınıfları gölge ve metal çatıdır. 100 ve 200 örneklem ile üretilmiş tematik haritalarda en yüksek F-skor doğruluğu metal çatı arazi sınıfıdır. 400 örneklem üretilmiş haritada ise en yüksek doğruluk hem çakıl hem de metal çatı sınıflarına aittir. 50 örneklem ile oluşturulmuş haritada en düşük F-skor doğruluğu çakıl sınıfına aittir. Hata matrisine göre bu arazi sınıfı, asfalt ve tuğla sınıfları ile karışmaktadır. 100 örneklem ile üretilmiş tematik harita en düşük doğruluğa sahip arazi sınıfları çıplak toprak ve asfalt sınıflarına aittir. Asfalt sınıfı ziftli zemin sınıfı ile karışırken, çıplak toprak sınıfı ise çayır sınıfı ile karışmaktadır. 200 örneklem ile üretilmiş harita ise en düşük F-skor doğruluğu asfalt sınıfına aittir. Bu sınıf, ziftli zemin, tuğla ve çakıl arazi

sınıfları ile karışmaktadır. 400 örneklem ile üretilmiş harita ise en düşük F-skor doğruluğu %98 civarındadır.

5.4.4. Farklı Görüntü Parçacıklarının ve Farklı Sayıda Örneklem Kullanılmasının Karşılaştırılması

Tezin bu bölümünde 15x15, 21x21 ve 27x27 görüntü parçacıklarının tematik haritaların doğruluklarını nasıl etkilediği incelenmiştir. Tüm haritaların Kappa ve genel doğrulukları tablolar halinde özetlenmiştir. İlk olarak 15x15'lik görüntü parçacıklarının kullanıldığı 2 ve 3 boyutlu ESA'dan üretilen tematik haritaların doğrulukları Tablo 5.16'da yer almaktadır. Bu tablo incelendiğinde en yüksek genel doğruluk %99'lere varırken en genel düşük doğruluk ise %88 civarındadır.

Tablo 5.16: 15x15 görüntü parçacıkları kullanılarak eğitilmiş 2 ve 3 Boyutlu ESA'ların genel ve Kappa doğrulukları.

		15x 15 Görüntü Parçacığı			
		Örneklem Sayısı			
		50	100	200	400
3B	Genel Doğruluk (%)	91,37	95,72	97,06	99,35
	Kappa Doğruluğu	0,90	0,95	0,97	0,99
2B	Genel Doğruluk (%)	88,06	91,22	95,06	98,52
	Kappa Doğruluğu	0,87	0,90	0,94	0,98

Ardından 21x21'lik görüntü parçacıklarının kullanıldığı 2 ve 3 boyutlu ESA'dan üretilen tematik haritaların doğrulukları Tablo 5.17'de yer almaktadır. Bu tablo incelendiğinde en yüksek genel doğruluk %99'lere varırken en düşük genel doğruluk ise %86 civarındadır.

Tablo 5.17: 21x21 görüntü parçacıkları kullanılarak eğitilmiş 2 ve 3 Boyutlu ESA'ların genel ve Kappa doğrulukları.

		21x21 Görüntü Parçacığı			
		Örneklem Sayısı			
		50	100	200	400
3B	Genel Doğruluk (%)	90,81	96,24	98,11	99,52
	Kappa Doğruluğu	0,90	0,96	0,98	0,99
2B	Genel Doğruluk (%)	86,63	91,57	95,85	97,85
	Kappa Doğruluğu	0,85	0,91	0,95	0,98


27x27'lik görüntü parçacıklarının kullanıldığı 2 ve 3 boyutlu ESA'dan üretilen tematik haritaların doğrulukları Tablo 5.18'de yer almaktadır. Bu tablo incelendiğinde en yüksek genel doğruluk %99'lere varırken en düşük genel doğruluk ise %88 civarındır.

Tablo 5.18: 27x27 görüntü parçacıkları kullanılarak eğitilmiş 2 ve 3 Boyutlu ESA'ların genel ve Kappa doğrulukları.

		27x27 Görüntü Parçacığı			
		Örneklem Sayısı			
		50	100	200	400
3B	Genel Doğruluk (%)	87,17	95,98	97,33	99,43
	Kappa Doğruluğu	0,86	0,95	0,97	0,99
2B	Genel Doğruluk (%)	88,61	94,28	97,00	98,59
	Kappa Doğruluğu	0,87	0,94	0,97	0,98

Bu tablolar göz önünde alınarak bir grafik oluşturulmuştur (Şekil 5.12). Bu grafik incelendiğinde görüntü parçacıklarının derin öğrenme modeline olan etkisi açık bir şekilde görülmektedir. Özellikle, 3 boyutlu ESA ile üretilen haritalarda en yüksek genel ve Kappa doğruluğu 21x21'lik görüntü parçacıklarının kullanıldığı eğitimlerde gözlenmiştir. Ardından ise 50 örneklem ile üretilmiş haritalar dışında, 21x21'lik görüntü parçacıkları ile üretilmiş haritaların, 27x27'lik görüntü parçaları ile üretilmiş haritalar ile benzer doğruluklar verdiği Şekil 5.12'de görülmektedir. 2 boyutlu ESA'larda ise 27x27'lik görüntü parçacıklarının kullanılarak üretilmiş tematik

haritalarda en yüksek genel ve Kappa doğruluğu mevcuttur. 15x15'lik ve 21x21'lik görüntü parçacıklı modellerde örneklem sayısına göre doğruluğu arttığı veya azaldığı görülmektedir. Kısacası görüntü parçacığı boyutunun ideal olanının derin öğrenme modelinin eğitimi esnasında seçilmelidir. Bir derin öğrenme uygulanmasında veri türü, derin öğrenme modelinin boyutu, örneklem sayısı gibi faktörler de göz önüne alınmalıdır. Yapılacak uygulamanın özelliklerine göre eğitim verisine ait görüntü parçacıklarının en uygun boyutu seçilmelidir.



Şekil 5.12: Farklı görüntü parçacıklarının kullanıldığı derin öğrenme modellerinin genel doğruluklarının farklı veri setleri ile olan ilişkisi.

Görüntü parçağını uygulamasına ilaveten bir de eğitim için seçilen örneklem sayısının ESA'yı nasıl etkilediği istatistiksel bir yaklaşım olan serbestlik derecesine bağlı χ^2 testine dayandırılan McNemar testi ile bu bölümde kullanılmıştır. Bu yöntem, tek bir veri kümesinin kullanıldığı iki farklı yöntem sonucunda üretilen sonuçlar arasında anlamlı bir fark olup olmadığını göstermektedir [Kesikoglu vd., 2019]. Bu test, 50 ve 100 örneklem, 50 ve 200 örneklem, 50 ve 400 örneklem, 100 ve 200 örneklem ve son olarak 200 ve 400 örneklem kullanılarak üretilmiş tematik haritalar üzerinde yapılmıştır. Bu test %95 güven aralığında gerçekleştirilmiştir. Ayrı ayrı test edilerek çıkan değerler χ^2 tablosundaki 3,84'ten büyük olup olmadığı incelenmiştir. 2 boyutlu ESA'larda üretilen McNemar değerleri Tablo 5.19'da yer almaktadır. Bu değerlerin hepsi 3,84'ten büyük olduğu için istatistiksel açıdan anlamlıdır. Örneklem sayısının artması, tematik harita doğruluğunun artmasının anlamlı olduğu bu şekilde ispatlanmaktadır.

Tablo 5.19: 2 Boyutlu ESA'lara uygulanmış McNemar testi sonuçları.

2B			
15x15 Görüntü Parçacığı			
Örneklem	100	200	400
50	6.19	14.43	22.92
100	-	7.48	18.63
200	-	-	10.90
21x21 Görüntü Parçacığı			
Örneklem	100	200	400
50	8.92	18.41	22.41
100	-	10.84	15.79
200	-	-	7.75
27x27 Görüntü Parçacığı			
Örneklem	100	200	400
50	11.77	18.95	22.87
100	-	7.76	13.24
200	-	-	6.15

2 boyutlu ESA'lar ile elde edilmiş görüntülerin doğrulukları ve McNemar değerleri karşılaştırıldığından en yüksek McNemar değerleri yaklaşık 22 olarak hesaplanmıştır (Tablo 5.19). Bu değerler 50 ile 400 örneklem ile üretilmiş haritalarda ortaya çıkmaktadır. Tüm farklı görüntü parçacıkları uygulamalarında bu iki harita arasında genel doğruluk farkları yaklaşık %10 civarındadır. En düşük McNemar değerleri yaklaşık 6 olarak hesaplanmıştır (Tablo 5.19). Bu değer ise 15x15 görüntü parçacığı uygulanmasında 50 ile 100 örneklem arasında ve 27x27 görüntü parçacığı uygulanmasında 200 ile 400 örneklem arasında bulunmuştur. Bu iki harita arasında genel doğruluk farkları sırasıyla yaklaşık %3 ve %2 civarındadır.

McNemar testi 3 boyutlu ESA'lar için gerçekleştirilmiştir. Tablo 5.19'da 3 boyutlu ESA'lara uygulanmış McNemar test sonuçları yer almaktadır. 15x15, 21x21 ve 27x27'lik görüntü parçacıkları kullanılan ESA'larda çıkan sonuçların hepsi

3,84'ten büyük olduğu için farklı sayıda örneklem kullanmanın anlamlı olduğu ve bu örneklem sayısına bağlı olarak ESA'ların ürettiği sonuçları değiştirebileceği söylenebilir.

Tablo 5.20: 3 Boyutlu ESA'lara uygulanmış McNemar testi sonuçları.

3B			
15x15 Görüntü Parçacığı			
Örneklem	100	200	400
50	9.83	14.41	19.64
100	-	5.34	12.69
200	-	-	8.36
21x21 Görüntü Parçacığı			
Örneklem	100	200	400
50	15.71	16.79	22.08
100	-	4.45	11.68
200	-	-	8.07
27x27 Görüntü Parçacığı			
Örneklem	100	200	400
50	18.33	20.28	25.11
100	-	5.47	12.20
200	-	-	8.70

3 boyutlu ESA'lar ile elde edilmiş görüntülerin doğrulukları ve McNemar değerleri karşılaştırıldığından en yüksek McNemar değerleri yaklaşık 25 olarak hesaplanmıştır (Tablo 5.20). Bu değerler 27x27 görüntü parçacığı uygulanmasında 50 ile 400 örneklem ile üretilmiş haritalarda ortaya çıkmaktadır. Bu iki harita arasında genel doğruluk farkları yaklaşık %12 civarındadır. En düşük McNemar değerleri yaklaşık 4 olarak hesaplanmıştır (Tablo 5.20). Bu değer ise 21x21 görüntü parçacığı uygulanmasında 100 ile 200 örneklem arasında bulunmuştur. Bu iki harita arasında genel doğruluk farkları yaklaşık %2 civarındadır.

5.5. Başarım İyileştirme Tekniklerinin ESA'lara Uygulanması

YSA derin öğrenme modellerinin ağ mimarisinin ideal bir şekilde kurulabilmesi için derin öğrenme modeli için en uygun parametrelerin seçilmesi gerekmektedir. Ancak derin öğrenme modellerinin karmaşık yapıdaki problemleri çözebilmesi için ağ içi ideal parametrelerin bulunması zordur. Bu nedenle, derin öğrenme ile uğraşan kullanıcının bu konuda deneyimli olması gerekmektedir. Çünkü, bir derin öğrenme ağının eğitimi sırasında eğer uygun parametreler seçilmediyse, bu model aşırı veya yetersiz öğrenme durumu ile karşılaşabilir. Başarım iyileştirme teknikleri ile bu durumun önüne geçilebilmektedir.

Çalışmanın bu bölümünde ilk uygulamada olduğu gibi aynı 3 boyutlu ESA mimarisi kullanılmıştır ve bu bölümdeki tüm uygulamalar için eğitim esnasında kullanılacak örneklem sayısı 400 olarak seçilmiştir. Ancak, ilk aşamada bu ESA'nın içindeki tüm başarım iyileştirme parametreleri ve yöntemlerinden arındırılmıştır. Ardından, ayrı ayrı olacak biçimde başarım iyileştirme uygulanmamış ESA'ya erken durdurma metodu, düğüm seyreltme katmanının eklenmesi, standart başarım iyileştirme parametresinin kullanılması ve son olarak da yığın normalizasyon tekniğinin uygulanması ile 4 farklı ESA oluşturulmuştur. Üretilen bu 3 boyutlu ESA'lar birbirleri ile karşılaştırılmıştır. Başarım iyileştirme tekniklerinin sinir ağına yaptığı etkiler incelenmiştir.


