



**HİPERSPEKTRAL GÖRÜNTÜ SINIFLANDIRMA
UYGULAMALARINDA MAKİNE VE
DERİN ÖĞRENME KULLANIMI**

YÜKSEK LİSANS TEZİ

Eren Can SEYREK

Danışman

Doç. Dr. Murat UYSAL

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

Ocak 2021

Bu tez çalışması 20.FEN.BİL.12 numaralı proje ile AKÜ BAPK tarafından desteklenmiştir.

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

HİPERSPEKTRAL GÖRÜNTÜ SINIFLANDIRMA
UYGULAMALARINDA MAKİNE VE
DERİN ÖĞRENME KULLANIMI

Eren Can SEYREK

Danışman

Doç. Dr. Murat UYSAL

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

Ocak 2021

BİLİMSEL ETİK BİLDİRİM SAYFASI

Afyon Kocatepe Üniversitesi

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

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

beyan ederim.

15 / 01 / 2021

Eren Can SEYREK

ÖZET

Yüksek Lisans Tezi

HİPERSPEKTRAL GÖRÜNTÜ SINIFLANDIRMA UYGULAMALARINDA MAKİNE ve DERİN ÖĞRENME KULLANIMI

Eren Can SEYREK

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Harita Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Murat UYSAL

Uzaktan algılama (UA) ile elde edilen görüntüler dünya yüzeyindeki nesnelere hakkında detaylı bilgi toplamasını mümkün kılmaktadır. Elde edilen görüntülerin sınıflandırılmasıyla oluşturulan arazi örtüsü haritaları kaynakların izlenmesi, çevresel değişimin tespiti ve planlama gibi birçok alanda geniş bir kullanım alanına sahiptir. Dolayısıyla harita kullanıcıları doğru ve güvenilir arazi örtüsü haritalarına ihtiyaç duymaktadır. Temel sınıflardan oluşan haritaların üretilmesi için multispektral sensörlerden elde edilmiş veriler yeterli olurken, özellikle tür içi farklılar içeren sınıflar da dahil olmak üzere detaylı sınıfların bulunması bu verilerin sınıflandırma için yeterli spektral bilgiyi sağlayamamasına yol açmaktadır. Bu durumda yüzlerce dar aralıkta banda sahip olan hiperspektral görüntülerin, nesnelere hakkında daha detaylı spektral yansıtım bilgisini sunmaktadır. Hiperspektral görüntülerin geleneksel yöntemlerle sınıflandırılması hesaplama zorluğu sebebiyle yetersiz kalmaktadır. Bu durumda Makine Öğrenme (MÖ) ve Derin Öğrenme (DÖ) gibi yöntemler kullanıcılara bu tarz verilerde birçok avantaj sunmaktadır.

Bu tez kapsamında MÖ yöntemlerinden Destek Vektör Makineleri, Rastgele Orman, DÖ'de özellikle görüntü sınıflandırma alanında yaygın olarak kullanılan Evrişimli Sinir Ağı (ESA) kullanılmıştır. Çalışmada kullanılan ESA mimarileri yapısal özelliklerine göre 2B ESA ve 3B+2B ESA olarak isimlendirilmiştir. Yöntemlerin karşılaştırılması 176 bant spektral ve 30 metre konumsal çözünürlüklü HyRANK, 144 bant ve 2,5 metre konumsal çözünürlüklü DFC13 ile 202 bant ve 3,7 metre konumsal çözünürlüklü Salinas Scene veri

setleri ile gerçekleştirilmiştir. Modellerde eğitim veri setinin etkisini arařtırmak amacıyla her veri seti için 30%, 50% ve 70% eğitim veri kümesi oranları test edilmiştir. Çalışma sonucunda ESA modellerinin hiperspektral görüntülerin sınıflandırılmasında kullanımının yüksek doğruluk sağladıkları görülmüştür. Eğitim veri kümesi boyutunun araştırılması aşamasında ise beklendiği üzere 70% eğitim verisi kullanımının en yüksek doğruluğu sağladığı, bunun yanında 30% veri seti kullanımının da tatmin edici bir sınıflandırma doğruluğu sağladığı söylenebilir.

2021, xiv + 137 sayfa

Anahtar Kelimeler: Hiperspektral görüntü, Görüntü sınıflandırma, Makine öğrenme, Destek vektör makineleri, Rastgele orman, Derin öğrenme, Evrişimli sinir ağı.

ABSTRACT

M.Sc. Thesis

THE USE OF MACHINE AND DEEP LEARNING ON HYPERSPECTRAL IMAGE CLASSIFICATION APPLICATIONS

Eren Can SEYREK

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Geomatics Engineering

Supervisor: Assoc. Prof. Murat UYSAL

Remotely sensed images enable to collect detailed information about objects on the earth's surface. Land cover maps created by classifying the remotely sensed images have a wide range of uses in many areas such as monitoring resources, detecting environmental change and planning. Therefore, map users need accurate and reliable land cover maps. Images which obtained from multispectral sensors is sufficient to produce maps consisting of basic classes. However, the existence of detailed classes that including classes with intra-species differences causes these data to not provide sufficient spectral information for classification. In this case, hyperspectral images with hundreds of narrow bands offer more detailed spectral reflection information about objects. Classification of hyperspectral images by traditional methods is insufficient due to calculation difficulties. In this case, methods such as Machine Learning and Deep Learning offer many advantages to users in such data.

In this thesis, Support Vector Machines, Random Forest, and Convolutional Neural Network (CNN), which are widely used in the field of image classification in Deep Learning were used for classifying hyperspectral images. The CNN architectures used in the study are named as 2D CNN and 3D + 2D CNN according to their structural features. Comparison of the methods was performed with HyRANK (176 band spectral and 30 meter spatial resolution), DFC13 (144 band and 2,5 meter spatial resolution), Salinas Scene (202 band and 3,7 meter spatial resolution) data sets. In order to investigate the effect of training data set on models, 30%, 50% and 70% training data set ratios were

tested for each data set. As a result of the study, it was seen that the use of CNN models for classification of hyperspectral images provided high accuracy. When investigating the size of the training dataset, it can be said that the use of 70% training data provides the highest accuracy as expected, while the use of 30% data set provides a satisfactory classification accuracy.

2021, xiv + 137 pages

Keywords: Hyperspectral image, Image classification, Machine learning, Support Vector Machines, Random forest, Deep learning, Convolutional neural network.

TEŐEKKÜR

Bu arařtırmanın konusu, deneysel alıřmaların ynlendirilmesi, sonuların deęerlendirilmesi ve yazımı ařamasında yapmıř olduęu byk katkılarından dolayı tez danıřmanım Sayın Do. Dr. Murat UYSAL'a, deęerli bilgilerinden faydalandıęım Do. Dr. İsmail LKESEN'e, arařtırma ve yazım sresince yardımlarını esirgemeyen deęerli arkadařım Arř. Grv. Alper Tunga AKIN'a, nerilerinden yararlandıęım alıřma arkadařım Arř. Grv. mer Gkberk NARİN'e, her konuda neri ve eleřtirileriyle yardımlarını grdęm hocalarıma ve arkadařlarıma teőekkr ederim.

Bu arařtırmada kullanılan DFC13 veri setini cretsiz olarak saęlayan IEEE-GRSS Veri Fzyonu Komitesine, Houston niversitesi NSF Tarafından Finanse Edilen Hava Lazer Haritalama Merkezine (NCALM) ve Hiperspektral Grnt Analizi Grubuna teőekkr ederim.

Bu tez alıřması AK BAPK tarafından 20.FEN.BİL.12 numaralı proje kapsamında desteklenmiřtir.

Bu arařtırma boyunca maddi ve manevi desteklerinden dolayı aileme teőekkr ederim.

Eren Can SEYREK

Afyonkarahisar 2021

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER DİZİNİ.....	vi
KISALTMALAR DİZİNİ	viii
ŞEKİLLER DİZİNİ	ix
ÇİZELGELER DİZİNİ.....	xiii
1. GİRİŞ.....	1
2. LİTERATÜR BİLGİLERİ.....	6
3. MATERYAL ve METOT.....	11
3.1 Donanım ve Yazılım.....	11
3.2 Hiperspektral Görüntü	12
3.3 Veri Setleri	14
3.3.1 HyRANK Veri Seti	14
3.3.1.1 Dioni Veri Seti	15
3.3.1.2 Loukia Veri Seti	16
3.3.2 DFC13 Veri Seti.....	17
3.3.3 Salinas Scene Veri Seti.....	18
3.4 Temel Bileşenler Analizi.....	20
3.5 Makine Öğrenme Algoritmaları	23
3.5.1 Destek Vektör Makineleri Algoritması	25
3.5.2 Rastgele Orman Algoritması	29
3.5.3 Derin Öğrenme	31
3.5.4 Evrişimli Sinir Ağları (Convolutional Neural Networks)	32
3.5.4.1 Giriş Katmanı (Input Layer)	34
3.5.4.2 Evrişim Katmanı (Convolutional Layer)	35
3.5.4.3 Havuzlama Katmanı (Pooling Layer)	38
3.5.4.4 Tam Bağlı Katman (Fully Connected Layer)	40
3.5.4.5 2B ESA Mimarisi.....	40

3.5.4.6 3B+2B ESA Mimarisi.....	42
3.6 Doğruluk Analizi.....	43
3.6.1 Genel Doğruluk.....	45
3.6.2 Üretici ve Kullanıcı Doğrulukları.....	46
3.6.3 Kappa İstatistiği.....	46
3.6.4 McNemar's Testi.....	47
4. UYGULAMA.....	49
4.1 TBA ile Veri Setlerinin Boyutlarının İndirgenmesi.....	50
4.2 Dioni Veri Seti Sınıflandırma Sonuçları.....	52
4.3 Loukia Veri Seti Sınıflandırma Sonuçları.....	63
4.4 DFC13 Veri Seti Sınıflandırma Sonuçları.....	75
4.5 Salinas Scene Veri Seti Sınıflandırma Sonuçları.....	85
5. SONUÇLAR ve TARTIŞMA.....	95
6. KAYNAKLAR.....	101
ÖZGEÇMİŞ.....	112
EKLER.....	114