5.5.1. Başarım İyileştirme Teknikleri Kullanılmadan Oluşturulmuş ESA ve Sonucu

İlk uygulamada oluşturulan 3 boyutlu ESA mimarisi kullanılmıştır. Ancak oluşturulan bu ağda sadece evrişimsel katman, düzleştirme katmanı ve yoğunlaştırma katmanı kullanılmıştır. Bu ağ için ADAM optimizasyon algoritması ve ReLU/Softmax aktivasyon fonksiyonları tercih edilmiştir. Modelin öğrenme hızı 0,001 olarak seçilmiş ve kategorik çapraz entropi ile de maliyet fonksiyonu hesaplanmıştır. Öğrenme işlemi 200 epok ve 400 eğitim verisi ile tamamlanmıştır. Ancak bu modelin eğitimi sırasında aşırı öğrenme gerçekleştiği görülmüştür. Tablo 5.21'de eğitim için kullanılan model özetlenmiştir.

Tablo 5.21: Model: "Başarım iyileştirme teknikleri kullanılmadan oluşturulmuş ESA"


Katman(tipi)	Çıktı Boyutu	Parametre
Girdi Katmanı	(Yok, 5, 5, 103, 1)	0
3B ESA	(Yok, 5, 5, 74, 4)	124
3B ESA	(Yok, 5, 5, 45, 4)	484
3B ESA	(Yok, 5, 5, 26, 4)	324
Düzleştirme Katmanı	(Yok, 2.600)	0
Yoğunlaştırma Katmanı	(Yok, 512)	1.331.712
Yoğunlaştırma Katmanı	(Yok, 512)	262.656
Yoğunlaştırma Katmanı	(Yok, 512)	262.656
Yoğunlaştırma Katmanı	(Yok, 9)	4.617
Toplam Parametre:	-	1.862.573
Eğitilebilir Parametre:	-	1.862.573
Eğitilemeyen Parametre:	-	0

Sınıflandırma için kullanılan modelin eğitim işlemi tamamlandıktan sonra modelin doğruluğunu ve maliyeti içeren bir grafik çizdirilmiştir. Bu grafikte modelin test maliyeti, test doğruluğu, eğitim maliyeti ve eğitim doğruluğu değerleri yer almaktadır (Şekil 5.13). Başarım iyileştirme teknikleri kullanılmadan oluşturulmuş derin öğrenme modelinin, grafiğe bakarak aşırı öğrenme yaşadığı söylenebilir. Bunun en büyük nedeni, test maliyetinin azalması beklenirken artmasından kaynaklanmaktadır. Eğitim maliyeti ile test maliyetinin arasındaki değerin açılması da modelin iyi oluşturulmadığına işarettir. Bu nedenle bu modele başarım iyileştirme tekniklerinin uygulanması gerekir.



Şekil 5.13: Başarım iyileştirme teknikleri kullanılmadan oluşturulmuş ESA'nın doğruluk/maliyet grafiği.

Oluşturulan derin öğrenme modeline, veri seti uygulanarak görüntüye ilişkin 9 arazi sınıfını temsil eden bir adet tematik harita üretilmiştir (Şekil 5.14). Eğitimden sonra üretilen tahmin verisini etiketli veri olarak txt formatında kayıt edilmiştir. Ardından ERDAS yazılımında çıktı verisi img olarak farklı kayıt edilmiştir. Son görselleştirme aşaması için ArcGIS yazılımı kullanılmıştır.



Şekil 5.14: Başarım iyileştirme teknikleri kullanılmadan oluşturulmuş 3 boyutlu ESA ile üretilmiş tematik harita.

Arazi sınıflarına ait F-skor, genel ve Kappa doğruluklarını Python'ın kütüphanelerinden biri olan Keras modülü ile hesaplanmıştır. Üretilen tematik haritanın genel doğruluğu %78,48 iken Kappa doğruluğu ise 0,73 olarak bulunmuştur. Tablo 5.22'de arazi sınıflarına ait F-skor doğrulukları gösterilmiştir.

Tablo 5.22: Arazi sınıflarının F-skor doğruluk değerleri.

Arazi Sınıfı	F -Skor
Asfalt	0,70
Çayır	0,91
Çakıl	0,54
Ağaç	0,96
Metal Çatı	1,00
Çıplak Toprak	0,75
Ziftli Zemin	0,41
Tuğla	0,50
Gölge	0,98
Genel Doğruluk (%)	78,48
Kappa Katsayı	0,73
Eğitim Süresi (sn)	1200,4

Arazi sınıflarının doğrulukları incelendiğinde metal çatı sınıfının en yüksek doğruluğa sahip olduğu görülmüştür. Diğer ikinci en yüksek doğruluğa sahip olan arazi sınıfı ise gölge sınıfına aittir. Ayrıca, sınıfların doğruluklara bakıldığında ziftli zemine ait doğruluğun en düşük olduğu görülmüştür. Hata matrisi ve tematik harita incelendiğinde ziftli zemin sınıfına çayır ve asfalt sınıfının karıştığı gözlenmiş ve ardından gelen ise tuğla ve çakıl sınıfına ait sınıfların doğruluklarının düşük olduğu söylenebilir. Tuğla sınıfına ise çakıl ve asfalt sınıfının karıştığı, çakıl sınıfına ise tuğla, asfalt ve çayır sınıfının karıştığı gözlenmektedir.

5.5.2. Erken Durdurma Tekniğinin Uygulanması ve Sonucu


İlk bölümde, başarıyı iyileştirme teknikleri kullanılmadan oluşturulmuş derin öğrenme modeline erken durdurma tekniği eklenmiştir. Modelin özeti Tablo 5.23'te yer almaktadır. Erken durdurma metodu, eğitim aşamasında çalıştırılan katmana parametre olarak eklediği için özet tabloda yer almamaktadır. Erken durdurma metodunun prensibinde optimizasyon algoritması bulunmaktadır. Kısaca, öğrenme esnasında eğitim maliyeti ile test maliyeti arasındaki fark artmaya başladığında

modelin aşırı öğrenme yaşadığı ve bu nedenle, öğrenmenin bir yerde durması için kullanılan tekniktir. Bu işlemi gerçekleştirebilmek için modele en uygun optimizasyon algoritmasının seçilmesi gerekir. Bu algoritmanın prensibine göre modelin global minimum değerinin bulunması gerekir. Ancak derin öğrenme sistemleri kara kutu gibi çalıştığı için kullanıcının bu konuyla ilgili deneyimli olması gerekmektedir. Bu nedenle bu başarıyı iyileştirme tekniği çok fazla tercih edilmemektedir.

Tablo 5.23: Model: "Erken durdurma tekniği kullanılarak oluşturulmuş ESA".


Katman(tipi)	Çıktı Boyutu	Parametre
Girdi Katmanı	(Yok, 5, 5, 103, 1)	0
3B ESA	(Yok, 5, 5, 74, 4)	124
3B ESA	(Yok, 5, 5, 45, 4)	484
3B ESA	(Yok, 5, 5, 26, 4)	324
Düzleştirme Katmanı	(Yok, 2.600)	0
Yoğunlaştırma Katmanı	(Yok, 512)	1.331.712
Yoğunlaştırma Katmanı	(Yok, 512)	262.656
Yoğunlaştırma Katmanı	(Yok, 512)	262.656
Yoğunlaştırma Katmanı	(Yok, 9)	4.617
Toplam Parametre:	-	1.862.573
Eğitilebilir Parametre:	-	1.862.573
Eğitilemeyen Parametre:	-	0

İlk başta erken durdurma metodu uygulanırken 200 epok ile ayarlı olan eğitim 40. epokta durdurulmuştur. Bu nedenle, ağı biraz çalışması izin vermek adına 100 epok çalıştıktan sonra erken durdurma parametresi eklenmiştir. Böylece ağı nasıl bir eğitim geçirdiği gözlenmiştir. Bu durumu gözlemek için de modelin eğitim ve testin doğruluk/maliyet grafiği çizdirilmiştir (Şekil 5.15). Grafiğe bakıldığında bu yöntemin çok da başarılı olmadığı gözlenmiştir. 100. epoktan sonra grafik incelendiğinde 140. epoka kadar ilerlediği görülmüştür. 140 epokta eğitim maliyeti ile test maliyeti değerlerinin arasının açıldığı grafikte de görülmektedir. Bu da modelin 140. epoktan itibaren aşırı öğrenme yaşamaya başlayacağını göstermektedir.



Şekil 5.15: Erken durdurma tekniği kullanılarak oluşturulmuş ESA'nın doğruluk/maliyet grafiği.

Erken durdurma tekniği kullanılarak oluşturulmuş modelin eğitimi tamamlandıktan sonra Pavia veri seti modele verilerek 9 arazi sınıfına ait bir tematik harita üretilmiştir. Bu harita üretilirken tahmin sonuçları txt olarak kayıt edilmiş ve başka bir yazılımda da img formatına dönüştürülerek, ArcGIS yazılımında görselleştirmesi yapılmıştır (Şekil 5.16).



Şekil 5.16: Erken durdurma tekniği kullanılarak oluşturulmuş 3 boyutlu ESA ile üretilmiş tematik harita.

Üretilen tematik haritanın genel ve Kappa doğrulukları sırasıyla %66,9 ve 0,59 olarak bulunmuştur. Bu doğrulukların ilk modele göre düşük çıkmasının en büyük nedeni, modelin eğitimi sırasında tercih edilen epok sayısının tamamlanmamasından kaynaklanmaktadır. Diğer bir deyişle, modelin çok iyi bir öğrenme

sergileyememesinden ortaya böyle bir sonuç çıkmıştır. Bu nedenle, bu metodun uygulamasının iyi bir şekilde gerçekleştirilmesi gerekir.

Tablo 5.24: Arazi sınıflarının F-skor doğruluk değerleri.

Arazi Sınıfı	F -Skor
Asfalt	0,73
Çayır	0,71
Çakıl	0,68
Ağaç	0,71
Metal Çatı	1,00
Çıplak Toprak	0,44
Ziftli Zemin	0,48
Tuğla	0,68
Gölge	0,80
Genel Doğruluk (%)	66,9
Kappa Katsayı	0,59
Eğitim Süresi (sn)	848,28

Arazi sınıflarına ait F-skor doğrulukları hesaplanmıştır ve Tablo 5.24’te gösterilmiştir. Genel olarak bu tablo incelendiğinde metal çatı sınıfının en yüksek doğruluğa sahip iken çıplak toprak ve ziftli zemin sınıfları ise en düşük doğruluğa sahip olduğu görülmektedir. Çıplak toprak sınıfı, çayır ve çakıl sınıfı ile karıştığı görülmektedir. Ziftli zemin sınıfı ise asfalt ve çayır sınıfı ile karıştığı tematik harita ve hata matrisinde görülmektedir.

5.5.3. Düğüm Seyreltme Tekniğinin Uygulanması ve Sonucu


Diğer bir başarımla iyileştirme tekniklerinden biri de düğüm seyreltme katmanının derin öğrenme modeline uygulanmasıdır. Bu teknik, sınır ağı içerisindeki düğümleri olasılık hesabına göre rastgele ve her öğrenme tekrarında geçici olarak devre dışı bırakmaktadır. Yapılan çalışmanın amacına göre düğüm seyreltme katmanı

özelleştirilebilir bir özelliğe sahiptir. Başarım iyileştirme tekniği uygulanmamış modele 3 adet seyreltme katmanı eklenmiştir. Tablo 5.25'te oluşturulan modelin özet hali bulunmaktadır.

Tablo 5.25: Model: "Düğüm seyreltme tekniği kullanılarak oluşturulmuş ESA".