KISALTMALAR DİZİNİ

AVIRIS	Airborne Visible/Infrared Imaging Spectrometer
CART	Classification and Regression Trees
CNN	Convolutional Neural Networks
CORINE	Coordination of Information on the Environment
CUDA	Compute Unified Device Architecture
DFC	Data Fusion Contest
DFC13	Data Fusion Contest 2013
DÖ	Derin Öğrenme
DVM	Destek Vektör Makineleri
EÇB	En Çok Benzerlik
EO-1	Earth Observing-1
ESA	Evrişimli Sinir Ağları
EYK	En Yakın Komşuluk
GRSS	Geoscience and Remote Sensing Society
IEEE	Institute of Electrical and Electronics Engineers
ISODATA	Iterative Self Organizing Data Analysis Technique
ISPRS	International Society for Photogrammetry and Remote Sensing
İHA	İkili Hiyerarşik Ağaç
İHA-TKT	İkili Hiyerarşik Ağaç - Teke Karşı Tümü
LiDAR	Light Detection and Ranging
MÖ	Makine Öğrenme
NASA	National Aeronautics and Space Administration
NCALM	National Center for Airborne Laser Mapping
OOB	Out-of-Bag
RADAR	Radio Detection and Ranging
ReLU	Rectified Linear Unit
RO	Rastgele Orman
RTF	Radyal Tabanlı Fonksiyon
SAH	Spektral Açık Haritalama
SGD	Stochastic Gradient Descent
TBA	Temel Bileşenler Analizi
TKT-DVM	Teke Karşı Tümü Destek Vektör Makineleri
TT-DVM	Teke Tek Destek Vektör Makineleri
UA	Uzaktan Algılama
YSA	Yapay Sinir Ağları

ŞEKİLLER DİZİNİ

Sayfa

Şekil 3.1 Dioni veri setinin (a) Gerçek Renk, (b) Gerçek Renk + yer doğrulama ve (c) yer doğrulama görüntüleri.	15
Şekil 3.2 Loukia veri setinin (a) Gerçek Renk, (b) Gerçek Renk + yer doğrulama ve (c) yer doğrulama görüntüleri.	16
Şekil 3.3 DFC13 veri setinin (a) Gerçek Renk, (b) Gerçek Renk + yer doğrulama ve (c) yer doğrulama görüntüleri.	17
Şekil 3.4 Salinas Scene veri setinin (a) Gerçek Renk, (b) Gerçek Renk + yer doğrulama ve (c) yer doğrulama görüntüleri.	19
Şekil 3.5 Klasik programlama ile MÖ'nün farkı.	23
Şekil 3.6 MÖ türleri (Nassif vd. 2019).	24
Şekil 3.7 İki sınıfı en optimum şekilde ayıran hiperdüzlem (İnt.Kyn.6).	25
Şekil 3.8 RO algoritmasının çalışma prensibi.	30
Şekil 3.9 Yapay zekâ, MÖ, YSA ve DÖ arasındaki ilişki.	31
Şekil 3.10 Neocognitron ağının şematik gösterimi (Fukushima 1980).	33
Şekil 3.11 LeNet5 ESA mimarisinin şematik gösterimi (LeCun vd. 1998).	33
Şekil 3.12 Evrişim işlemi (Ghatak 2019).	36
Şekil 3.13 ReLU aktivasyon fonksiyonunun grafiği (Agarap 2018).	38
Şekil 3.14 5×5 boyutundaki girdi matrisine 1×1 kaydırma adımı ile 3×3 boyutunda havuzlama operasyonu uygulanması (Dumoulin ve Visin 2018).	39
Şekil 3.15 Önerilen 2B ESA modelinin şematik gösterimi.	41

Şekil 3.16 Önerilen 3B+2B ESA mimarisinin şematik gösterimi.....	42
Şekil 3.17 Hata matrisinin şematik gösterimi.	44
Şekil 3.18 McNemar's Testi olumsuzluk tablosu.	48
Şekil 4.1 Dioni (a), Loukia (b), DFC13 (c) ve Salinas Scene (d) veri setleri için temel bileşenlerin açıklanabilir varyansları.....	50
Şekil 4.2 Dioni (a), Loukia (b), DFC13 (c) ve Salinas Scene (d) veri setleri için temel bileşenlerin kümülatif varyansları.	51
Şekil 4.3 Dioni veri seti (a) için eğitim-test piksellerinin sırasıyla 30%(b)-70%(c), 50%(d)-50%(e) ve 70%(f)-30%(g) dağılımları.	53
Şekil 4.4 Dioni veri seti için sırasıyla 30% (a), 50% (b) ve 70% (c) eğitim kümesi boyutlarına göre RO algoritmasının OOB hataları.....	53
Şekil 4.5 Dioni veri setinin sınıflandırılması için 30%, 50% ve 70% eğitim verisi ile oluşturulan ESA modellerinin kayıp fonksiyonu ve model doğruluğu grafikleri.	54
Şekil 4.6 Dioni 30% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).....	57
Şekil 4.7 Dioni 50% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).	60
Şekil 4.8 Dioni 70% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).	62
Şekil 4.9 Loukia veri seti (a) için eğitim-test piksellerinin sırasıyla 30%(b)-70%(c), 50%(d)-50%(e) ve 70%(f)-30%(g) dağılımları.	64
Şekil 4.10 Loukia veri seti için sırasıyla 30% (a), 50% (b) ve 70% (c) eğitim kümesi boyutlarına göre RO algoritmasının OOB hataları.....	65

Şekil 4.11 Loukia veri setinin sınıflandırılması için 30%, 50% ve 70% eğitim verisi ile oluşturulan ESA modellerinin kayıp fonksiyonu ve model doğruluğu grafikleri.	66
Şekil 4.12 Loukia 30% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).	68
Şekil 4.13 Loukia 50% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).	71
Şekil 4.14 Loukia 70% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).	74
Şekil 4.15 DFC13 veri seti (a) için eğitim-test piksellerinin sırasıyla 30%(b)-70%(c), 50%(d)-50%(e) ve 70%(f)-30%(g) dağılımları.	76
Şekil 4.16 DFC13 veri seti için sırasıyla 30% (a), 50% (b) ve 70% (c) eğitim kümesi boyutlarına göre RO algoritmasının OOB hataları.....	77
Şekil 4.17 DFC13 veri setinin sınıflandırılması için 30%, 50% ve 70% eğitim verisi ile oluşturulan ESA modellerinin kayıp fonksiyonu ve model doğruluğu grafikleri.	78
Şekil 4.18 DFC13 30% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).	80
Şekil 4.19 DFC13 50% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).	82
Şekil 4.20 DFC13 70% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).	84
Şekil 4.21 Salinas Scene veri seti (a) için eğitim-test piksellerinin sırasıyla 30%(b)-70%(c), 50%(d)-50%(e) ve 70%(f)-30%(g) dağılımları.	86

- Şekil 4.22** Salinas Scene veri seti için sırasıyla 30% (a), 50% (b) ve 70% (c) eğitim kümesi boyutlarına göre RO algoritmasının OOB hataları. 86
- Şekil 4.23** Salinas Scene veri setinin sınıflandırılması için 30%, 50% ve 70% eğitim verisi ile oluşturulan ESA modellerinin kayıp fonksiyonu ve model doğruluğu grafikleri. 87
- Şekil 4.24** Salinas Scene 30% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f)... 89
- Şekil 4.25** Salinas Scene 50% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f)... 91
- Şekil 4.26** Salinas Scene 70% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f)... 93

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1 Kullanılan iş istasyonunun donanım bileşenleri.	11
Çizelge 3.2 Başlıca hiperspektral sensörler ve özellikleri.....	13
Çizelge 3.3 Önerilen 2B ESA modelinin Salinas Scene veri seti için özeti.....	42
Çizelge 3.4 Önerilen 3B+2B ESA modelinin Salinas Scene veri seti için özeti.....	43
Çizelge 3.5 Kappa İstatistiği değerinin yorumlanması (Viera ve Garrett 2005).....	47
Çizelge 4.1 Dioni veri setinde sınıflar ve 30%-50%-70% eğitim veri kümesi oranlarına göre eğitim ve test için ayrılan etiketli veri sayıları.	52
Çizelge 4.2 Dioni 30% veri seti için algoritmaların performansları.	55
Çizelge 4.3 Dioni 50% veri seti için algoritmaların performansları.	59
Çizelge 4.4 Dioni 70% veri seti için algoritmaların performansları.	61
Çizelge 4.5 Dioni veri seti için hesaplanan McNemar's testi sonuçları.....	63
Çizelge 4.6 Loukia veri setinde sınıflar ve 30%-50%-70% eğitim veri kümesi oranlarına göre eğitim ve test için ayrılan etiketli veri sayıları.	64
Çizelge 4.7 Loukia 30% veri seti için algoritmaların performansları.	67
Çizelge 4.8 Loukia 50% veri seti için algoritmaların performansları.	70
Çizelge 4.9 Loukia 70% veri seti için algoritmaların performansları.	73
Çizelge 4.10 Loukia veri seti için hesaplanan McNemar's testi sonuçları.	75
Çizelge 4.11 DFC13 veri setinde sınıflar ve 30%-50%-70% eğitim veri kümesi oranlarına göre eğitim ve test için ayrılan etiketli veri sayıları.	76
Çizelge 4.12 DFC13 30% veri seti için algoritmaların performansları.....	79
Çizelge 4.13 DFC13 50% veri seti için algoritmaların performansları.....	81
Çizelge 4.14 DFC13 70% veri seti için algoritmaların performansları.....	83
Çizelge 4.15 DFC13 veri seti için hesaplanan McNemar's testi sonuçları.	85

Çizelge 4.16 Salinas Scene veri setinde sınıflar ve 30%-50%-70% eğitim veri kümesi oranlarına göre eğitim ve test için ayrılan etiketli veri sayıları.	85
Çizelge 4.17 Salinas Scene 30% veri seti için algoritmaların performansları.	88
Çizelge 4.18 Salinas Scene 50% veri seti için algoritmaların performansları.	90
Çizelge 4.19 Salinas Scene 70% veri seti için algoritmaların performansları.	92
Çizelge 4.20 Salinas Scene veri seti için hesaplanan McNemar's testi sonuçları.....	94
Çizelge 5.1 Modellerin veri setleri ve eğitim veri küme oranlarına göre genel doğrulukları.....	97