Katman(tipi)	Çıktı Boyutu	Parametre
Girdi Katmanı	(Yok, 5, 5, 103, 1)	0
3B ESA	(Yok, 5, 5, 74, 4)	124
3B ESA	(Yok, 5, 5, 45, 4)	484
3B ESA	(Yok, 5, 5, 26, 4)	324
Düzleştirme Katmanı	(Yok, 2.600)	0
Yoğunlaştırma Katmanı	(Yok, 512)	1.331.712
Seyreltme Katmanı	(Yok, 512)	0
Yoğunlaştırma Katmanı	(Yok, 512)	262.656
Seyreltme Katmanı	(Yok, 512)	0
Yoğunlaştırma Katmanı	(Yok, 512)	262.656
Seyreltme Katmanı	(Yok, 512)	0
Yoğunlaştırma Katmanı	(Yok, 9)	4.617
Toplam Parametre:	-	1.862.573
Eğitilebilir Parametre:	-	1.862.573
Eğitilemeyen Parametre:	-	0

Düğüm seyreltme katmanı kullanılarak üretilmiş modelin eğitim aşaması tamamlandıktan sonra modele ait test ve eğitim maliyet/doğrulukları grafik olarak çizdirilmiştir (Şekil 5.17:). Diğer uygulamalara göre test maliyetinin gözle görülür bir şekilde azaldığı grafikte gösterilmiştir. Aslında bu tekniği daha uygun bir şekilde kullanarak test maliyetini daha da azaltabileceği söylenebilir. Başarım iyileştirme tekniği kullanılmadan üretilmiş modelin grafiği ile bu grafik karşılaştırıldığı zaman modelin aşırı öğrenmesinin kısmen önüne geçildiği belirtilebilir.



Şekil 5.17: Düğüm seyreltme tekniği kullanılarak oluşturulmuş ESA'nın doğruluk/maliyet grafiği.

Yeni derin öğrenme modelinden üretilen çıktı, başta bahsedilen şekilde tematik haritaya dönüştürülmüştür (Şekil 5.18). Ardından, 9 adet arazi sınıfını temsil eden tematik haritanın genel ve Kappa doğrulukları hesaplanmıştır. Genel doğruluğu %89,45 iken Kappa doğruluğu da 0,86 olarak hesaplanmıştır.



Şekil 5.18: Düğüm seyreltme tekniği kullanılarak oluşturulmuş 3 boyutlu ESA ile üretilmiş tematik harita.

Ayrıca tematik haritanın arazi sınıflarının F-skor doğruluğu hesaplanmış ve Tablo 5.26’da gösterilmiştir. Oluşturulan bu tabloya göre en yüksek F-skor doğruluğa sahip arazi sınıfı gölge sınıfına aittir. Bu sınıftan sonra ise en yüksek doğruluk metal çatı arazi sınıfına aittir. F-skor doğruluk analizine göre ise en düşük doğruluk da ziftli

zemin sınıfına aittir. Ziftli zemin sınıfının asfalt ve çayır sınıfı ile karıştığı hem tematik haritadan hem de üretilen hata matrisinde görülmektedir.

Tablo 5.26: Arazi sınıflarının F-skor doğruluk değerleri.

Arazi Sınıfı	F -Skor
Asfalt	0,84
Çayır	0,96
Çakıl	0,74
Ağaç	0,95
Metal Çatı	0,97
Çıplak Toprak	0,87
Ziftli Zemin	0,68
Tuğla	0,80
Gölge	0,99
Genel Doğruluk (%)	89,45
Kappa Katsayı	0,86
Eğitim Süresi (sn)	1204,4

5.5.4. Standart Başarım İyileştirme Parametresinin Uygulanması ve Sonucu

Diğer başarım iyileştirme tekniklerine göre standart başarım iyileştirme parametrelerini model uygulamak daha kolaydır. Derin öğrenme modelinin eğitim esnasında değişen ağırlıklarını kullanarak yapılan bir uygulamadır. Modelin ağırlıklarının başlangıca olan uzaklığını ortadan kaldırmak veya azaltmak amacıyla uygulaması gerçekleşir. Böylece ağırlıklar optimum bir yapıya dönüşmesi amaçlanır. Literatürde L1 ve L2 olmak üzere iki adet standart başarım iyileştirme parametresinden bahsedilmektedir. L1 parametresi ağırlıkların mutlak toplamıyla hesaplanırken, L2 parametresi ise modelin ağırlıklarının karesi alınarak kullanılır. Oluşturulan modelin karmaşıklığına göre bu iki parametre arasında seçim yapılabilir.


Başarım iyileştirme yapılmamış modelin eğitim katmanına L2 parametresi eklenmiştir ve ardından eğitim aşamasına geçilmiştir. Tablo 5.27’de oluşturulan derin

öğrenme modelinin yapısı bulunmaktadır. L2 parametresi katmana parametre olarak eklendiği için ağ tablosunda özel olarak belirtilmemiştir.

Tablo 5.27: Model: "Standart başarımlar iyileştirme parametresi kullanılarak oluşturulmuş ESA".


Katman(tipi)	Çıktı Boyutu	Parametre
Girdi Katmanı	(Yok, 5, 5, 103, 1)	0
3B ESA	(Yok, 5, 5, 74, 4)	124
3B ESA	(Yok, 5, 5, 45, 4)	484
3B ESA	(Yok, 5, 5, 26, 4)	324
Düzleştirme Katmanı	(Yok, 2.600)	0
Yoğunlaştırma Katmanı	(Yok, 512)	1.331.712
Yoğunlaştırma Katmanı	(Yok, 512)	262.656
Yoğunlaştırma Katmanı	(Yok, 512)	262.656
Yoğunlaştırma Katmanı	(Yok, 9)	4.617
Toplam Parametre:	-	1.862.573
Eğitilebilir Parametre:	-	1.862.573
Eğitilemeyen Parametre:	-	0

Eğitim aşaması tamamlandıktan sonra, oluşturulan modele ait modelin doğruluğunu ve maliyetini içeren bir grafik üretilmiştir (Şekil 5.19). Bu grafikte, test maliyeti, test doğruluğu, eğitim maliyeti ve eğitim doğruluğun içeren 4 farklı hesaplama mevcuttur. İlk bölümlerdeki, başarımlar iyileştirme teknikleri kullanılarak oluşturulmuş modellere göre biraz daha iyi sonuç ortaya çıkarmıştır. Test maliyeti ara ara pik yapmasına rağmen diğerlerine göre bir azalma göstermiştir.



Şekil 5.19: Standart başarımlar iyileştirme parametresi kullanılarak oluşturulmuş ESA'nın doğruluk/maliyet grafiği.

Eğitim aşaması sonlandıktan sonra üretilen tahmin çıktısı, 9 arazi sınıfı içeren bir tematik harita dönüştürülmüştür (Şekil 5.20). Bu tematik haritaya ait genel ve Kappa doğruluğu sırasıyla %91,50 ve 0,89 olarak hesaplanmıştır.



Şekil 5.20: Standart başarımla iyileştirme parametresi kullanılarak oluşturulmuş 3 boyutlu ESA ile üretilmiş tematik harita.

Üretilen tematik haritanın tüm arazi sınıflarının F-skor doğruluğu hesaplanmıştır (Tablo 5.28). Bu tabloda en yüksek F-skor doğruluğuna sahip arazi sınıfı metal çatı sınıfına sahiptir. Diğer yandan en düşük F-skor doğruluğu da çıplak toprak sınıfına

aittir. Hata matrisine ve tematik haritaya göre çıplak toprak sınıfının, çayır sınıfı ile karıştığı gözlenmektedir.

Tablo 5.28: Arazi sınıflarının F-skor doğruluk değerleri.

Arazi Sınıfı	F -Skor
Asfalt	0,95
Çayır	0,93
Çakıl	0,88
Ağaç	0,91
Metal Çatı	1,00
Çıplak Toprak	0,82
Ziftli Zemin	0,92
Tuğla	0,91
Gölge	0,94
Genel Doğruluk (%)	91,50
Kappa Katsayı	0,89
Eğitim Süresi (sn)	1221,4


5.5.5. Yığın Normalizasyon Tekniğinin Uygulanması ve Sonucu

Yığın normalizasyonu tekniği başarımların iyileştirme tekniklerinden biridir. Bu teknik, sinir ağlarının performansını arttırmak için iç kovaryans algoritmasını kullanılır. Aslında bu yöntem girdi verisine getirilen düzeltme gibi düşünülebilir ve sinir ağının eğitim doğruluğunu artırır. Kısaca girdi verisini normalize ederek öğrenme hızını artırır ve seyreltme katmanını gibi diğer başarımların iyileştirme tekniklerine olan ihtiyacı azaltmaktadır. Başarımların iyileştirme tekniği kullanılmadan oluşturulmuş modelin girdi katmanından sonra yığın normalizasyon katmanını eklenir ve modelin veriyi daha iyi bir şekilde okuyabileceği hale getirilir. Tablo 5.29’da oluşturulan tablonun özet hali bulunmaktadır.

Tablo 5.29: Model: "Yığın normalizasyon tekniği kullanılarak oluşturulmuş ESA".


Katman(tipi)	Çıktı Boyutu	Parametre
Girdi Katmanı	(Yok, 5, 5, 103, 1)	0
Yığın Normalleştirme Katmanı	(Yok, 5, 5, 103, 1)	4
3B ESA	(Yok, 5, 5, 74, 4)	124
3B ESA	(Yok, 5, 5, 45, 4)	484
3B ESA	(Yok, 5, 5, 26, 4)	324
Düzleştirme Katmanı	(Yok, 2.600)	0
Yoğunlaştırma Katmanı	(Yok, 512)	1.331.712
Yoğunlaştırma Katmanı	(Yok, 512)	262.656
Yoğunlaştırma Katmanı	(Yok, 512)	262.656
Yoğunlaştırma Katmanı	(Yok, 9)	4.617
Toplam Parametre:	-	1.862.573
Eğitilebilir Parametre:	-	1.862.573
Eğitilemeyen Parametre:	-	0

Yığın normalizasyon katmanı eklenen modelin eğitim aşaması tamamlandıktan sonra bu modele ait doğruluk/maliyet grafiği çizdirilmiştir (Şekil 5.21). Bu grafikte test ve eğitim verilerine ait maliyet ve doğruluk değerleri yer almaktadır. Tek tek uygulanmış başarımlı iyileştirme tekniklerinin modelleri arasında en anlamlı grafiğe sahip olan başarımlı iyileştirme tekniği, yığın normalizasyon tekniğine aittir. Bu yöntem sonucunda 4 farklı teknik arasında en düşük test maliyetine erişilmiştir.



Şekil 5.21: Yığın normalizasyon tekniği kullanılarak oluşturulmuş ESA'nın doğruluk/maliyet grafiği.

Eğitim aşaması tamamlandıktan sonra eğitilmiş modele tüm veri seti uygulanmış ve 9 adet arazi sınıfını temsil eden bir tematik harita üretilmiştir. Şekil 5.22'de üretilen tematik harita gösterilmiştir. Bu tematik haritanın genel ve Kappa doğruluğu hesaplanmıştır. Sırasıyla genel doğruluk %98,07 iken Kappa doğruluğu da 0,97 olarak bulunmuştur.



Şekil 5.22: Yığın normalizasyon tekniği kullanılarak oluşturulmuş 3 boyutlu ESA ile üretilmiş tematik harita.

Tematik haritada bulunan her arazi sınıfı için F-skor değeri hesaplanmıştır ve Tablo 5.30’da tüm arazi sınıflarının F-skor değerleri yer almaktadır. Tabloya göre en yüksek F-skor doğruluğuna sahip arazi sınıfı metal çatıdır. Ardından gelen en yüksek doğruluklar ise çayır ve asfalt arazi sınıflarına aittir. Bunların yanında, oluşturulan tabloya göre en düşük F-skor doğruluğuna ise çıplak toprak sınıfı sahiptir. Çıplak

toprak sınıfının çayır sınıfı ile karıştığı hem tematik haritada hem de hata matrisinde görülmektedir.

Tablo 5.30: Arazi sınıflarının F-skor doğruluk değerleri .

Arazi Sınıfı	F -Skor
Asfalt	0,99
Çayır	0,99
Çakıl	0,97
Ağaç	0,97
Metal Çatı	1,00
Çıplak Toprak	0,96
Ziftli Zemin	0,98
Tuğla	0,97
Gölge	1,00
Genel Doğruluk (%)	98,071
Kappa Katsayı	0,97
Eğitim Süresi (sn)	1201,4


5.5.6. Başarım İyileştirme Tekniklerinin Birlikte Kullanılarak Uygulanması ve Sonucu

Bu uygulamada, yığın normalizasyonu, seyreltme katmanı ve standart başarım iyileştirme parametreleri birlikte kullanılarak 3 boyutlu ESA mimarisine eklenmiştir. Böylelikle, başarım iyileştirme tekniklerinin birlikte kullanılmasının, oluşturulan ESA'ya olan etkisi incelenmiştir. Tablo 5.31.'da oluşturulan modelin mimarisinin özet hali bulunmaktadır. ESA mimarisine girdi katmanından sonra yığın normalizasyon katmanı eklenmiştir. Ardından ağ mimarisine standart başarım iyileştirme parametresi eklenmiştir. Son olarak da seyreltme katmanı ile ağ tasarımı tamamlanmıştır.

Tablo 5.31: Model: "Başarım iyileştirme tekniklerinin birlikte kullanılarak oluşturulmuş ESA".


Katman(tipi)	Çıktı Boyutu	Parametre
Girdi Katmanı	(Yok, 5, 5, 103, 1)	0
Yığın Normalleştirme Katmanı	(Yok, 5, 5, 103, 1)	4
3B ESA	(Yok, 5, 5, 74, 4)	124
3B ESA	(Yok, 5, 5, 45, 4)	484
3B ESA	(Yok, 5, 5, 26, 4)	324
Düzleştirme Katmanı	(Yok, 2.600)	0
Yoğunlaştırma Katmanı	(Yok, 512)	1.331.712
Yoğunlaştırma Katmanı	(Yok, 512)	262.656
Yoğunlaştırma Katmanı	(Yok, 512)	262.656
Seyreltme Katmanı	(Yok, 512)	0
Yoğunlaştırma Katmanı	(Yok, 9)	4.617
Toplam Parametre:	-	1.862.577
Eğitilebilir Parametre:	-	1.862.577
Eğitilemeyen Parametre:	-	2

Başarım iyileştirme parametreleri eklenen modelin eğitim aşaması tamamlandıktan sonra bu modele ait doğruluk/maliyet grafiği çizdirilmiştir. Bu grafikte test ve eğitim verilerine ait maliyet ve doğruluk değerleri yer almaktadır. Tek tek uygulanmış başarım iyileştirme tekniklerinin modellerine göre bu bölümde birden fazla başarım iyileştirme teknikleri kullanılarak oluşturulmuş modelin doğruluğunun daha yüksek olduğu söylenebilir. Diğer grafiklerle karşılaştırıldığında en düşük test maliyetine sahip grafik Şekil 5.23'te gösterilmiştir. Bu şekle göre test ve eğitim maliyeti en düşük seviyededir ve aşırı öğrenmenin önüne geçildiği görülmektedir.



Şekil 5.23: Başarım iyileştirme tekniklerinin birlikte kullanılarak oluşturulmuş ESA'nın doğruluk/maliyet grafiği.

3 boyutlu ESA modelinin eğitim aşaması bittikten sonra eğitilmiş modele tüm veri seti uygulanmış ve 9 adet arazi sınıfını temsil eden bir tematik harita üretilmiştir. Şekil 5.24'te üretilen tematik harita gösterilmiştir. Üretilen tematik haritanın genel ve Kappa doğruluğu sırasıyla, %98,45 ve 0,98 olarak hesaplanmıştır.



Şekil 5.24: Başarım iyileştirme tekniklerinin birlikte kullanılarak oluşturulmuş 3 boyutlu ESA ile üretilmiş tematik harita.

Üretilen tematik haritanın içinde bulunan her arazi sınıfı için F-skor değeri hesaplanmıştır (Tablo 5.32). Tabloya göre en yüksek F-skor doğruluğuna sahip arazi sınıfı metal çatıdır. Ardından gelen en yüksek doğruluklar ise çayır, asfalt, tuğla ve gölge arazi sınıflarına aittir. Bunların yanında, oluşturulan tabloya göre en düşük F-

skor doğruluğuna ise ağaç sınıfına aittir. Ağaç sınıfının çayır sınıfı ile karıştığı hem tematik haritada hem de hata matrisinde görülmektedir.

Tablo 5.32: Arazi sınıflarının F-skor doğruluk değerleri.

Arazi Sınıfı	F -Skor
Asfalt	0,99
Çayır	0,99
Çakıl	0,98
Ağaç	0,96
Metal Çatı	1,00
Çıplak Toprak	0,98
Ziftli Zemin	0,97
Tuğla	0,99
Gölge	0,99
Genel Doğruluk (%)	98,45
Kappa Katsayı	0,98
Eğitim Süresi (sn)	1301,4

5.5.7. Başarım İyileştirme Tekniklerinin Karşılaştırılması

Genel olarak, tezin bu bölümünde başarım iyileştirme tekniklerinin modele ve öğrenmeye olan etkileri incelenmiştir. Farklı başarım iyileştirme teknikleri ile farklı derin öğrenme modelleri oluşturulmuş ve Pavia görüntüsünün nasıl sınıflandırılacağı üzerinde çalışılmıştır. Sınıflandırma problemini ele alan ESA, 5 farklı şekilde tekrardan başarım iyileştirme tekniklerine göre düzenlemiştir. İlk olarak, 4 farklı başarım iyileştirme tekniği ayrı ayrı olacak şekilde ESA'ya uygulanmıştır. Bu dört farklı teknikten en iyi sonuç alınan metot yığın normalizasyonuna aittir. Oluşturulan modeller arasında sınıflandırma sonucu üretilen tematik haritanın genel ve Kappa doğruluğu en yüksek değeri almıştır. Bu yöntemden sonra ESA sınıflandırmasının en iyi doğruluğa sahip olmasını sağlayan başarım iyileştirme teknikleri sırasıyla standart başarım iyileştirme parametrelerinin kullanıldığı teknik, düğüm seyreltme tekniği ve

son olarak da erken durdurma metodudur. Bu görüntü sınıflandırması için kullanılan ESA'nın başarımlarını iyileştirme teknikleri bir de toplu halde kullanılmıştır ve tüm teknikler arasında en yüksek doğruluk bu tekniklerin doğru bir şekilde ESA'ya uygulanması ile elde edilmiştir.

Derin öğrenme algoritmaları içeren çalışmalarda, karşılaşılan en yaygın problemler bir YSA türünün optimizasyonu ve ağ modelinin iyi eğitim yapabilmesi için uygun/ideal parametre seçimidir. Derin öğrenme modeline optimizasyon yapılmasının en büyük nedeni, modelin öğrenme esnasında ürettiği ağırlıkların gizli katmanlarda gerçekleşmesi ve modelin, eğitim aşamasında, arka bölümünde hangi matematiksel işlemlerin kullandığı, kullanıcıya sunulmadan gerçekleşmesinden kaynaklanmaktadır. Bu nedenle derin öğrenme modellerinin kara kutu olarak davrandığı söylenmektedir. Herhangi bir problemin karmaşıklığına göre derin öğrenme modeli de karmaşıklıklaştırmaktadır. Ancak modelin karmaşıklığının artması, yüksek doğrulukla sonuçlar vereceği anlamına gelmeyebilir. Bu nedenle, modelin karmaşıklığını arttırmaktan ziyade, en ideal modeli belirlerken optimizasyon ve başarımlarını iyileştirme yöntemlerinin amaca uygun olacak şekilde seçilmesi beklenilmektedir. Böylelikle, sınıflandırma veya obje tespiti gibi herhangi bir problemi çözmek için kullanılan derin öğrenme modelinin geliştirilebilmesi için bilim insanları tarafından çeşitli çalışmalar yapılmaktadır.

6. SONUÇLAR ve TARTIŞMA

Uzaktan algılama günümüzün popüler konularında biridir. Bu nedenle, uzaktan algılama bilim dalı, güvenlik, savunma, ziraat, afet tespiti, şehir gelişimini incelemek gibi amaçlarla yaygın olarak kullanılır. Özellikle, uzaktan algılama yer yüzünü konu olan afet, savunma ve kentsel çalışmalar gibi birçok alanda tercih edilen bir bilim dalıdır. Ancak uzaktan algılanmış verilerin işlenmesinde bazı zorluklar bulunmaktadır. Bu işlemlerin deneyimli kişiler tarafından yapılması gerekmektedir. Ayrıca diğer popüler olan konu başlıklarından biri de makine öğrenmesinin alt kolu olan derin öğrenme algoritmasıdır. Günümüzde, bu algoritma uzaktan algılama gibi çok fazla miktarda veri içeren bilim dallarında yaygın olarak tercih edilmektedir. Bu metodun daha çok tercih edilme nedeni insandan bağımsız ve hızlı bir şekilde verilen görevi yerine getirmesi olarak sunulabilir. Çünkü bunun temelinde insanı taklit eden bir algoritma mevcuttur.

Bu tez kapsamında ilk olarak sınıflandırma teknikleri, daha sonra yapay sinir ağları ve en son olarak da derin öğrenme yaklaşımları ayrı ayrı incelenmiştir. Uygulama bölümünde ise Pavia Üniversitesi hiperspektral görüntüsü kullanılmıştır. Tezin bu bölümünde üç farklı uygulama gerçekleştirilmiştir. İlk uygulamada derin öğrenme modellerinden biri olan ESA irdelenmiştir ve ESA'nın farklı boyutları kullanılarak sınıflandırma işlemi yapılmıştır. Her bir farklı boyuttaki ESA'nın ağ mimarisi en optimum şekilde oluşturulmaya çalışılmıştır. 1 boyutlu, 2 boyutlu ve 3 boyutlu ESA'ların yanında 50, 100, 200 ve 400 örneklem içeren eğitim setleri ile oluşturulan modeller eğitilmiştir. 1 boyutlu ESA'lar sadece spektral özellikleri kullanırken, 2 boyutlu ESA'lar hem spektral özellikleri hem de harita nesnesinin mekânsal özellikleri de dahil edilmiştir. 3 boyutlu ESA'larda ise spektral ve mekânsal özelliklerin yanında da görüntüye ait çok fazla bantı da aynı anda derin öğrenme modelinin eğitimine dahil etmeye olanak tanımaktadır. 1 boyutlu ESA'larda elde edilen en yüksek genel doğruluğu %89,30 ile 400 örneklem içi gerçekleştirilmiştir. En düşük doğruluğu ise 50 örneklem kullanan derin öğrenme modeli %74,84 olarak hesaplanmıştır. 2 boyutlu ESA'larda ise en yüksek genel doğruluk %93,97 iken en düşük genel doğruluk %82,24 olarak bulunmuştur. 3 boyutlu ESA kullanılarak üretilen genel doğruluklarda en yüksek ve en düşük doğruluklar sırasıyla %97,52 ve %85,57 olarak bulunmuştur. Bu uygulamalar sonucunda örneklem sayısının artması modelin

doğru eğitilmesi ve daha yüksek tematik harita doğruluğunun üretilmesin olanak tanımıştır. Ayrıca bu uygulamada oluşturulan modellerde kullanılan aktivasyon parametreleri, öğrenme hızı ve seyreltme parametreleri gibi özelliklerin doğru belirlenmesi gerekmektedir. Bu parametrelerin en iyi şekilde belirlenebilmesi için araştırmacının bu konuyla ilgili belli bir deneyime sahip olması gerekmektedir. Çünkü derin öğrenme modeli kara kutu prensibi ile çalıştığı için iç kısmında döndürdüğü işlemler bilinmemektedir.