1. GİRİŞ

Arazi örtüsü insanlar ile fiziksel çevreyi birbirine bağlayan kritik değişkenlerden birisidir. Kaynak planlaması, çevresel değişimin tespit edilmesi ve biyolojik çeşitliliğin korunması gibi konular başta olmak üzere birçok uygulama için güncel ve yüksek doğruluğa sahip bilgiye ihtiyaç vardır. Dünya üzerinde insanların ulaşmasının çok güç olduğu bölgeler de dahil olmak üzere arazi örtüsü hakkında bahsi geçen uygulama alanları için gerekli bilginin düzenli olarak elde edilmesi Uzaktan Algılama (UA) ile sağlanabilmektedir. UA ile elde edilen görüntülerin sınıflandırılmasıyla kısa sürede diğer yöntemlere göre daha düşük maliyetle üretilebilmektedir. Üretilmek istenen arazi örtüsü haritasının detay seviyesi sınıflandırmada kullanılacak görüntünün özelliklerini de belirlemektedir. Haritada orman, şehir, su ve toprak gibi sınıfların belirlenmesi multispektral görüntülerle belirlenebilmektedir. Ancak bu sınıflar tür içi farklı sınıflar gibi giderek detaylanmaya başladığında multispektral görüntüler yerine spektral çözünürlüğü çok daha yüksek olan hiperspektral görüntülerin kullanımı daha uygun olacaktır. Yaklaşık olarak son otuz yıllık süreçte kullanımı giderek artan hiperspektral görüntüler diğer sensörlerden elde edilen görüntülere göre içerdiği dar aralıklı yüzlerce spektral bant sayesinde çok daha yüksek spektral çözünürlük sağlamaktadır. Ancak bu durum bantlar arasında korelasyonun yüksek olması ve görüntünün boyutunun yüksek olmasına sebep olmaktadır. Özellikle kısıtlı eğitim verisi bulunması durumunda bant sayısının fazla olması Hughes fenomenini ortaya çıkararak sınıflandırma doğruluğunun düşmesine neden olarak “çok boyutluluğun laneti” şeklinde de anılan durumu ortaya çıkarmaktadır. Sağladığı yararlar ve aşılması gereken güçlükleri sebebiyle hiperspektral görüntüler üzerine yapılan çalışmalar giderek artmaktadır. Özellikle sınıflandırma problemlerinde geleneksel metotların yetersiz kalması, son zamanlarda kullanımı giderek artan Makine Öğrenme (MÖ) ve özellikle son on yıllık süreçte birçok alanda kullanımı giderek yaygınlaşan ve MÖ’nün alt dallarından birisi olan Derin Öğrenme (DÖ) metotlarının hiperspektral görüntüler üzerindeki kullanımı popüler araştırma konularındandır. UA alanında sıklıkla kullanılan görüntü işleme yöntemlerinden birisi olan görüntü sınıflandırma, mevcut spektral veriler ile spektral sınıfın parçası olan piksellerin etiketlenmesi işlemidir (Richards 2013). Diğer bir deyişle görüntü sınıflandırma görüntüdeki pikselleri istatistiksel karar kuralları veya

mantıksal karar kuralları ile arazi sınıflarına atama işlemidir (Gao 2009). Sınıflandırma süreci iki aşamadan oluşur. İlk aşamada gerçek dünyadaki nesnelerin sınıflarının tanımlanmasıdır. Bu sınıflar çalışmanın coğrafi ölçeğine ve yapısına bağlı olarak belirlenir. Bu sınıflara örnek olarak ormanlık alanlar, su kütleleri, otlaklar ve diğer arazi örtüsü türleri verilebilir. İkinci aşamada, sınıflandırılacak pikseller etiketlenir. Görüntü sınıflandırmasında bu etiketler sayısaldir, dolayısıyla piksellerin sınıfları sayılarla temsil edilmektedir (Mather ve Koch 2011). Böylelikle UA verilerinden bilgi elde edilerek anlamlandırılmış olur.

Piksel tabanlı sınıflandırma yöntemleri kontrolsüz ve kontrollü sınıflandırma olarak iki başlıkta incelenebilir. Kümeleme olarak da bilinen kontrolsüz sınıflandırma, tematik arazi sınıfları hakkında öncül bilgi bulunmaması durumunda görüntüdeki doğal sınıfları ortaya çıkarmaktadır. Sınıflandırma sonucunda ortaya çıkan kümelerin hangi arazi sınıfına ait olduğu hava fotoğrafları ve diğer haritalardan tespit edilebilir. K-Ortalamlar (K-Means) ve ISODATA (Iterative Self Organizing Data Analysis Technique) algoritmaları en bilinen kontrolsüz sınıflandırma algoritmalarındandır. Kontrollü sınıflandırmada görüntüdeki arazi sınıflarını tanımlayan eğitim verileri bulunmaktadır. Kontrollü sınıflandırma algoritmaları parametrik ve parametrik olmayan sınıflandırma algoritmaları olarak ayrılmaktadır. Parametrik algoritmalar eğitim verisinden hesaplanan varyans, kovaryans ve ortalama gibi çeşitli istatistiksel parametreleri kullanmaktadır. Parametrik algoritmalar verilerin normal dağılımda olduğu varsayımını yapmaktadır (Sunar vd. 2011). En Küçük Mesafe, En Çok Benzerlik (EÇB) ve Fisher Doğrusal Diskriminant yöntemleri yaygın parametrik sınıflandırma algoritmalarındandır. Parametrik olmayan algoritmalar verilerin dağılımına dair herhangi bir varsayım yapmamaktadır. En Yakın Komşuluk (EYK), Rastgele Orman (RO), Torbalama (Bagging), Hızlandırma (Boosting), Destek Vektör Makineleri (DVM) ve Yapay Sinir Ağları (YSA) parametrik olmayan algoritmalara örnek verilebilir. Bu algoritmalar Makine Öğrenme (MÖ) metotları olarak da bilinir. MÖ metotları 3.5 numaralı başlık altında daha detaylı şekilde açıklanmıştır.

Kontrollü sınıflandırmada eğitim verisi ilgili sınıflara ait özelliklerin algoritmalar tarafından öğrenilmesini sağlar. Görüntüdeki bantlar, ilgili dalga boyunda nesnelerin özelliklerini temsil ettiğinden dolayı, özelliklerin en iyi şekilde çıkarılması bant sayısına da bağlıdır. Dolayısıyla hiperspektral görüntülerde yer alan çok sayıda bant, sınıfa ait nesneyi spektral imzasına en yakın şekilde temsil edeceğinden dolayı, hiperspektral

görüntülerle yapılan sınıflandırma işlemlerinde sınıflandırma performansının daha yüksek olması, bitki üzerinden örnek verilirse türlerin daha kolay ayrılmasını, hatta aynı türdeki bitkilerin sağlıklı ve sağlıklı olmayanlarının dahi ayırt edilebileceği söylenebilir.

Son yıllarda, teknolojiye gelişmeler sayesinde hiperspektral uzaktan algılama sistemleri dünya yüzeyinin izlenmesinde önemli bir araç haline gelmiştir (Chang 2003, Grahn ve Geladi 2007). Hiperspektral görüntüler elektromanyetik spektrumun görünür, yakın kızılötesi, orta kızılötesi ve termal kızılötesi bölgeleri boyunca genellikle 100'den fazla sayıda, dar aralıkta, bitişik spektral bantlara sahip görüntülerdir. Hiperspektral sensör teknolojisindeki son gelişmeler, sağladığı yüksek spektral, zamansal ve konumsal çözünürlüğe sahip bilgiler yardımıyla yeryüzünün geniş alanlarının çeşitli analizleri için birçok uygulamayı uygulanabilir hale getirmiştir. Fakat hiperspektral verilerin yüksek boyutu, eğitim örneklerinin bulunmaması, görüntünün elde edilmesi sürecindeki ışık saçılım mekanizmaları, farklı atmosferik ve geometrik bozulmalar gibi faktörler bu tür verileri daha karmaşık hale doğrusal olmayan bir hale dönüştürmektedir (Ghamisi vd. 2017). Hiperspektral görüntülerin bahsedilen avantajlarının yanında çözüm aranması gereken dezavantajları da göz önünde tutulduğunda, üzerine daha fazla çalışma yapılması gereken bir alan olduğu açıktır. Literatürdeki çalışmalar da incelendiğinde başta sınıflandırma olmak üzere hiperspektral görüntüler üzerine birçok çalışma yapıldığı görülmektedir (Melgani ve Bruzzone 2004, Camps-Valls ve Bruzzone 2005, Fauvel vd. 2012, Chen vd. 2014, Roy vd. 2019, Hang vd. 2020). Bu çalışmalarda genellikle MÖ ve son yıllarda giderek popülerleşen Derin Öğrenme (DÖ) algoritmaları kıyaslama veri setleri ile eğitilip performansları kendi aralarında ve diğer temel yöntemlerle kıyaslanmıştır.

Bilgisayar teknolojilerinin son yıllarda önemli ölçüde gelişmesi ve buna paralel olarak yeni algoritmaların önerilmesi, yapay zekanın alt dallarından olan MÖ kavramının önemli ölçüde popülerleşmesini sağlamıştır. MÖ algoritmaları temel istatistiksel hesaplamalar ve deneyim yoluyla kendilerini otomatik olarak geliştirmektedir. Klasik programlamada program girdisi veriler ve kurallar iken program çıktısı sonuçlardır. MÖ'de ise veri ve istenen sonuçlar program girdisini oluştururken program çıktısında kurallar elde edilmektedir. Böylece MÖ insanların öğrenme davranışlarını ve karar verme yeteneklerini taklit eder (Jordan ve Mitchell 2015, Nassif vd. 2019). MÖ algoritmaları bilgisayarlı görü, konuşma tanıma, doğal dil işleme, robotik kontrol ve diğer

uygulamalarda karşımıza sıklıkla çıkmaktadır (Jordan ve Mitchell 2015). EYK, RO, Torbalama, Hızlandırma, DVM ve YSA gibi yöntemler geleneksel MÖ algoritmalarındandır. İnsan beyninin öğrenme sürecinden etkilenecek McCulloch ve Pitts (1943) tarafından geliştirilen YSA, ilerleyen yıllarda birden fazla gizli katmana sahip olacak şekilde özelleştirilmiştir ve DÖ kavramı ortaya çıkmıştır. DÖ modellerinin geleneksel MÖ yöntemlerine göre avantajları öznelik seçimi gerektirmemeleri ve veri sayısı arttıkça algoritmanın performansının artmaya devam etmesidir. Temel DÖ çeşitleri Evrişimli Sinir Ağları (ESA), Tekrarlayan Sinir Ağları, Uzun Kısa Süreli Hafıza Ağları, Sınırlı Boltzman Makineleri ve Derin Oto-Kodlayıcılarıdır. Özellikle görüntü tabanlı uygulamalarda sıklıkla kullanılan ESA'ların temeli Fukushima (1980) tarafından atılmıştır. Bir diğer önemli çalışma ise LeCun vd. (1989) tarafından geliştirilen LeNet5 ESA mimarisidir. Buna rağmen ESA 2012'de düzenlenen ImageNet yarışmasına kadar popüler olamamıştır. Bu yarışmada Krizhevsky vd. (2017)'nin oluşturduğu AlexNet modeli yüksek başarı göstermiştir ve bu çalışmadan sonra ESA giderek popülerleşmiştir. Hiperspektral görüntülerin sınıflandırılmasında ESA mimarilerinin kullanılması da son 5 yıldır giderek yaygınlaşmaktadır (Chen vd. 2016, Zhao W ve Du 2016, Mou vd. 2017, Paoletti vd. 2018, Cihan ve Ceylan 2020, Hong vd. 2020). Bahsi geçen çalışmalar ve diğer çalışmalara dair detaylara literatür özetinde değinilmiştir.