İkinci uygulamada derin öğrenme modellerinin eğitimi için farklı görüntü parçacıklarının kullanılması araştırılmıştır. Pavia görüntüsünün sınıflandırılması için 15x15, 21x21 ve 27x27'lik görüntü parçacıkları kullanılarak eğitim veri seti oluşturulmuştur. Bu veri seti ayrı ayrı olacak şekilde hem 2 boyutlu hem de 3 boyutlu ESA'lara 50, 100, 200 ve 400 örneklem ile uygulanmıştır. Uygulama sonucunda, bu görüntü parçacıklarının boyutlarının değişmesi eğitimi sonucu üretilen tematik haritanın doğruluklarını etkilemiştir. Çoğunlukla, 3 boyutlu ESA'larda 21x21'lik görüntü parçacıkları ile oluşturulmuş olan tematik haritanın doğruluğu en yüksek çıkmıştır. 2 boyutlu ESA'larda ise çoğunlukla 27x27'lik görüntü parçacıkları ile üretilen doğruluklar en yüksek seviyede çıkmıştır. Bu bilgiler ışığında görüntü parçacık boyutlarının değişmesi oluşturulan modele ve veri setine bağlıdır. Kısaca aynı veri setinde kullanılan farklı görüntü parçacıkları için 2 ve 3 boyutlu ESA'larda farklı doğruluklar elde edilmiştir. Bu nedenle, gelecekte yapılacak çalışmalarda görüntü parçacığının boyutunun en optimum olarak belirlenmesi üretilen haritaların doğruluklarını büyük ölçüde etkileyecektir.

Son uygulamada ise derin öğrenme modelinde optimizasyon için kullanılan başarımlar iyileştirme teknikleri ayrı ayrı incelenmiştir. Karşılaştırma yapmak için ilk olarak başarımlar iyileştirme tekniği kullanılmadan bir model oluşturulmuştur. Ardından ayrı ayrı olacak şekilde, erken durdurma, düğüm seyreltme, standart başarımlar iyileştirme parametreleri ve yığın normalizasyonu teknikleri derin öğrenme modeline uygulanmıştır. Bu metotlar arasından en yüksek doğruluk yığın normalizasyonu ile sağlanırken en düşük doğruluk da erken durdurma ile sağlanmıştır. Ayrıca bir de bu uygulamada bu tekniklerin hepsi bir arada kullanılarak bir model oluşturulmuştur. Ve tüm modellerin arasında en büyük doğruluğa sahip olduğu gözlenmiştir. Derin öğrenmede optimizasyon çok önemli bir kavramdır. Çünkü birçok çalışmada sinir ağlarında büyük bir problem olarak gösterilmektedir. Bir derin öğrenme modelinin optimizasyonunu sağlamak zorlu bir süreçtir. Bunun en temel nedeni derin öğrenme

modellerinin kara kutu gibi davranmasından kaynaklanmaktadır. Kısaca, eğitim aşamasında oluşturulan gizli katmanların nasıl davrandığının bilinmemesinden kaynaklanmaktadır. Ayrıca optimizasyonun diğer bir önemi ise derin öğrenme modelinin ağ mimarisinin karmaşıklığını azaltıp, genelleşmesini sağlamayı amaçlamaktadır. Böylece farklı görüntülerde basit değişikliklerle aynı sınıflandırma modelinin kullanılabilmesine olanak sağlanabilir.

Sonuç olarak, bu tez çalışmamda derin öğrenme ile uzaktan algılanmış bir hiperspektral görüntünün sınıflandırılması yapılmış ve sınıflandırma etki edebilen ağ içindeki veya eğitim veri setindeki değişkenler incelenmiştir. Tez kapsamında yapılan tüm uygulamalar sonucunda, derin öğrenme metotlarından biri olan ESA'nın 3 boyutlu olanının diğerlerine göre de yüksek doğruluk sağladığı gözlenmiştir.

KAYNAKLAR

- Abbas A. W., Minallh N., Ahmad N., Abid S. A. R., Khan M. A. A., (2016), "K-Means and ISODATA clustering algorithms for land cover classification using remote sensing", *Sindh University Research Journal (Science Series)*, 48 (2), 315-318.
- Abburu S., Babu Golla S., (2015), "Satellite image classification methods and techniques: a review", *International Journal of Computer Applications*, 119 (8), 20-25.
- Abdel-Hamid O., Mohamed A., Jiang H., Deng L., Penn G., Yu D., (2014), "Convolutional neural networks for speech recognition", *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 22 (10), 1533-1545.
- Abdeljaber O., Avci O., Kiranyaz S., Gabbouj M., Inman D. J., (2017), "Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks", *Journal of Sound and Vibration*, 388, 154-170
- Abhishek K., Singh M. P., Ghosh S., Anand A., (2012), "Weather forecasting model using artificial neural network", *Procedia Technology*, 4 (2012), 311-318.
- Abiodun O. I., Jantan A., Omolara A. E., Dada K. V., Mohamed N. A. E., Arshad H., (2018), "State-of-the-art in artificial neural network applications: a survey", *Heliyon*, 4 (11), 1-41.
- Aggarwal C. C., (2018), "Neural networks and deep learning", 1st Edition, Springer Nature.
- Al-Ahmadi F. S., Hames A. S., (2009), "Comparison of four classification methods to extract land use and land cover from raw satellite images for some remote arid areas, Kingdom of Saudi Arabia", *Eart Science*, 20 (1), 167-191.
- Ali N., Zafar B., Iqbal M. K., Sajid M., Younis M. Y., Dar S. H., Mahmood M. T., Lee I. H., (2019), "Modeling global geometric spatial information for rotation invariant classification of satellite images". *PLoS ONE*, 14 (7), 1-24.
- Alom M. Z., Taha T. M., Yakopcic C., Westberg S., Sidike P., Nasrin M. S., Asari V. K. (2019), "A state-of-the-art survey on deep learning theory and architectures", *Electronics*, 8 (3), 292-359.
- Alsmadi M. K., Omar K. B., Noah S. A., Almarashdah I., (2009), "Performance comparison of multi-layer perceptron (Back Propagation, Delta Rule and Perceptron) algorithms in neural networks", 2009 IEEE International Advance Computing Conference, 296-299, Patiala, India, 6-7 March.
- Atkinson P. M., Tatnall A. R. L., (1997), "Introduction neural networks in remote sensing", *International Journal of Remote Sensing*, 18 (4), 699-709.

Babatunde D. E., Anozie A., Omoleye J., (2020), “Artificial neural network and its applications in the energy sector- an overview”, *International Journal of Energy Economics and Policy*, 10 (2), 250-264.

Bahari N. I. S., Ahmad A., Aboobaider B. M., (2014), “Application of support vector machine for classification of multispectral data”, *IOP Conference Series: Earth and Environmental Science*, 20 (1), 1-9.

Ball J. E., Anderson D. T., Chan C. S., (2018), “Feature and deep learning in remote sensing applications”, *Journal of Applied Remote Sensing*, 11 (4), 1-4.

Ball J. E., Wei P., (2018), “Deep learning hyperspectral image classification using multiple class-based denoising autoencoders, mixed pixel training augmentation, and morphological operations”, *2018 IEEE International Geoscience and Remote Sensing Symposium*, 6903-6906, Valencia, Spain, 22-27 July.

Barsi A., Kugler Z., László I., Szabó G., Abdulmutalib H. M., (2018), “Accuracy dimensions in remote sensing”, *Developments, Technologies and Applications in Remote Sensing*, 61-67, Beijing, China, 7-10 May.

Bastin L., (1997), “Comparison of fuzzy c-means classification, linear mixture modelling and MLC probabilities as tools for unmixing coarse pixels”, *International Journal of Remote Sensing*, 18 (17), 3629-3648.

Basu J. K., Bhattacharyya D., Kim T. H., (2010), “Use of artificial neural network in pattern recognition”, *International Journal of Software Engineering and Its Application*, 4 (2), 140-152.

Belwalkar A., Nath A., Dikshit O., (2018), “Spectral-spatial classification of hyperspectral remote sensing images using variational autoencoder and convolution neural network”, *ISPRS- Geospatial Technology – Pixel to People*, 613-620, Dehradun, India, 20-23 November.

Bermejo J. F., Fernández J. F. G., Polo F. O., Márquez A. C., (2019). “A review of the use of artificial neural network models for energy and reliability prediction. A study of the solar PV, hydraulic and wind energy sources”, *Applied Sciences*, 9 (9), 1844-1864.

Bhandare A., Bhide M., Gokhale P., Chandavarkar R., (2016), “Applications of convolutional neural networks”, *International Journal of Computer Science and Information Technologies*, 7 (5), 2206-2215.

Bielecki A., (2019), “Models of neurons and perceptrons: selected problems and challenges”, 1st Edition, Springer International Publishing.

Bjorek J., Gomes C., Selman B., Weinberger K. Q., (2018), “Understanding batch normalization”, *Neural Information Processing Systems*, 1-12, Montreal, Canada, 2-8 December.

- Bocco M., Ovando G., Sayago S., Willington E., (2007), "Neural network models for land cover classification from satellite images" *Agricultura Tecnica*, 67 (4), 414-421.
- Borra S., Thanki R., Dey N., (2019), "Satellite image analysis: clustering and classification", *Studies in Computational Intelligence*, 1st Edition, Springer Singapore.
- Bouthillier X., Konda K., Vincent P., Memisevic R., (2015), "Dropout as data augmentation", *ICLR 2016*, 1-11, San Juan, Puerto Rico, 2-4 May.
- Buduma N., (2016), "Fundamentals of deep learning. Designing next-generation machine intelligence algorithms", 1st Edition, O'Reilly.
- Buğday E., Buğday S. E., (2019), "Modeling and simulating land use/cover change using artificial neural network from remotely sensing data", *CERNE*, 25 (2), 246-254.
- Calin O., (2020), "Deep learning architectures a mathematical approach", 1st Edition, Springer International Publishing.
- Canziani G., Ferrati R., Marinelli C., Dukatz, F., (2008), "Artificial neural networks and remote sensing in the analysis of the highly variable pampean shallow lakes", *Mathematical Biosciences and Engineering*, 5 (4), 691-711.
- Chebbi I., Mellouli N., Lamolle M., Farah I. R., (2019), "Deep learning analysis for big remote sensing image classification", *Proceedings of the 11th International Joint Conference on Knowledge Discovery, Knowledge Engineering and Knowledge Management*, 355-362, Vienna, Austria, 17-19 September.
- Cheng G., Han J., (2016), "A survey on object detection in optical remote sensing images", *ISPRS Journal of Photogrammetry and Remote Sensing*, 117(2016), 11-28.
- Cheng K. S., Ling J. Y., Lin T. W., Liu Y. T., Shen Y. C., Kono Y., (2019), "A new thinking of LULC classification accuracy assessment", *ISPRS Geospatial Week 2019*, 1207-1211, Enschede, The Netherlands, 10-14 June.
- Chen J., Huang H., Peng J., Zhu J., Chen L., Li W., Sun B., Member H. L., (2020), "Convolution neural network architecture learning for remote sensing scene classification", *arXiv*, 1-10.
- Chen M., Wang Q., Li X., (2018), "Discriminant analysis with graph learning for hyperspectral image classification", *Remote Sensing*, 10 (6), 1-15.
- Chen S. Y., Lin C., Chuang S. J., Kao Z. Y., (2019), "Weighted background suppression target detection using sparse image enhancement technique for newly grown tree leaves", *Remote Sensing*, 11 (9), 1081-1105.
- Chen Y., Jiang H., Li C., Jia X., Ghamisi P., (2016), "Deep feature extraction and classification of hyperspectral images based on convolutional neural networks", *IEEE Transactions on Geoscience and Remote Sensing*, 54 (10), 6232-6251.

Chi M., Plaza A.J., Benediktsson J.A., Sun Z., Shen J., Zhu Y., (2016), “Big data for remote sensing: challenges and opportunities”, *Proceedings of the IEEE*, 104 (11), 2207-2219.

Cho D., Tai Y. W., Kweon I. S., (2019), “Deep convolutional neural network for natural image matting using initial alpha mattes. *IEEE Transactions on Image Processing*, 28 (3), 1054-1067.

Choon L. S., Samsudin A., Budiarto R., (2004), “Light weight and cost-effective MPEG video encryption”, *2004 International Conference on Information and Communication Technologies: From Theory to Applications*, 525-526, Damascus, Syria, 23 April.

Cortes C., Vapnik V., (1995), “Support-vector networks”, *Machine Learning*, 20, 273-297.

Çölkesen İ., (2015), “Yüksek çözünürlüklü uydu görüntüleri kullanarak benzer spektral özelliklere sahip doğal nesnelerin ayırt edilmesine yönelik bir metodoloji geliştirme”, *Doktora Tezi, İstanbul Teknik Üniversitesi*.

Dai X., Cheng J., Gao Y., Guo S., Yang X., Xu X., Cen Y., (2020), “Deep belief network for feature extraction of urban artificial targets”, *Mathematical Problems in Engineering*, 2020 (10), 1-13.

Dai X. L., Khorram S., (1999), “Remotely sensed change detection based on artificial neural networks”, *Photogrammetric Engineering and Remote Sensing*, 65 (10), 1187-1194.

Daş R., Polat B., Tuna G., (2019), “Derin öğrenme ile resim ve videolarda nesnelerin tanınması ve takibi”, *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31 (2), 571-581.

Deer P. J., Eklund P. W., (2002), “A study of parameter values for a mahalanobis distance fuzzy classifier”, *Fuzzy Sets and Systems*, 137 (2), 191-213.

Demyanov S., (2015), “Regularization methods for neural networks and related models”, *Doctoral Thesis, Melbourne University*.

Deng J., Dong W., Socher R., Li L., Li K., Fei-Fei L., (2009), “ImageNet: a large-scale hierarchical image database”, *IEEE Conference on Computer Vision and Pattern Recognition*, 248-255, Miami, FL, USA, 18 August.

Dey N., Bhatt C., Ashour A. S., (2018), “Big data for remote sensing: visualization, analysis and interpretation”, 1st Edition, Springer International Publishing.

Dhingra S., Kumar D., (2019), “A review of remotely sensed satellite image classification”, *International Journal of Electrical and Computer Engineering*, 9 (3), 1720-1731.

Du K. L., Swamy M. N. S., (2014), "Neural networks and statistical learning", 1st Edition, Springer-Verlag London.

Evgeniou T., Poggio T., Pontil M., Verri A., (2002), "Regularization and statistical learning theory for data analysis", *Computational Statistics and Data Analysis*, 38(4), 421-432.

Fauvel B. M., Tarabalka Y., Ieee M., (2013), "Advances in spectral - spatial classification of hyperspectral images", *Proceeding of IEEE*, 101(3), 652-675.

Fauvel M., Villa A., Chanussot J., Benediktsson J. A., (2010), "Mahalanobis kernel for the classification of hyperspectral images", 2010 IEEE International Geoscience and Remote Sensing Symposium, 3724-3727, Honolulu, HI, USA, 25-30 July.

Finn J. T., (1993), "Use of the average mutual information index in evaluating classification error and consistency", *International Journal of Geographical Information Science*, 7 (4), 349-366.

Foody G. M., (1996), "Relating the land-cover composition of mixed pixels to artificial neural network classification output", *Photogrammetric Engineering and Remote Sensing*, 62 (5), 491-499.

Foody G. M., (2002), "Status of land cover classification accuracy assessment", *Remote Sensing of Environment*, 80 (2002), 185-201.

Foody G. M., Mathur A., (2006), "The use of small training sets containing mixed pixels for accurate hard image classification: training on mixed spectral responses for classification by a SVM", *Remote Sensing of Environment*, 103 (2006), 179-189.

Foody G. M., McCulloch M. B., Yates W. B., (1994), "Classification of remotely sensed data by an artificial neural network: issues related to training data characteristics", *Photogrammetric Engineering and Remote Sensing*, 61 (4), 391-401.

Frazão X. F., Alexandre L. A., (2014), "Dropall: generalization of two convolutional neural network regularization methods", *International Conference on Image Analysis and Recognition*, 282-289, Vilamoura, Algarve, Portugal, 22-24 October.

Furukawa H., (2018), "Deep learning for end-to-end automatic target recognition from synthetic aperture radar imagery", *Technical Report No: SANE2017-92 (2018-01)*, The Institute of Electronics, Information and Communication, Japan.

Gezahegn K., Chakraborty S., (2019), "Automatic target recognition and classification from synthetic aperture radar imagery using multi-stream convolution neural network", *International Journal of Advance Research, Ideas and Innovations in Technology*, 5 (4), 311-314.

Ghasemian A., Hosseinmardi H., Clauset A., (2018), "Evaluating overfit and underfit in models of network community structure", *IEEE Transactions on Knowledge and Data Engineering*, 32 (9), 1722-1735.

Giannopoulos M., Aidini A., Fotiadou K., Giannopoulos M., Pentari A., Tsakalides P., (2019), “Survey of deep-learning approaches for remote sensing observation enhancement”, *Sensor*, 19 (18), 1-39.

Gonçalves L., Fonte C., Júlio E., Caetano M., (2009), “Evaluation of remote sensing image classifiers with uncertainty measures. spatial data quality”, 6th International Symposium on Spatial Data Quality, 163-177, Newfoundland, Canada, 6-8 July.

Gopal S., (2016), “Artificial neural networks in geospatial analysis”, *International Encyclopedia of Geography: People, the Earth, Environment and Technology*, 1-7.

Goswami A. K., (2014), “Automatic object recognition from satellite images using artificial neural network”, *International Journal of Computer Application*, 95 (10), 33-39.

Gu Y., Wang Y., Li Y., (2019), “A survey on deep learning-driven remote sensing image scene understanding: scene classification, scene retrieval and scene-guided object detection”, *Applied Sciences*, 9 (10), 1-24.

Haas A., Karrasch P., Bernard L., (2019), “Acquisition of urban trees using artificial neural networks and remote sensing data”, *AGILE*, 1-7, Limassol, Cyprus, 17-20 June.

Hayes J. J., Castillo O., (2017), “A new approach for interpreting the Morisita index of aggregation through quadrat size”, *ISPRS International Journal of Geo-Information*, 6 (10), 1-15.

Hebb D. O., (1949), “The organization of behavior”, 4th Edition, Wiley.

Hinton G. E., (2009), “Deep belief networks”, *Scholarpedia*, 4 (5), 5947.

Hinton G., (2014), “Dropout: a simple way to prevent neural networks from overfitting”, *Journal of Machine Learning Research*, 15 (2014), 1929-1958.

Hochreiter S. Schmidhuber J., (1997), “Long short-term memory”, *Neural Computation*, 9 (8), 1735-1780.

Huang Y., Yu Y., (2020), “An internal covariate shift bounding algorithm for deep neural networks by unitizing layers' outputs”, *arXiv*, 1-19.

Hu W., Huang Y., Wei L., Zhang F., Li H., (2015), “Deep convolutional neural networks for hyperspectral image classification”, *Journal of Sensing*, 2015 (2), 1-12.

Ioffe S., Szegedy C., (2016), “Batch normalization: accelerating deep network training by reducing internal covariate shift”, *arXiv*, 1-11.

Jia X., (1997), “Block-based maximum likelihood classification for hyperspectral remote sensing data”, *International Geoscience and Remote Sensing Symposium* 778-780, Singapore, Singapore, 3-8 August.

Jin J., Dundar A., Culurciello E., (2014), “Flattened convolutional neural networks for feed forward acceleration”, International Conference on Learning Representations, 1-11, San Diego, CA, USA, 7-9 May.

Kahraman I., Turan M. K., Karas I. R., (2015), “Road detection from high satellite images using neural networks”, International Journal of Modeling and Optimization, 5 (4), 304-307.

Kanellopoulos I., Varfis A., Wilkinson G., Megier J., (1991), “Neural network classification of multi-date satellite imagery”, International Geoscience and Remote Sensing Symposium, 2215-2218, Espoo, Finland, Finland, 3-6 June.

Kavzoğlu T., (2001), “An investigation of the design and use of feed-forward artificial neural networks in the classification of remotely sensed images”, Doctor Thesis, The University of Nottingham.

Kavzoğlu T., Çölkesen I., (2010), “Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi”, Harita Dergisi, 144 (2010), 73-82.

Kavzoğlu T., Çölkesen I., (2005), “A kernel function analysis for support vector machines for land cover classification”, International Journal of Applied Earth Observation and Geoinformation, 11 (5), 352-359.

Kavzoğlu T., Gomez H., (2005), “Assessment of shallow landslide susceptibility using artificial neural networks in Jabonosa River Basin, Venezuela”, Engineering Geology, 78 (2005), 11-27.

Kavzoğlu T., Mather P. M., (1998), “Assessing artificial neural network pruning algorithms”, the 24th Annual Conference and Exhibition of the Remote Sensing Society, 603-609, Greenwich, UK, 9-11 September.

Kavzoğlu T., Mather P. M., (2002), “The role of feature selection in artificial neural network application”, International Journal of Remote Sensing, 23(15), 2919-2937.

Kavzoğlu T., Mather P. M., (2003), “The use of backpropagating artificial neural networks in land cover classification”, International Journal of Remote Sensing, 24 (23), 4907-4938.

Kavzoglu T., Reis S., (2008), “Performance analysis of maximum likelihood and artificial neural network classifiers for training sets with mixed pixels”, GIScience and Remote Sensing, 45 (3), 330-342.

Kavzoglu T., Yilmaz E. O., Tonbul H., (2019), “Object-based land use/land cover change detection using spatio-temporal images- A case study in metropolitan city of İstanbul, Turkey”, 40th Asian Conference on Remote Sensing, 1-7, Daejeon, Korea, 14-18 October.

Kesikoğlu H. M., Atasever H. U., Dadaser-Celik F., Özkan C., (2019), “Performance of ANN, SVM and MLH techniques for land use/cover change detection at Sultan Marshes wetland, Turkey”, *Water Science and Technology*, 80 (3), 466-477.

Keskenler M. F., Keskenler E. F., (2017), “Geçmişten günümüze yapay sinir ağları ve tarihçesi”, *Tavim-i Vekayi*, 5 (2), 8-18.

Khan A., Sohail A., Zahoor U., Qureshi A. S., (2020), “A survey of the recent architectures of deep convolutional neural networks”, *Artificial Intelligence Review*, 1-62.

Khan S., Rahmani H., Shah S. A. A., Bennamoun M., (2018), “A guide to convolutional neural networks for computer vision”, *Synthesis Lectures on Computer Vision*, 8 (1), 1-207.

Khan N., Shah J., Stavness I., (2018), “Bridgeout: stochastic bridge regularization for deep neural networks”, *IEEE*, 6 (2018), 4296-142970.

Kiranyaz S., Avci O., Abdeljaber O., Ince T., Gabbouj M., Inman D. J., (2019), “1D convolutional neural networks and applications: a survey”, *arXiv*, 1-20.

Kiranyaz S., Member S., Gastli A., Member S., (2019), “Real-time fault detection and identification for MMC using 1-d convolutional neural networks”, *IEEE Transactions on Industrial Electronics*, 66 (11), 8760-8771.

Kişî Ö., (2008), “River flow forecasting and estimation using different artificial neural network techniques”, *Hydrology Research*, 39 (1), 27-40.

Kong Y. L., Huang Q., Wang C., Chen J., Chen J., He D., (2018), “Long short-term memory neural networks for online disturbance detection in satellite image time series”, *Remote Sensing*, 10 (3), 1-13.

Kotu V., Deshpande B., (2019), “Data science: concept and practice”, 2nd Edition, Morgan Kaufmann.

Krizhevsky A., Sutskever I., Hinton G. E., (2017), “ImageNet classification with deep convolutional neural networks”, *Communications of the ACM*, 60 (6), 84-90.

Kukačka J., Golkov V., Cremers D., (2017), “Regularization for deep learning: a taxonomy”, *arXiv*, 1-24.

Kulkarni N. M., (2017), “Crop identification using unsupervised ISODATA and K-means from multispectral remote sensing imagery”, *Journal of Engineering Research and Application*, 7 (4), 45-49.

Kulkarni A. J., Satapathy S. C., (2020), “Optimization in machine learning and applications”, 1st Edition, Springer Singapore.