Hiperspektral verilerin güncel en büyük dezavantajların birisi de sensörlerin çok kısıtlı şekilde bulunmasıdır. Sistemlerin genellikle hava aracı tabanlı olması ve yüksek maliyet sebebiyle verilere ulaşmak çok pahalı ve zahmetlidir. İnsansız hava araçlarına monte edilen hiperspektral sensörler ise uydu ve hava aracı platformlarındaki hiperspektral görüntüleme sistemleri kadar yüksek spektral çözünürlük sağlayamamaktadır. Bilinen yaygın uydu tabanlı görüntüleme sistemlerinden EO-1 Hyperion ise görev ömrünü Şubat 2017'de tamamladığı için bu sensörden güncel veri sağlanamamaktadır (İnt.Kyn.1). Ancak gelişen teknoloji ve çeşitli uzay ajansları tarafından gönderilmesi planlanan hiperspektral görüntüleme uyduları yüksek potansiyele sahip bu veriler için güzel bir gelecek vaat etmektedir. Güncel durumda verilere ulaşmanın güçlüğü ve yer doğrulama verilerinin hazırlanması zor ve pahalı olduğu için araştırmacılar çeşitli kurumlar ve kişiler tarafından hazırlanmış karşılaştırma verileri üzerinde akademik çalışmalarını sürdürmektedir. En yaygın kullanılanları Indian Pines, Salinas Scene, University of Pavia ve Kennedy Space Center olmak üzere Pavia Centre, Cuprite ve Botswana gibi

karşılaştırma veri setleri mevcuttur (İnt.Kyn.2). Ayrıca diğer komiteler tarafından yayınlanan ancak çok yaygın olarak kullanılmayan HyRANK, Data Fusion Contest 2013 (DFC13) ve Data Fusion Contest 2018 gibi hiperspektral veri setleri de bulunmaktadır. Hiperspektral görüntülerin sınıflandırılması konusu Elektrik ve Elektronik Mühendisliği, Bilgisayar Mühendisliği ve Harita (Geomatik) Mühendisliği disiplinlerinin ortak çalışma konularındandır. Literatürde yukarıda bahsi geçen karşılaştırma veri setleri ile yapılan çalışmalarda dikkat çeken detaylardan birisi de veri setlerinin yer doğrulama verilerinin eğitim ve test veri seti olarak ayrıldığı, ardından algoritma eğitildikten sonra yine yalnızca yer doğrulama piksellerinin sınıflandırıldığı görülmüştür. Daha objektif bir değerlendirme için görüntülerin tamamının sınıflandırılması ve sınıflandırma haritalarının da görsel olarak yorumlanması önemli unsurlardan birisidir.

Bu tez çalışmasının amacı çeşitli eğitim veri kümesi boyutlarında geleneksel MÖ algoritmalarının ve DÖ tabanlı ESA modellerinin hiperspektral görüntülerin sınıflandırılmasında kullanılabilirliğinin incelenmesidir. Bu doğrultuda DVM, RO, 2B ESA ve 3B ESA algoritmalarının hiperspektral görüntülerin sınıflandırılmasında kullanılması amaçlanmıştır. Bunun yanında algoritmaların eğitim veri kümesi boyutlarına göre performanslarının önemli ölçüde değişip değişmeyeceğini test etmek için sırasıyla 30%, 50% ve 70% eğitim veri kümesi boyutu uygulanması amaçlanmıştır. Algoritmaların eğitiminde literatürde sıklıkla kullanımı tekrar eden karşılaştırma veri setleri yerine HyRANK ve DFC13 veri setleri de kullanılacak; bunun yanında yaygın kullanılan veri setlerinden Salinas Scene kullanılacaktır. Böylelikle çeşitli konumsal çözünürlük, spektral çözünürlük ve arazi sınıfları sağlayan görüntülerin tek bir çalışmada incelenmesi sağlanacaktır. Algoritmaların performansları literatürde de sıklıkla kullanılan genel doğruluk, üretici ve kullanıcı doğrulukları ve Kappa katsayısı metriklerine göre değerlendirilecek ve aralarındaki farkların anlamlı olup olmadıkları McNemar's testi ile belirlenecektir. Son olarak ise tüm pikselleri sınıflandırılan hiperspektral görüntülerin sınıflandırma haritaları görsel yorumlama ile incelenecektir.

2. LİTERATÜR BİLGİLERİ

UA'da hiperspektral görüntülerin sağladıkları yüksek spektral çözünürlük sayesinde bu konu üzerinde ortaya koyulan çalışmalar giderek yaygınlaşmaktadır. Yapılan çalışmalarda yaygın konulardan birisi de hiperspektral görüntülerin sınıflandırılmasıdır. Son yıllarda MÖ algoritmalarının sağladığı avantajlar ve gösterdikleri yüksek başarı hiperspektral görüntülerin sınıflandırılmasında bu algoritmaların kullanımının yaygınlaşmasına sebep olmuştur. İnsan beyninin öğrenme, muhakeme ve karar verme yeteneklerini taklit eden MÖ algoritmaları, istatistiksel yöntemlerle sınıflandırma kurallarını kendileri üretmektedir. Ayrıca MÖ algoritmalarında kullanıcı müdahalesi de düşük seviyededir. Kullanıcı tanımlı parametreler gerektiren MÖ algoritmalarında söz konusu parametreler optimum şekilde belirlendiğinde yüksek sınıflandırma doğrulukları elde edilmektedir. Son yıllarda giderek popülerleşen DÖ algoritmalarından olan ESA algoritması ise geleneksel MÖ algoritmalarına göre başarı seviyesini daha da ileriye taşımıştır. Çeşitli disiplinlerden birçok araştırmacı, en iyi sınıflandırma performansını sağlamak amacıyla farklı ESA mimarileri tasarlayarak bu alandaki çalışmalarını sürdürmektedir. Aşağıda kronolojik sıralamaya göre, yöntemler ve kullanılan veri setleri ile birlikte literatürde yer alan bazı çalışmalar açıklanmıştır.

Melgani ve Bruzzone (2004) hiperspektral görüntülerin sınıflandırmasında DVM'nin performansını araştırmıştır. Veri seti olarak Indian Pines veri seti kullanılmış; ilk aşamada DVM Linear Kernel, DVM Radyal Tabanlı Fonksiyon (RTF) Kernel, K-En Yakın Komşuluk (K-EYK) ve RTF YSA yöntemlerini kıyaslamışlardır. İkinci aşamada ise çok sınıflı yaklaşımlar olarak DVM için paralel yaklaşımlardan Teke Tek (TT-DVM) (One against one) ve Teke Karşı Tümü (TKT-DVM) (One against all) stratejileri, İkili Hiyerarşik Ağaç (İHA) yaklaşımlarından ise Dengeli Şubeler (İHA-DŞ) (Balanced branches) ve Teke Karşı Tümü (İHA-TKT) stratejileri karşılaştırılmıştır. Çalışma sonucunda DVM'lerin sınıflandırma doğruluğu, hesaplama süresi ve parametre ayarında kararlılık açısından diğer geleneksel parametrik olmayan K-EYK ve RTF YSA sınıflandırıcılardan çok daha etkilidir (94,38% doğrulukla DVM-RTF). DVM'ler çalışmada uygulandığı gibi, bir öznitelik çıkarma veya seçimi prosedürü ile geleneksel bir sınıflandırıcının kombinasyonuna dayanan geleneksel örüntü tanıma yaklaşımından

daha etkili görünmektedir. Ayrıca DVM'ler Hughes fenomenine karşı düşük hassasiyet göstermektedir. Çok sınıflı yaklaşımlar için yapılan deneyde de 93,96%'lık doğrulukla TKT-DVM en yüksek doğruluğu vermiştir.

Chan ve Paelinckx (2008) HyMap sensörü ile elde edilmiş hiperspektral görüntünün sınıflandırılmasında AdaBoost ve RO algoritmalarının kullanımını incelemişlerdir. Sınıflandırma performansı açısından neredeyse birbirine eşit olan AdaBoost ve RO algoritmalarının YSA'dan daha yüksek başarıya sahip olduğu görülmüştür. RO algoritmasının her bölme için rastgele alt kümeler kullanması ve budama yapmaması sebebiyle eğitim süresi bakımından daha hızlı olduğu, buna karşın AdaBoost'un biraz daha yüksek doğruluk sağladığı sonucuna ulaşmışlardır.

Waske vd. (2009) DVM ve RO algoritmalarının hiperspektral görüntülerin sınıflandırmasında kullanılmasını araştırmışlardır. Çalışmada kullanılan görüntü İzlanda'daki Hekla Volkanı ve çevresini kapsamakta olup AVIRIS sensörü tarafından 17 Haziran 1991 tarihinde elde edilmiştir. Yer doğrulama verisinde 22 arazi sınıfı mevcuttur. Her sınıftan 100, 200 ve 400 eğitim verisiyle algoritmaların eğitimi gerçekleştirilmiş ve sınıflandırma sonuçları EÇB ve SAH algoritmalarının sonuçlarıyla kıyaslanmıştır. Çalışma sonucunda DVM'nin tüm eğitim veri küme boyutlarında diğer algoritmalarından daha yüksek doğruluk verdiğini ve RO'ya göre daha dengeli üretici-kullanıcı doğruluklarına sahip olduğu görülmüştür. Yapılan McNemar's Testi ve Spearman'in Sıralı Korelasyon Katsayılarıyla DVM ile RO'nun sınıflandırma haritaları arasında anlamlı bir farklılık tespit edilmiştir. Çalışma sonucunda, her iki algoritmanın da İzlanda'daki farklı volkanik birimleri hiperspektral veri setleriyle ayırt etmek için kullanışlı olduğu sonucuna varmışlardır.

Mou vd. (2017) hiperspektral görüntülerin sınıflandırılmasında Tekrarlayan Sinir Ağlarının (TSA) kullanılmasını önermişlerdir. Bu modelin hiperspektral görüntüler için kullanılmasında hiperspektral piksellerin sıralı veri olarak kabul edilebileceği şeklinde gerçekleştirdikleri gözlemlerinden esinlenmişlerdir. Ayrıca çalışmada PRetanh aktivasyon fonksiyonunu da önermiştir. University of Pavia, Indian Pines ve DFC13 veri setleriyle gerçekleştirilen deneyde önerdikleri metot DVM-RTF ve Hu vd. (2015)'nin ESA modelinden daha yüksek sınıflandırma performansı göstermiştir.

Luo vd. (2018) HSI-CNN ismini verdikleri bir yeni bir sınıflandırma modeli

önermişlerdir. Modelin ana fikri ağ yapısını derinleştirmek ve ağın özellikleri daha iyi çıkarmasını ve ayırt etmesini sağlamak için evrişim sonuçları arasındaki korelasyonu kullanarak verileri yeniden düzenlemek ve tek boyutlu verileri iki boyutlu veriler gibi görüntüye eklemektir. Önerilen ağın aşırı öğrenme durumunu önermek için sınıflandırma aşamasında karar ağacı tabanlı yeni algoritmalarından olan XGBoost (Extreme Gradient Boosting) algoritmasını HSI-CNN+XGBoost isimli bir model de kurmuşlardır. Indian Pines, Kennedy Space Center, Pavia University ve Salinas Scene karşılaştırma seti ile yapılan sınıflandırmalarda önerilen HSI-CNN mimarisi >99% genel doğruluk ile en iyi sınıflandırma performansını göstermiştir.

Christovam vd. (2019) HyRANK veri seti ile arazi kullanımı ve arazi örtüsü sınıflandırma uygulamasında Spektral Açık Haritalama (SAH), DVM ve RO yöntemlerini kullanmışlardır. SAH ve RO algoritmalarında eğitim için 176 bantlı yüzey reflektans verisini girdi olarak seçmişlerdir. DVM ve ikinci bir RO modeli için ise Temel Bileşenler Analizi (TBA) uygulayıp 14 temel bileşeni kullanmışlardır. Çalışma sonucunda RO-TBA modelinin 92% genel doğruluk ile en yüksek doğruluğa sahip olduğunu, SAH modelinin ise 48% genel doğrulukla en düşük genel doğruluğa sahip olduğunu tespit etmişlerdir. TBA uygulanmayan RO modeli ise 91% doğruluk vermiştir. Buradan da anlaşılacağı üzere TBA modelde 1%'lik bir iyileşme sağlamıştır.

Roy vd. (2019) çalışmasında üç tane 3B evrişim katmanı ve bir tane 2B evrişim katmanına sahip olan; bu melez yapıya atıfta bulunarak HybridSN olarak isimlendirdikleri bir 3B+2B ESA modelini önermişlerdir. 3B evrişim katmanlarında konumsal-spektral öğrenme işlemi gerçekleştiren bu yapı, girdi şeklini değiştirerek son katmandaki 2B evrişim işlemi ile sadece konumsal öğrenme işlemi gerçekleştirmektedir. Indian Pines, University of Pavia ve Salinas Scene karşılaştırma veri setleri ile gerçekleştirilen deneylerde önerilen ESA mimarisiyle sırasıyla 99,75%, 99,98% ve 100% genel doğruluk değerlerine ulaştıkları görülmektedir. Test ettikleri modeller arasında en yüksek doğruluğa sahip olan HybridSN modeli 10% gibi kısıtlı eğitim veri küme boyutunda da yüksek başarı göstermiştir.

Bera ve Shrivastava (2020) hiperspektral verilerin ESA modelleriyle sınıflandırılmasında optimizasyon fonksiyonlarının model doğruluğuna etkisini araştırmışlardır. Çalışmalarında TBA ile verinin boyutunu düşüren ve üç tane 2B evrişim katmanından

oluşan bir ESA mimarisi kullanmışlardır. Kennedy Space Center, Indian Pines, University of Pavia ve Salinas Scene karşılaştırma veri setleri kullanılarak SGD, Adagrad, Adadelat, RMSprop, Adam, Adamax ve Nadam optimizasyon fonksiyonlarını genel doğruluk ve işlem süresine etkisi açısından karşılaştırmışlardır. Çalışma sonucunda Adam optimizasyon fonksiyonunun diğerlerinden daha fazla doğruluk sağladığı ve daha kısa işlem süresi gerektirdiği sonucuna ulaşmışlardır.

Cihan ve Ceylan (2020) hiperspektral verilerin sınıflandırılmasında komşuluk çıkarımı işlemiyle örnek sayısının artırıldığı, 3 tane evrişim katmanından oluşan KÇ3B-ESA mimarisini önermişlerdir. Indian Pines, Salinas Scene ve Pavia University veri setleri ile 20% eğitim verisi ile yaptıkları karşılaştırmada önerilen KÇ3B-ESA, DVM (Melgani ve Bruzzone 2004), 2B-ESA (Makantasis vd. 2015), 3B-ESA (Hamida vd. 2018) ve M3B-ESA (He vd. 2017) modellerine göre daha yüksek performans göstermiştir.

Paoletti, Haut, Tao, vd. (2020) DVM algoritmasıyla hiperspektral görüntülerin sınıflandırılmasında işlem süresini kısaltmak ve bellek gecikmelerini gidermek için yaygın kullanılan DVM algoritmasını grafik işlem birimiyle (GİB) çalışır bir şekilde getirmişlerdir. Indian Pines, University of Pavia ve DFC13 veri setleri kullanılarak yapılan karşılaştırmada eğitim veri kümesi boyutu ve farklı iki GİB ile yapılan deneylerde GİB-DVM klasik DVM ile benzer doğruluk değerlerini daha kısa sürede sağlamaktadır.

Paoletti, Haut, Roy, vd. (2020) geleneksel evrişim kernellerinin dairesel harmonik filtrelerle değiştirilmesi ile oluşturulan yönelim-eşdeğişkenli re2DCNN modelini önermişlerdir. Indian Pines, University of Pavia ve Salinas Scene karşılaştırma veri setleri kullanılarak çok kısıtlı eğitim kümesi (1%-15%) ile gerçekleştirilen deneylerde önerilen model diğer yöntemlerden daha yüksek başarı göstermiştir. Ayrıca yeni yaklaşımın veri yönelimsel varyansına karşı daha iyi bir sağlamlık (robustness) sergilediği ve veri artırma teknikleri gerektirmeden daha iyi bir genelleme sağladığı sonucuna varmışlardır.

İncelenen çalışmalarda görülen eksikliklerden bazıları şunlardır: Bazı çalışmalarda sürekli olarak aynı karşılaştırma veri setleri kullanılmıştır. Dolayısıyla algoritmaların farklı özellikteki veri setleriyle karşılaştırılması konusunda eksiklikler bulunmaktadır. Çalışmaların bir kısmında sınıflandırma haritaları verilmezken bazı çalışmalarda daha önce bahsedildiği gibi yalnızca etiketli verilerin bulunduğu alanların sınıflandırma sonuçları verilip diğer alanlar siyah renk ile sınıflandırılmamış olarak gösterilmiştir. Bu

durumda görüntülerdeki detayların şekilsel olarak doğruluęu hakkında yorum yapılması mümkün olmamaktadır. Diğer bir eksiklik ise modellerin performans kıyaslaması yapılan çalışmalarda genel doğruluk ve üretici-kullanıcı doğrulukları dışında istatistiksel testler uygulanmamıştır. Tez çalışmasında bu eksilikler göz önünde bulundurularak analizler gerçekleştirilmiş ve literatürde bu konudaki açık giderilmiştir.



3. MATERYAL ve METOT

Bu bölümde ilk olarak hiperspektral görüntülerin sınıflandırma aşamalarının gerçekleştirildiği iş istasyonunun donanım ve yazılım özellikleri ile tezde kullanılan veri setlerinden bahsedilmiştir. Ardından hiperspektral görüntülerin ön işleminde boyut indirgeme amacıyla kullanılan TBA, MÖ kavramı, tez kapsamında kullanılan geleneksel MÖ yöntemleri ile DÖ kavramı ve ESA mimarileri açıklanmıştır. Son olarak tez çalışmasında kullanılan ESA mimarileri ve modellerin sınıflandırma performansının belirlenme yöntemleri olan doğruluk analizi açıklanmıştır.

3.1 Donanım ve Yazılım

Tez çalışması kapsamında oluşturulan sınıflandırma modelleri için Asus marka iş istasyonu kullanılmıştır. İş istasyonunun donanım bileşenleri Çizelge 3.1’de verilmiştir.

Çizelge 3.1 Kullanılan iş istasyonunun donanım bileşenleri.

Donanım	Donanım Modeli
İşlemci	Intel® Xeon® E-2136 @3.30 GHz
Grafik İşlemci Birimi	ASUS ROG STRIX GeForce RTX-2070 SUPER 8GB
Bellek	64 GB DDR-4
Depolama	TOSHIBA RC500 NVME SSD 500 GB

İş istasyonunda Windows 10 Pro for Workstations Version 1909 işletim sistemi yüklüdür. Modellerin geliştirilmesinde Python 3.7.9 programlama dili kullanılmıştır. Kodlar Anaconda Navigator’ın geliştirdiği Spyder 4.1.5 ortamında geliştirilmiştir. ESA modellerinin oluşturulmasında Keras kütüphanesinin 2.3.1 sürümü kullanılmıştır. Keras’ın arka planında hesaplamaların gerçekleştirilmesi için Tensorflow ve Tensorflow-GPU kütüphanelerinin 2.1.0 sürümleri kullanılmıştır. Tensorflow kütüphanesi Nvidia ekran kartlarının sağladığı CUDA (Compute Unified Device Architecture) Toolkit 10.2 hizmetini de desteklemektedir. Böylece iş istasyonunun grafik işlem birimi de ESA’ların

eğitiminde rol oynamakta olup eğitim sürecini hızlandırmaktadır. TBA dönüşümü, SVM ve RO modellerinin kurulmasında Scikit-Learn 0.23.2 kullanılmıştır. Bu kütüphanelere ek olarak ise çeşitli işlem adımlarında Numpy, Pandas, Time, TiffFile, Plotly, Matplotlib gibi diğer yardımcı kütüphaneler de kullanılmıştır.

3.2 Hiperspektral Görüntü

UA, yeryüzü ve yeryüzündeki kaynaklara temas etmeden söz konusu nesnelere incelenmesini sağlayan sistemlerdir. UA'da algılayıcı sistemleri aktif ve pasif algılayıcılar olarak incelenebilir. Aktif algılayıcılar kendi üzerinde bulunan yapay enerji kaynaklarından ürettiği elektromanyetik dalga sinyallerini hedefe yönlendirip hedeften saçılan enerjiyi algılayan sistemlerdir. RADAR (Radio Detection and Ranging) ve LiDAR (Light Detection and Ranging) sistemleri aktif algılayıcılara örnek gösterilebilir. Pasif algılayıcılar ise güneş veya diğer kaynakların yeryüzüne gönderdiği ışınlar aracılığıyla yeryüzünden yansıyan veya yayılan enerjiyi algılayan optik, ısı ve mikrodalga algılayıcı sistemlerdir. Pasif algılayıcı sistemlerde cisimlerden yansıyan veya yayılan enerji genellikle elektromanyetik spektrumda ilgili kısımlara karşılık gelen birçok banda kaydedilmektedir. Görüntüdeki bant sayısına göre görüntüler multispektral ve hiperspektral olarak tanımlanabilir. Multispektral görüntüler genellikle üçten fazla banda sahip olan görüntülerdir. Hiperspektral görüntüler ise çok daha fazla sayıda (genellikle 100'den fazla) dar spektral aralıkta alınmış bantlara sahiptir.