- Kussul N., Lavreniuk M., Skakun S., Shelestov A., (2017) "Deep learning classification of land cover and crop types using remote sensing data", IEEE Geoscience and Remote Sensing Letters, 14 (5), 778-782.
- Kuznetsov Y., Stuckler J., Leibe B., (2017), "Semi-supervised deep learning for monocular depth map prediction", 2017 IEEE Conference on Computer Vision and Pattern Recognition, 6647-6655, Honolulu, HI, USA, 21-26 July.
- Lakhal M. I., Çevikalp H., Escalera S., Ofli F., (2018), "Recurrent neural networks for remote sensing image classification", IET Computer Vision, 12 (7), 1040-1045.
- Lakshmi M., (2019), "Image classification using machine learning techniques", International Journal of Advanced Research, 7 (5), 1238-1245.
- Lary D. J., Alavi A. H., Gandomi A. H., Walker A. L., (2016), "Machine learning in geosciences and remote sensing", Geoscience Frontiers, 7 (1), 3-10.
- Lecun Y., Bengio Y., Hinton G., (2015), "Deep learning", Nature, 521 (2015), 436-444.
- LeCun Y., Boser B., Denker J. S., Henderson D., Howard R. E., Hubbard W., Jackel L.D., (1990), "Handwritten digit recognition with a back-propagation network", Advances in Neural Information Processing Systems, 2, 396- 404.
- LeCun Y., Bottou L., Haffner P., (1998), "Gradient-based learning applied to document recognition", IEEE, 86 (11), 2278-2324.
- Lee C. Y., Gallagher P. W., Tu Z., (2016), "Generalizing pooling functions in convolutional neural networks: mixed, gated, and tree", 19th International Conference on Artificial Intelligence and Statistics, 464-472, Cadiz, Spain, 9-11 May.
- Lei Ba J., Kiros J. R., Hinton G., (2016), "Layer Normalization", arXiv, 1-14.
- Le J. H., Yazdanpanah A. P., Regentova E. E., Muthukumar V. A., (2015), "Deep belief network for classifying remotely-sensed hyperspectral data", In: Bebis G. et al. (eds) Advances in Visual Computing, Springer.
- Lemberger P., (2017), "On generalization and regularization in deep learning", arXiv, 1-11.
- Liang P., Shi W., Zhang X., (2017), "Remote sensing image classification based on stacked denoising autoencoder", Remote Sensing, 10 (1), 1-12.
- Licciardi G., Frate F. D., (2010), "A neural network approach for pixel unmixing in hyperspectral data", 2nd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, Reykjavik, Iceland, 14-16 June.
- Li C., Wang Y., Zhang X., Gao H., Yang Y., Wang J., (2019), "Deep belief network for spectral-spatial classification of hyperspectral remote sensor data", Sensors, 19(1), 1-13.

- Li H., Peng J., Tao C., Chen J. J., Deng M., (2017), "What do we learn by semantic scene understanding for remote sensing imagery in cnn framework?", arXiv, 1-20.
- Li J., Cui R., Li B., Li Y., Mei S., Du Q., (2019), "Dual 1D-2D spatial-spectral CNN for hyperspectral image super-resolution", IEEE International Geoscience and Remote Sensing Symposium, 3113-3116, Yokohama, Japan, 28 July-2 August.
- Li J., Cui R., Li B., Song R., Li Y., Du Q., (2019), "Hyperspectral image super-resolution with 1D-2D attentional convolutional neural network", Remote Sensing, 11 (23), 2859.
- Li M., Zang S., Zhang B., Li S., Wu C., (2014), "A review of remote sensing image classification techniques: The role of Spatio-contextual information", European Journal of Remote Sensing, 47 (1), 389-411.
- Li S., Song W., Fang L., Chen Y., Ghamisi P., Benediktsson J. A., (2019), "Deep learning for hyperspectral image classification: an overview", IEEE Transactions on Geoscience and Remote Sensing, 57 (9), 6690-6709.
- Litta A. J., Mary Idicula S., Mohanty U. C., (2013), "Artificial neural network model in prediction of meteorological parameters during premonsoon thunderstorms", International Journal of Atmospheric Sciences, 2013 (10), 1-14.
- Liu P., Di L., Du Q., Wang L., (2018), "Remote sensing big data: theory, methods and applications", Remote Sensing, 10 (5), 2016-2019.
- Li Y., Zhang H., Xue X., Jiang Y., Shen Q., (2018), "Deep learning for remote sensing image classification: A survey", Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 8 (6), 1-17.
- Li Z., Khananian A., Fraser R. H., Cihlar J., (2001), "Automatic detection of fire smoke using artificial neural networks and threshold approaches applied to AVHRR imagery", IEEE Transactions on Geoscience and Remote Sensing, 39 (9), 1859-1870.
- Lu D., Weng Q., (2007), "A survey of image classification methods and techniques for improving classification performance", International Journal of Remote Sensing, 28 (5), 823-870.
- Lu X., Tsao Y., Matsuda S., Hori C., (2014), "Ensemble modeling of denoising autoencoder for speech spectrum restoration", INTERSPEECH, 885-889, Singapore, 14-18 September.
- Lü Q., Tang M., (2012), "Detection of hidden bruise on kiwi fruit using hyperspectral imaging and parallelepiped classification", Procedia Environmental Sciences, 12 (2012), 1172-1179.
- Maggiori E., Charpiat G., (2017), "Recurrent neural networks to correct satellite image classification maps", IEEE Transactions on Geoscience and Remote Sensing, 55 (9), 4962-4971.

Maggiori E., Tarabalka Y., Charpiat G., Alliez P., (2017), “Convolutional neural networks for large-scale remote sensing image classification”, *IEEE Transactions on Geoscience and Remote Sensing*, 55 (2), 645-657.

Mahendra H. N., Mallikarjunaswamy S., Rekha V., Puspallatha V., Sharmila N., (2019), “Performance analysis of different classifier for remote sensing application”, *International Journal of Engineering and Advanced Technology*, 9 (1), 7153-7158.

Mahmon N. A., Ya’acob N., (2014), “A review on classification of satellite image using artificial neural network (ANN)”, 5th IEEE Control and System Graduate Research Colloquium, 153-157, Shah Alam, Malaysia, 11-12 August.

Ma L., Liu Y., Zhang X., Ye Y., Yin G., Johnson B. A., (2019), “Deep learning in remote sensing applications: a meta-analysis and review”, *ISPRS Journal of Photogrammetry and Remote Sensing*, 152 (2019), 166-177.

Mammadov M., Yazici B., Yolaçan Ş., Aslanargun A., Yüzer A. F., Agaoglu E., (2006), “Statistical methods and artificial neural networks”, *Journal of Modern Applied Statistical Methods*, 5 (2), 495-512.

Maselli F., Conese C., Petkov L., (1994), “Use of probability entropy for the estimation and graphical representation of the accuracy of maximum likelihood classifications”, *ISPRS Journal of Photogrammetry and Remote Sensing*, 49 (2), 13-20.

Mas J. F., Flores J. J., (2008), “The application of artificial neural networks to the analysis of remotely sensed data”, *International Journal of Remote Sensing*, 29 (3), 617-663.

Marius P., Balas V. E., Mastorakis N., (2009). “Multilayer perceptron and neural networks”, *WSEAS Trans Circuits Systems*, 8 (7), 579-588.

Mather P., Tso B., (2016), “Classification methods for remotely sensed data”, 2nd Edition, CRS Press.

Maxwell A., Warner T., Fang F., (2018), “Implementation of machine-learning classification in remote sensing: an applied review”, *International Journal of Remote Sensing*, 39 (9), 2784-2817.

Mehta P., Wang C., Day A. G. R., Richardson C., Fisher C. K., Ai U., Francisco S., Schwab D. J., Ave F., York N., (2019), “A high-bias, low-variance introduction to machine learning for physicists”, *Physics Report*, 810 (2019), 1-124.

Meireles M. R. G., Almeida P. E. M., Simões M. G., (2003), “A comprehensive review for industrial applicability of artificial neural networks”, *IEEE Transactions on Industrial Electronics*, 50 (3), 585-601.

Mcculloch W. S., Pitts W., (1943), “A logical calculus of the ideas immanent in nervous activity”, *The Bulletin of Mathematical Biophysics*, 5 (4), 115-133.

Minsky M., Papert S., (1969), “Perceptrons”, M.I.T. Press.

Morerio P., Cavazza J., Volpi R., Vidal R., Murino V., (2017), "Curriculum Dropout", e-prints arXiv:1703.06229.

Mosavi A., Ardabili S., Varkonyi-koczy A. R., (2019), "List of deep learning models", INTER-ACADEMIA, 202-214, Budapest, Hungary, 4-7 September.

Mou L., Ghamisi P., Zhu X. X., (2017), "Deep recurrent neural networks for hyperspectral image classification", IEEE Transactions on Geoscience and Remote Sensing, 55 (7), 3639-3655.

Mukhopadhyay S., Mukhopadhyay S., (2018), "Advanced data analytics using python", 1st Edition, Apress.

Murugan P., Durairaj S., (2017), "Regularization and optimization strategies in deep convolutional neural network", arXiv, 1-15.

Mustapha M. R., Lim H. S. Mat Jafri M. Z., (2010), "Comparison of neural network and maximum likelihood approaches in image classification", Journal of Applied Sciences, 10 (22), 2847-2854.

Ndehedehe C., Ekpa A., Simeon O., Nse O., (2013), "Understanding the neural network technique for classification of remote sensing data sets", New York Science Journal, 6 (8), 26-33.

Ndikumana E., Ho D., Minh T., Baghdadi N., Courault D., Hossard L., (2018), "Deep recurrent neural network for agricultural classification using multitemporal SAR Sentinel-1 for Camargue", Remote Sensing, 10 (8), 1-16.

Nguyen G., Dlugolinsky S., Bobák M., Tran V., López Á., Ignacio G., Peter H., Ladislav M., (2020), "Machine learning and deep learning frameworks and libraries for large-scale data mining: a survey". Artificial Intelligence Review, 52 (1), 77-124.

Noriega L., (2005), "Multilayer perceptron tutorial", 1-12.

Nusrat I., Jang S. B., (2018), "A comparison of regularization techniques in deep neural networks", Symmetry, 10 (11).

Nwankpa C., Ijomah W., Gachagan A., Marshall S. (2018), "Activation Functions: Comparison of trends in Practice and Research for Deep Learning", arXiv, 1-20.

Ojaghi S., Ebadi H., Ahmadi F. F., (2015), "Using artificial neural network for classification of high resolution remotely sensed images and assessment of its performance compared with statistical methods", American Journal of Engineering, Technology and Society, 2 (1), 1-8.

Özbay F. A., (2020), "Çevrimiçi sosyal medyada sahte haber tespiti", Dicle Ün,versitesi Mühendislik Fakültesi Mühendislik Dergisi, 11(1), 91-103.

Öztürk K., Şahin M. E., (2018), "Yapay sinir ağları ve yapay zekâya genel bir bakış", Takvim-i Vekayi, 6 (2), 25-36.

Pal M., Mather P. M., (2005), "Support vector machines for classification in remote sensing", *International Journal of Remote Sensing*, 26 (5), 1007-1011.

Paoletti M. E., Haut J. M., Plaza J., Plaza A., (2018), "A new deep convolutional neural network for fast hyperspectral image classification", *ISPRS Journal of Photogrammetry and Remote Sensing*, 145 (2018), 120-147.

Pasupa K., Sunhem W., (2016), "A comparison between shallow and deep architecture classifiers on small dataset", 8th International Conference on Information Technology and Electrical Engineering, 1-6, Yogyakarta, Indonesia, 5-6 October.

Pekel E., Soner Kara S., (2017), "A comprehensive review for artificial neural network application to public transportation", *Journal of Engineering & Natural Sciences*, 35 (1), 157-179.

Radhika K., Varadarajan S., (2018), "A neural network-based classification of satellite images for change detection applications", *Cogent Engineering*, 5 (1), 1-9.

Panigrahi S., Verma K., Tripathi P., (2019), "Land cover change detection using focused time delay neural network", *Software Computing*, 23 (17), 7699-7713.

Pradhan R., Pradhan M. P., Bhusan A., Pradhan R. K., Ghose M. K., (2010), "Land-cover classification and mapping for eastern himalayan state sikkim", *Journal of Computing*, 2 (3), 166-170.

Prechelt L., (1998), "Automatic early stopping using cross validation: quantifying the criteria", *Neural Networks*, 11 (4), 761-767.

Qiang Y., Lam N. S. N., (2015), "Modeling land use and land cover changes in a vulnerable coastal region using artificial neural networks and cellular automata", *Environmental Monitoring and Assessment* 187, 57 (2015), 1-6.

Rosenblatt F., (1958), "The perceptron: a probabilistic model for information storage and organization in the brain", *Psychological Review*, 65 (6), 386-408.