Hiperspektral sensörler elektromanyetik spektrumun görünür, yakın kızılötesi, orta kızılötesi ve termal kızılötesi bölgeleri boyunca çok sayıda, dar aralıkta, bitişik spektral bantlarda görüntü alan cihazlardır. Bu sistemler genellikle 100'den fazla bantta veri toplayıp görüntüdeki her bir piksel için yansıtım (termal kızılötesi bölgede yayım) spektrumunun oluşmasını sağlamaktadır (Grahn ve Geladi 2007, Lillesand vd. 2015). Hiperspektral sınıflandırma yöntemlerinin gıda, medikal, tarım, askeri ve savunma, madencilik gibi değişik alanlarında uygulamaları bulunmaktadır (Demir 2010).

UA sistemleri yeryüzündeki kentleşme, kıyı kesimlerindeki değişimler, erozyon, orman yaygınları ve iklim değişikliği gibi olayların gözlenmesi ve yaşanan olumsuzluklar karşısında tedbirler alınması konusunda birçok analiz yapılmasına imkân sağlamaktadır.

Elektromanyetik spektrumda çok geniş bir aralıkta yüksek çözünürlükte veri kaydedebilen hiperspektral sistemler ile elde edilen verilerin sınıflandırılması veya sınıfların belirlenmesi, bahsi geçen problemlerin çözümünde yüksek başarı sağlamaktadır (Landgrebe 2005). Çizelge 3.2’te başlıca hava aracı ve uydu platformundaki hiperspektral sensörler verilmiştir (Dalponte vd. 2009, İnt.Kyn.3) .

Çizelge 3.2 Başlıca hiperspektral sensörler ve özellikleri.

Sensör Adı	Üretici	Platform	Max Bant Sayısı	Max Spektral Çözünürlük (nm)	Spektral Aralık (µm)
Hyperion	NASA Goddard Space F. C.	Uydu	220	10	0.4-2.5
MODIS	NASA	Uydu	36	40	0.4-14.3
CHRIS Proba	ESA	Uydu	63'e kadar	1.25	0.415-1.05
PRISMA	OHB Italia	Uydu	~250	12	0.4-2.5
HySIS	ISRO	Uydu	60+256	10	0.4-2.4
AVIRIS	NASA Jet Propulsion Lab	Hava Aracı	224	10	0.4-2.5
HYDICE	Naval Research Lab	Hava Aracı	210	7.6	0.4-2.5
PROBE-1	Earth Search Sciences Inc.	Hava Aracı	128	12	0.4-2.45
CASI 550	ITRES Research Limited	Hava Aracı	288	1.9	0.4-1
CASI 1500	ITRES Research Limited	Hava Aracı	288	2.5	0.4-1.05
SASI 600	ITRES Research Limited	Hava Aracı	100	15	0.95-2.45
TASI 600	ITRES Research Limited	Hava Aracı	64	250	8-11.5
HyMap	Integrated Spectronics	Hava Aracı	125	17	0.4-2.5
ROSIS	DLR	Hava Aracı	84	7.6	0.43-0.85
EPS-H	GER Corporation	Hava Aracı	133	0.67	0.43-12.5
EPS-A	GER Corporation	Hava Aracı	31	23	0.43-12.5
DAIS 7915	GER Corporation	Hava Aracı	79	15	0.43-12.3
AISA Eagle	Spectral Imaging	Hava Aracı	244	2.3	0.4-0.97
AISA Eaglet	Spectral Imaging	Hava Aracı	200	-	0.4-1
AISA Hawk	Spectral Imaging	Hava Aracı	320	8.5	0.97-2.45
AISA Dual	Spectral Imaging	Hava Aracı	500	2.9	0.4-2.5
MIVIS	Daedolus	Hava Aracı	102	20	0.43-12.7
AVNIR	OKSI	Hava Aracı	60	10	0.43-1.03

3.3 Veri Setleri

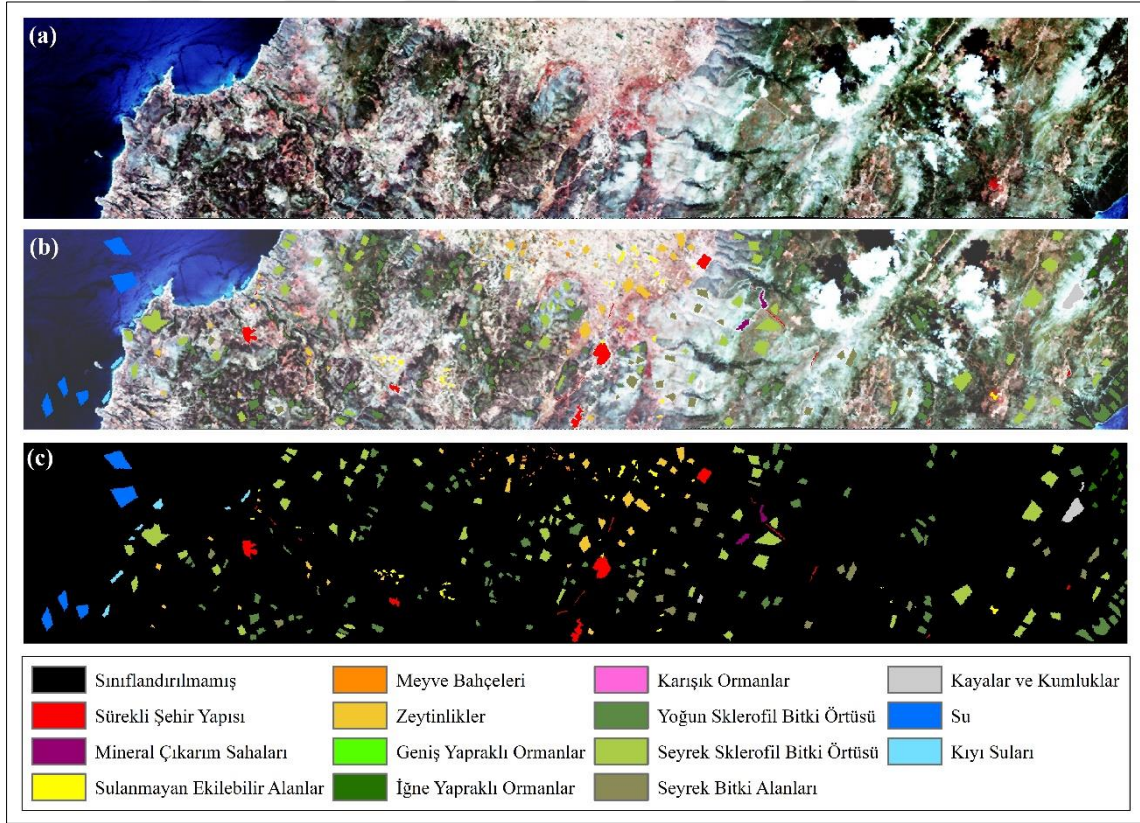
Bu çalışmada uydu ve hava platformlarından farklı sensörler aracılığıyla elde edilmiş 5 farklı hiperspektral veri seti kullanılmıştır. Kullanılan veri setleri farklı konumsal, spektral ve radyometrik çözünürlüklere sahiptir. Dolayısıyla bu veri setlerinin sınıflandırılmasında görüntülerin elde edilmesinden kaynaklanan bu farklılıkların da sınıflandırma performansına etkilerinin incelenmesi amaçlanmıştır. Bölümün alt başlıklarında veri setlerinin özelliklerine dair bilgiler verilmiştir.

3.3.1 HyRANK Veri Seti

HyRANK Benchmark veri seti ISPRS'in (International Society for Photogrammetry and Remote Sensing) Komisyon III Çalışma Grubu III/4 tarafından yeni sınıflandırma algoritmalarının bilinen en iyi sınıflandırma algoritmalarıyla kıyaslanması ve kısıtlı sayıda olan hiperspektral veri setlerine alternatif veri seti kazandırılması amacıyla oluşturulmuş bir karşılaştırma veri setidir (Karantzas vd. 2018). Veriler 2006 yılının mayıs ayı sonu ile temmuz ayı başı arasında NASA'nın (National Aeronautics and Space Administration) EO-1 (Earth Observing-1) uydu platformu üzerinde yer alan Hyperion sensöründen elde edilmiştir. EO-1 Hyperion platformu görünür yakın kızılötesi dalga boyları aralığı ile kısa dalga kızılötesi (357-2576 nanometre) spektral bölgelerinde görüntü alabilen ilk uydu sistemidir. Hyperion görüntüleri 10 nanometre spektral aralıkla alınmış ve 30 metre konumsal çözünürlüğe sahip 220 banttan oluşmaktadır (İnt.Kyn.4). HyRANK veri setindeki verilerde görüntülerin ön işleme işlemleri gerçekleştirilmiş olup su buharı emme bantları ve diğer bozuk bantlar temizlenerek bant sayısı 176'ya düşürülmüştür. HyRANK veri seti Dioni, Loukia, Erato, Kirki ve Nefeli olarak isimlendirilmiş 5 görüntüyü içermektedir. Bu veri setlerinden Dioni ve Loukia, algoritmaların eğitimi için yer doğrulama verisine sahiptir. Diğer görüntüler ise doğrulama için ayrılmıştır. Yer doğrulama verileri CORINE (Coordination of Information on the Environment) 2006 arazi kullanımı / arazi örtüsü haritası, Google Earth ve diğer yüksek çözünürlüklü uydu görüntüleri üzerinden hassasça seçilmiş 14 arazi kullanımı / arazi örtüsü sınıfına sahiptir (Karantzas vd. 2018).

3.3.1.1 Dioni Veri Seti

Dioni veri seti HyRANK veri seti içerisinde yer doğrulama verisine sahip iki görüntüden birisidir. Görüntü $250 \times 1376 \times 176$ boyutundadır. Görüntü Loukia görüntüsü ile aynı sınıflara göre tanımlanmasına rağmen Geniş Yapraklı Ormanlar (Sınıf No: 6) ve Karışık Ormanlar (Sınıf No: 8) sınıfları yer doğrulama verisinde mevcut değildir. Dolayısıyla görüntü 12 farklı sınıfa sahiptir. Veri setinin (Kırmızı: 23, Yeşil: 11, Mavi: 07) bant kombinasyonuna göre renklendirilmiş şekli, renklendirilmiş hali üzerinde yer doğrulama verisinin görünümü ve yalnızca yer doğrulama verisinin gösterildiği hali Şekil 3.1’de gösterilmiştir.

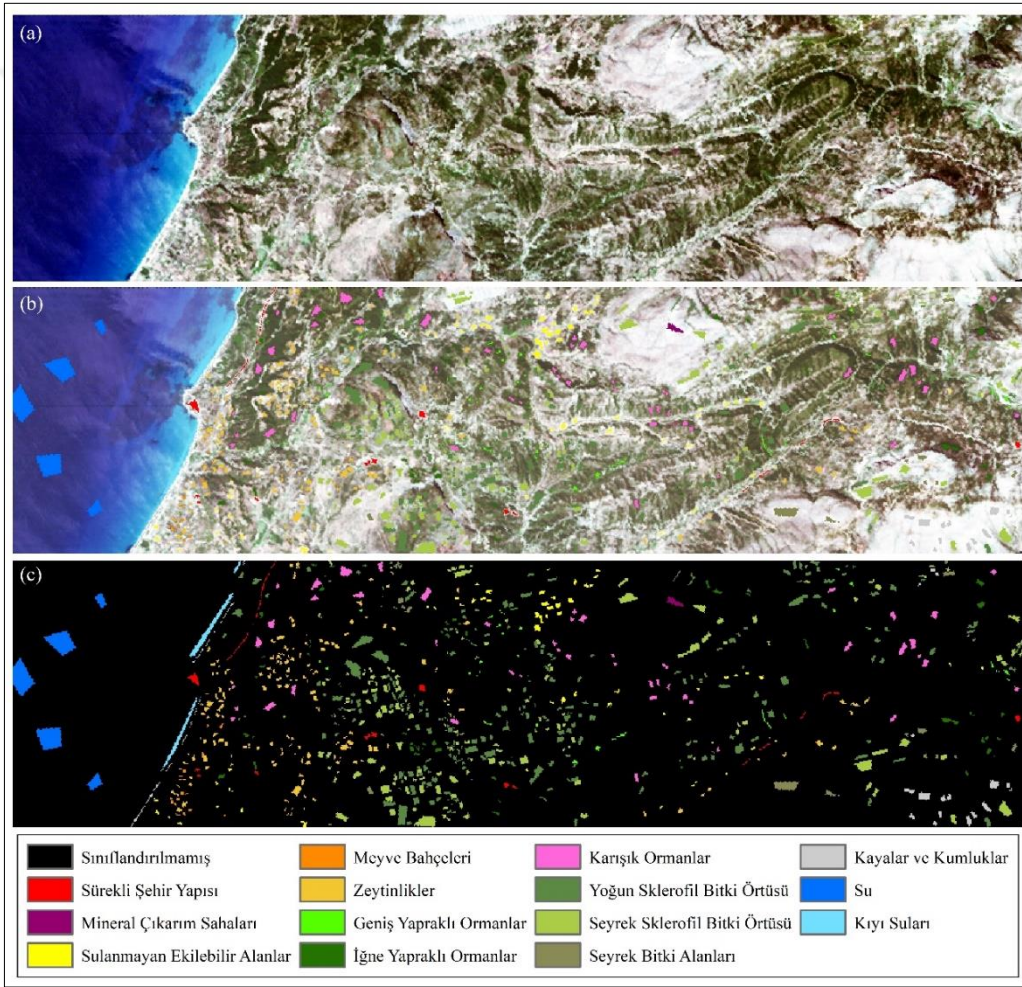


Şekil 3.1 Dioni veri setinin (a) Gerçek Renk, (b) Gerçek Renk + yer doğrulama ve (c) yer doğrulama görüntüleri.

Görüntünün sağ kısmında görülen bulutlar ve bulut gölgeleri görüntünün orijinal halinde maskeleme gibi herhangi bir ön işlemeye tabii tutulmadığı için doğrudan kullanılmıştır.

3.3.1.2 Loukia Veri Seti

Loukia veri seti HyRANK veri setinde yer alan ve yer doğrulama verisine sahip olan diğer veri setidir. Görüntü 249×945×176 boyutundadır. Veri setinin (Kırmızı: 23, Yeşil: 11, Mavi: 07) bant kombinasyonuna göre renklendirilmiş şekli, renklendirilmiş hali üzerinde yer doğrulama verisinin görünümü ve yalnızca yer doğrulama verisinin gösterildiği hali Şekil 3.2’de gösterilmiştir (Karantzos vd. 2018).

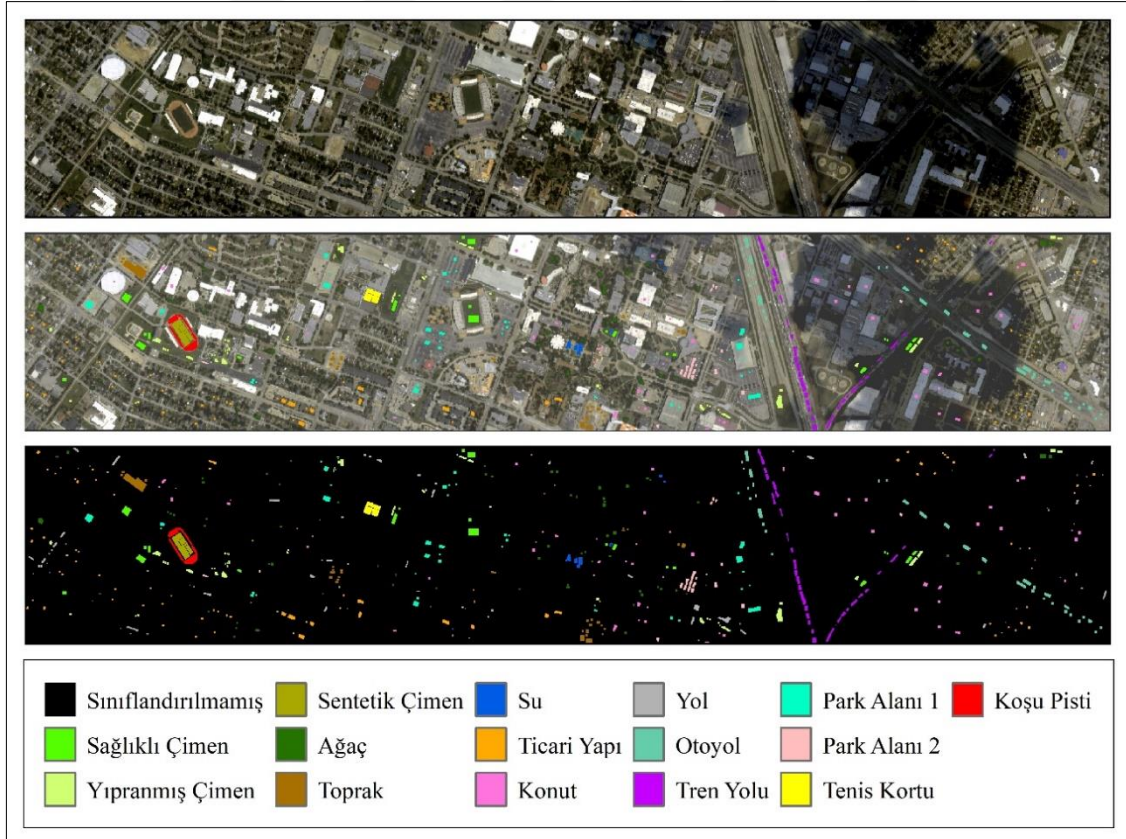


Şekil 3.2 Loukia veri setinin (a) Gerçek Renk, (b) Gerçek Renk + yer doğrulama ve (c) yer doğrulama görüntüleri.

Şekil incelendiğinde sınıfları tanımlayan yer doğrulama verilerinin seçimlerinin görüntü üzerinde olabildiğince homojen dağılımda yapıldığı açıkça görülmektedir.

3.3.2 DFC13 Veri Seti

DFC13 (Data Fusion Contest 2013) veri seti 23 Haziran 2012 tarihinde 17:37:10 ile 17:39:50 saatleri arasında elde edilmiş hiperspektral görüntüdür. Görüntü Houston Üniversitesi Kampüsü ve çevresindeki şehir alanını kapsamaktadır. NCALM (National for Airborne Laser Mapping) tarafından elde edilen görüntü 2,5 metre konumsal çözünürlüğe sahiptir ve 5500 feet (1676,4 metre) yükseklikten çekilmiştir (İnt.Kyn.5). Görüntü 380 ile 1050 nanometre arasında 144 spektral banda sahiptir. Görüntü 349×1905×144 boyutundadır. Veri seti hiperspektral görüntü, eğitim verisi ve doğrulama verisi içermektedir. Tez çalışmasında söz konusu iki doğrulama birleştirilerek kullanılmıştır. Veri setinin (Kırmızı: 62, Yeşil: 42, Mavi: 20) bant kombinasyonuna göre renklendirilmiş şekli, renklendirilmiş hali üzerinde yer doğrulama verisinin görünümü ve yalnızca yer doğrulama verisinin gösterildiği hali Şekil 3.3'te gösterilmiştir.