Rubwurm M., Korner M., (2017), "Temporal vegetation modelling using long short-term memory networks for crop identification from medium-resolution multi-spectral satellite images", *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, 1496-1504, Honolulu, HI, USA, 21-26 July.

Ruder S., (2016), "An overview of gradient descent optimization", *arXiv*, 1-14.

Ruder S., (2017), "An overview of multi-task learning in deep neural networks", *arXiv*, 1-14.

Sağlam A., Baykan N. A., (2018), "A satellite image classification approach by using one dimensional discriminant analysis", *Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42 (3W4), 429-435.

Salah M., (2017), "A survey of modern classification techniques in remote sensing for improved image classification", *Journal of Geomatics*, 11(1), 2-22.

Schmidt M., Fung G., Rosales R., (2007), "Fast optimization methods for L1 regularization: a comparative study and two new approaches", *Lecture Notes in Computer Science*, 471 (2007), 286-297.

Shahid N., Rappon T., Berta W., (2019), "Applications of artificial neural networks in health care organizational decision-making: a scoping review", *PLoS ONE*, 14 (2), 1-22.

Shatnawi A., Al-bdour G., Al-qurran R., Al-ayyoub M., (2018), "A comparative study of open source deep learning frameworks", *Proceedings of the 9th International Conference on Information and Communication Systems*, 72-77, Irbid, Jordan, 3-5 April.

Sheldon R. A., (1990), "Satellite image analysis using neural networks", *Telematics and Informatics*, 7 (3-4), 431-439.

Shi B., Bai X., Liu W., Wang J., (2014), "Deep regression for face alignment", *arXiv*, 1-9.

Shivakumar B. R., Prakash J., (2018), "A novel method for denoising remotely sensed hyperspectral image using autoencoder technique", *International Journal of Applied Engineering Research*, 13 (20), 14733-14740.

Sildir H., Aydin E., Kavzoglu T., (2020), "Design of feedforward neural networks in the classification of hyperspectral imagery using superstructural optimization", *Remote Sensing*, 12 (6), 1-19

Sisodia P. S., Tiwari V., Kumar A., (2014), "Analysis of supervised maximum likelihood classification for remote sensing image", *International Conference on Recent Advances and Innovations in Engineering*, 9-12, Jaipur, India, 9-11 May.

Smirnov E. A., Timoshenko D. M., Andrianov S. N., (2014), "Comparison of regularization methods for ImageNet classification with deep convolutional neural networks". *AASRI Procedia*, 6 (2014), 89-94.

Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R., (2014), "Dropout: a simple way to prevent neural networks from overfitting", *Journal of Machine Learning Research*, 15 (56), 1929-1958.

Strahler A. H., Boschetti L., Foody G. M., Friedl M. A., Hansen M. C., Herold, M., Mayaux, P., Morissette, J. T., Stehman, S. V., & Woodcock, C. E., (2006), "Global land cover validation: recommendations for evaluation and accuracy assessment of global land cover maps", 1st Edition, the EU.

Szegedy C., Toshev A., Erhan D., (2013), "Deep neural networks for object detection", *Advantages in Neural Information Processing Systems*, 2553-2561, Lake Tahoe, Nevada, USA, 5-10 December.

Switzer P., (1980), "Extensions of linear discriminant analysis for statistical classification of remotely sensed satellite imagery", *Journal of the International Association for Mathematical Geology*, 12 (4), 367-376.

Tao J., Xinjie W., (2020), "Hyperspectral images classification based on fusion features derived from 1D and 2D convolutional neural network", *International Conference on Geomatics in the Big Data Era*, 335-341, Guilin, Guangxi, China, 15-17 November.

Tonbul H., Kavzoğlu T., (2017), "Nesne-tabanlı sınıflandırmada segmentasyon (bölütleme) kalitesinin sınıflandırma doğruluğu üzerine etkisinin incelenmesi", *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 17 (2017), 118-125.

Topouzelis K., Karathanassi V., Pavlakis P., Rokos D., (2004), "Oil spill detection using RBF neural networks and SAR data", *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 7 (5), 142.

Thung K. H., Wee C. Y., (2018), "A brief review on multi-task learning", *Multimedia Tools and Applications*, 77 (22), 29705-29725.

Tomczak J. M., (2013), "Prediction of breast cancer recurrence using classification restricted Boltzmann Machine with dropping", *arXiv*, 1-9.

Vanitha A., Subashini P., Krishnaveni M., (2013), "SAR ice image classification using parallelepiped classifier based on Gram-Schmidt spectral technique", *Computer Science & Information Technology*, 3 (5), 385-392.

Venkatesan R., Prabu S., (2019), "Hyperspectral image features classification using deep learning recurrent neural networks", *Journal of Medical Systems*, 43 (2019), 216.

Venkateswaran K., Kasthuri N., Balakrishnan K., Prakash K., (2013), "Performance analysis of k-means clustering for remotely sensed images", *International Journal of Computer Applications*, 84 (12), 23-27.

Vieira J. P. A., Moura R. S., (2017), "An analysis of convolutional neural networks for sentence classification", *2017 XLIII Latin American Computer Conference*, 1-5, Cordoba, Argentina, 4-8 September.

Wang H., Raj B., (2017), "On the origin of deep learning", *arXiv*, 1-72.

Wang S., Manning C. D., (2012), "Baselines and bigrams: simple, good sentiment and topic classification", *50th Annual Meeting of the Association for Computational Linguistics*, 90-94, Jeju, Korea, 8-14 July.

Wan L., Zeiler M., Zhang S., LeCun Y. L., Fergus R., (2013), "Regularization of neural network using DropConnect", *30th International Conference on Machine Learning (ICML)*, 1058-1066, Atlanta, GE, USA, 17-19 June.

Wang Y, Jamshidi M., (2004), “Fuzzy logic applied in remote sensing image classification”, 2004 IEEE International Conference on Systems, Man and Cybernetics, 6378-6382, The Hague, Netherlands, 10-13 October.

Wang Y., Wang X., Jian J., (2019), “Remote sensing landslide recognition based on convolutional neural network”, Mathematical Problems in Engineering, 2019, 1-12.

Wang Q., JaJa J., (2014), “From maxout to channel-out: encoding information on sparse pathways”, International Conference on Artificial Neural Networks, 273-280, Hamburg, Germany, 15-19 September.

Web 1, (2020), <https://developers.google.com/machine-learning/crash-course/classification/roc-and-auc>, (Erişim Tarihi: 01/06/2020).

Web 2, (2000), <https://cs.stanford.edu/people/eroberts/courses/soco/projects/neural-networks/History/index.html>, (Erişim Tarihi: 10/06/2020).

Web 3, (2020), <https://www.tensorflow.org/learn>, (Erişim Tarihi: 05/06/2020).

Web 4, (2020), <https://keras.io/>, (Erişim Tarihi: 10/06/2020).

Web 5, (2017), <https://docs.microsoft.com/en-us/cognitive-toolkit/>, (Erişim Tarihi: 10/06/2020).

Web 6, (2020), <https://www.mathworks.com/help/images/deep-learning.html>, (Erişim Tarihi: 16/05/2020).

Web 7, (2020), https://crs.hi.is/?page_id=877, (Erişim Tarihi: 16/05/2020).

Windrow B., Walach E., (2008), “Thirty years of adaptive neural networks: perceptron, madaline, and backpropagation”, Reissue Edition, 2008 the Institute of Electrical and Electronics Engineers.

Xiang M., Hung C., Pham M., Kuo B., Coleman T., (2005), “A parallelepiped multispectral image classifier using genetic algorithms”, 2005 IEEE International Geoscience and Remote Sensing Symposium, 482-485, Seoul, South Korea, 29 July.

Xie T., Yu H., Wilamowski B., (2011), “Comparison between traditional neural networks and radial basis function networks”, 2011 IEEE International Symposium on Industrial Electronics, 1194-1199, Gdansk, Poland, 27-30 June.

Yang C., Li W., Lin Z., (2018), “Vehicle object detection in remote sensing imagery based on multi-perspective convolutional neural network”, International Journal of Geo-Information, 7 (7), 249.

Yan F., Gong Y., Feng Z., (2015), “Combination of artificial neural network with multispectral remote sensing data as applied in site quality evaluation in Inner Mongolia”, Croatian Journal of Forest Engineering, 36 (2), 307-319.

Yang J., Fu X., Hu Y., Huang Y., Ding X., Paisley J., (2017), "PanNet: a deep network architecture for pan-sharpening", 2017 IEEE International Conference on Computer Vision, 1753-1761, Venice, Italy, 22-29 October.

Yamashita R., Nishio M., Do R. K. G., Togashi K., (2018), "Convolutional neural networks: an overview and application in radiology", *Insights into Imaging*, 9 (4), 611-629.

Yazıcı A. C., Ögüş E., Ankaralı S., Canan, S., Ankaralı H., Akkuş, Z., (2007), "Yapay sinir ağlarına genel bakış", *Türkiye Klinikleri Tıp Bilimleri Dergisi*, 27 (1), 65-71.

Yegnanarayana B., (2006), "Artificial neural networks", 1st Edition, New Delhi: Prentice-Hall of India.

Yuan H., Van Der Wiele C.F., Khorram S., (2009), "An automated artificial neural network system for land use/landcover classification from Landsat TM imagery", *Remote Sensing*, 1, 243-265.

Yu H., Xie T., Paszczyński S., Wilamowski B. M., (2011), "Advantages of radial basis function networks for dynamic system design", *IEEE Transactions on Industrial Electronics*, 58 (12), 5438-5450.

Zbakh A., Mdaghri Z. A., Benyoussef A., El Kenz A., El Yadari M., (2019), "Spectral classification of a set of hyperspectral images using the convolutional neural network, in a single training", *International Journal of Advanced Computer Science and Applications*, 10 (6), 245-250.

Zhang A., Lipton Z. C., Li M., Smola A. J., (2020), "Dive into deep learning".

Zhang L., Zhang L., Du B. O. (2016), "Deep learning for remote sensing data: a technical tutorial on the state of the art", *IEEE Geoscience and Remote Sensing Magazine*, 4 (2), 22-40.

Zhang L., Xia G. S., Wu T., Lin L., Tai X. C., (2016), "Deep learning for remote sensing image understanding", *Journal of Sensors*, 2016, 1-3.

Zhang S. L., Chang T. C., (2015), "A study of image classification of remote sensing based on back-propagation neural network with extended delta bar delta", *Mathematical Problems in Engineering*, 2015, 1-12.

Zhang X., LeCun Y., (2015), "Text understanding from scratch", *arXiv*, 1-10.

Zhang X., Xu C., Shen M., He X., Du W., (2018), "Survey of convolutional neural network", *International Conference on Network, Communication, Computer Engineering*, 93-97, Seattle, WA, USA, 14-16 February.

Zhao W., Du S., (2016), "Learning multiscale and deep representations for classifying remotely sensed imagery", *ISPRS Journal of Photogrammetry and Remote Sensing*, 113 (2016), 155-165.

Zhou L., Yang X., (2008), "Use of neural networks for land cover classification from remotely sensed imagery", *Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38 (7), 575-578.

Zhu X. X., Tuisa D., Mou L., Xia G., Zhang L., Xu F., Fraundorfer F., (2017), "Deep learning in remote sensing: a comprehensive review and list of resources", *IEEE Geoscience and Remote Sensing Magazine*, 5 (4), 8-36.

Zou W., Yan W. Y., Shaker A., (2012), "Neural network based remote sensing image classification in urban area", *The 2012 International Joint Conference on Neural Networks*, 1-6, Brisbane, QLD, Australia, 10-15 June.

ÖZGEÇMİŞ

Elif Özlem YILMAZ 1994 yılında İstanbul’da doğdu. 2017 yılında İstanbul Teknik Üniversitesinden Geomatik Mühendisliği Lisans programından bölüm üçüncülüğü ile mezun oldu. Ardından aynı üniversitede yüksek lisans eğitime başlamıştır. Yatay geçiş ile Gebze Teknik Üniversitesinde Harita Mühendisliğinde yüksek lisans eğitime devam etmiştir. Ayrıca 2019 yılından itibaren Araştırma Görevlisi kadrosu ile Gebze Teknik Üniversitesinde görev yapmaktadır.