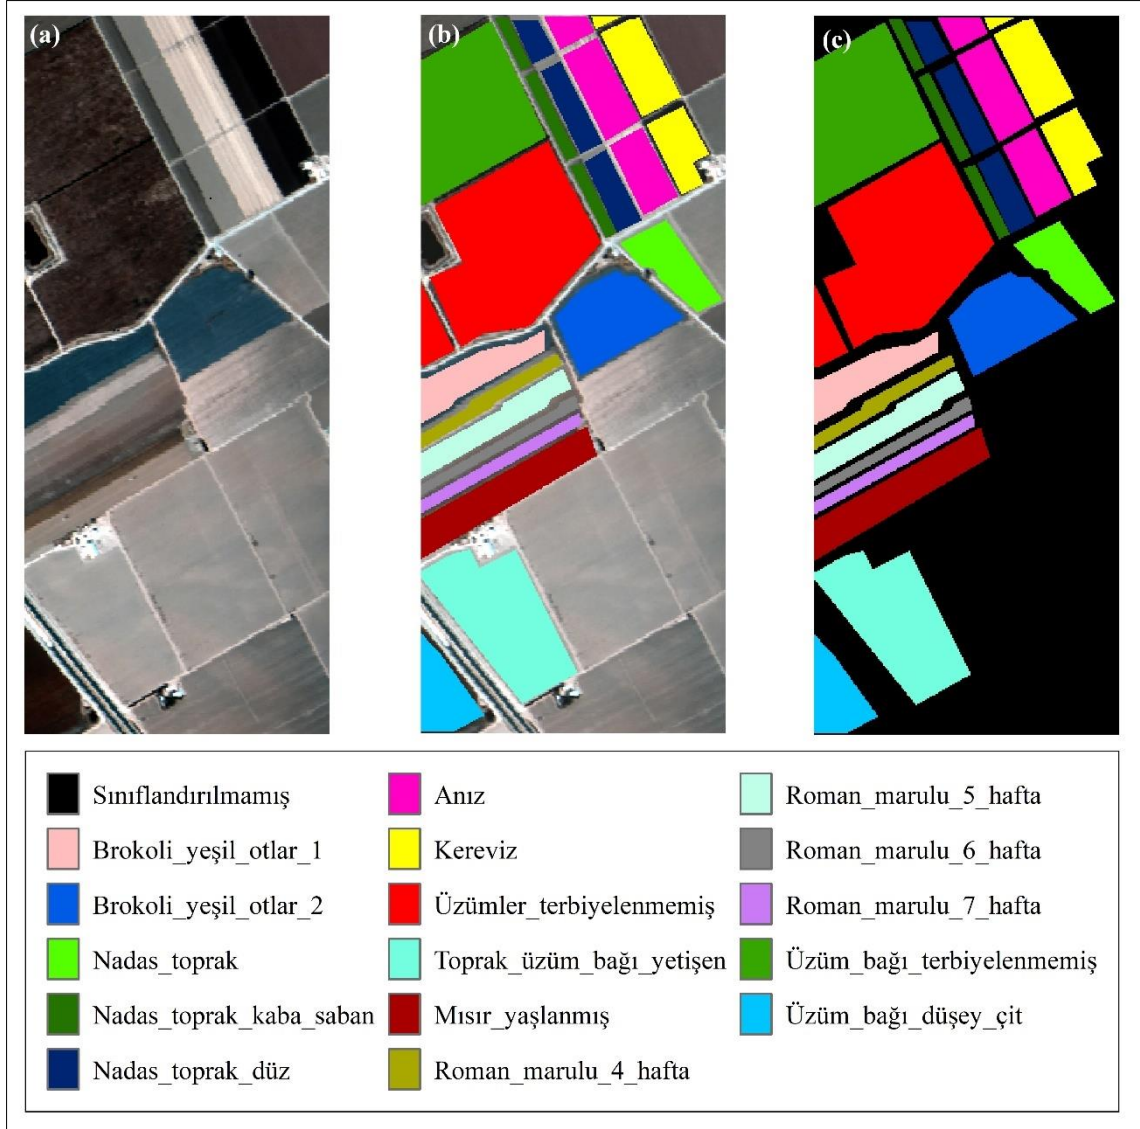


Şekil 3.3 DFC13 veri setinin (a) Gerçek Renk, (b) Gerçek Renk + yer doğrulama ve (c) yer doğrulama görüntüleri.

Şekil 3.3'te yer alan lejantta da görülebileceği üzere DFC13 veri seti 15 sınıfa sahiptir. Sınıfların tespiti ve görüntü üzerinde işaretlenmesi, IEEE GRSS (Institute of Electrical and Electronics Engineers Geoscience and Remote Sensing Society) topluluğu tarafından Görüntü Analizi ve Veri Füzyonu Teknik Komitesi tarafından düzenlenen 2013 Veri Füzyonu Yarışması (IEEE GRSS Data Fusion Contest) için gerçekleştirilmiştir (Debes vd. 2014). Sınıflar 2,5 metre konumsal çözünürlüğe sahip bir görüntü için ayırt edilebilir şekildedir.

3.3.3 Salinas Scene Veri Seti

Hiperspektral görüntüler üzerine yapılan çalışmalarda literatürde sıklıkla karşılaşılan Salinas veri seti Amerika Birleşik Devletleri'nin Kaliforniya eyaletindeki Salinas Vadisinde AVIRIS (Airborne Visible/Infrared Imaging Spectrometer) hiperspektral algılayıcısıyla 9 Ekim 1998 tarihinde elde edilmiştir. Görüntünün konumsal çözünürlüğü 3,7 metre; spektral çözünürlüğü ise 224 banttır. Görüntünün su buharı emme bantları olan (108–112, 154–167 ve 224) aralığındaki 20 bantı silinerek 204 banda indirilmiştir. Bu işlemlerin ardından ortaya çıkan görüntü 512×217×204 boyutundadır. Veri setinin (Kırmızı: 50, Yeşil: 20, Mavi: 10) bant kombinasyonuna göre renklendirilmiş şekli, renklendirilmiş hali üzerinde yer doğrulama verisinin görünümü ve yalnızca yer doğrulama verisinin gösterildiği hali Şekil 3.4'te gösterilmiştir.



Şekil 3.4 Salinas Scene veri setinin (a) Gerçek Renk, (b) Gerçek Renk + yer doğrulama ve (c) yer doğrulama görüntüleri.

Salinas Scene veri setinin yer doğrulama verisi temelde sebzeler, yer ve toprak, üzüm bağları olmak üzere 3 ana sınıf altında incelenebilir (Gualtieri vd. 1999). Veri setinin yer doğrulama verisi toplamda 16 sınıftan oluşmaktadır. Sınıfların belirlenmesi görüntünün çekim tarihinde ilgili parsellerde yapılan yersel gözlemler ile sağlanmıştır.

3.4 Temel Bileşenler Analizi

Hiperspektral algılayıcılar çok büyük miktarda veri sunmalarına rağmen daha düşük spektral çözünürlüklü görüntülerden farklı birtakım dezavantajlara sahiptir. Hiperspektral görüntüler dar spektral aralıklarla yüzlerce bant içerdiği için spektral bilgilerin tekrar edilmesinden dolayı birbirleri arasındaki korelasyon yüksektir (Li W vd. 2011). Verinin istatistiksel olarak daha anlamlı hale getirilebilmesi, veri setinin daha az depolama alanı gerektirmesi ve işlem süresinin kısaltılması için boyut indirgeme yöntemleri kullanılmalıdır. Boyut indirgeme, sınıflandırma uygulamalarında sınıflandırma performansını potansiyel olarak bozabilecek gereksiz özellikleri atarak hesaplama karmaşıklığını azaltmayı ve istatistiksel kötü koşullandırmayı iyileştirmeyi amaçlamaktadır (Lee ve Landgrebe 1993). Boyut indirgeme yöntemleri eğitilmiş, yarı eğitilmiş ve eğitimsiz algoritmalar olarak üç ana başlıkta incelenmektedir (Ghamisi vd. 2017). Lineer Diskriminant Analizi, Nonparametrik Ağırlıklı Öznitelik Çıkartma, Jeffries–Matsushita mesafesini kullanan bant seçimi ve karşılıklı bilgiyi kullanan bant seçimi yöntemleri sıklıkla kullanılan eğitilmiş boyut indirgeme yöntemleridir. Bu yöntemler sınıfların ayrılabilirliğinin artırılması için etiketli verileri kullanmaktadır. Uygulamada etiketli verilerin elde edilmesi zordur ve bu veriler oldukça kısıtlıdır. Diğer taraftan etiketlenmemiş veriler çok düşük maliyetle büyük miktarlarda mevcuttur. Bu sebeple hem etiketlenmemiş hem de sınırlı etiketli verileri kullanarak sınıflandırmayı iyileştirmeyi amaçlayan yarı eğitilmiş yöntemler geliştirilmeye başlanmıştır. Bu yöntemlerden bazıları birlikte eğitim, dönüştürücü DVM ve grafik tabanlı yarı eğitilmiş öğrenme yöntemleridir. Etiketli verinin mümkün olmadığı durumlarda eğitimsiz boyut indirgeme yöntemleri ile bazı kriterler sağlanarak daha az sayıda bant kümesinin elde edilmesi amaçlanmaktadır. Eğitimsiz boyut indirgeme algoritmalarına ise TBA, Bağımsız Bileşen Analizi ve En Az Gürültü Giderme Dönüşümü yöntemleri örnek gösterilebilir. Bu tez çalışmasında ise literatürde yaygın olarak kullanılan ve en bilinen yöntemlerden olan TBA yöntemi ile hiperspektral görüntülerin bant sayılarının azaltılması amaçlanmıştır.

TBA, Pearson (1901) tarafından tanıtılmış ve Hotelling (1933) tarafından geliştirilmiş bir yöntemdir. TBA verileri varyanslarının en yüksek oldukları değerlere göre birbirleri ile

kolerasyonsuz daha az boyuttaki doğrusal bir alt uzaya yerleştiren doğrusal bir boyut indirgeme yöntemidir (Hotelling 1933). TBA temelde bantların kovaryans matrisinin özdeğer ayrışmasına dayanır. TBA'nın hesaplanmasında ilk olarak 3B hiperspektral görüntü (X) denklem (3.1)'de gösterildiği şekilde 2B matrise (X_m) dönüştürülür:

$$X \in R^{M \times N \times D} \rightarrow X_m \in R^{D \times W} \quad (3.1)$$

Burada W , X 'teki toplam piksel sayısını ($M \times N = W$) ifade etmektedir. Bu işlemin ardından bir piksel vektörü eşitlik (3.2) şeklinde yazılabilir:

$$p_i = [p_1, p_2, \dots, p_D]^T, \quad i = 1, 2, \dots, W \quad (3.2)$$

Piksel vektörlerinin boyutları D 'ye eşittir. Tüm piksellerin ortalaması m hesaplanır (3.3) ve ardından ortalama merkezli veri matrisi U eşitlik (3.4)'e göre hesaplanır:

$$m = \frac{1}{W} \sum_{i=1}^W p_i \quad (3.3)$$

$$U = [p_1 - m \quad p_2 - m \quad \dots \quad p_i - m] \in R^{D \times W} \quad (3.4)$$

Ortalama merkezleme, ortalaması sıfıra eşit bir veri matrisi oluşturmak için kovaryans matrisinin hesaplanmasından önce yapılması gerekli olan bir işlemdir. Bantların arasındaki korelasyonların analizi için kovaryans matrisi Cov hesaplanır (3.5):

$$Cov = UU^T \quad (3.5)$$

Boyutu ($D \times D$) olan kovaryans matrisinde köşegen elemanları her bir bandın varyansını;

köşegen dışındaki elemanlar ise bantlar arasındaki kovaryansı ifade etmektedir. Kovaryans matrisinin bulunmasının ardından özdeğer ayrışımı bulunur ve eşitlik (3.6) şeklini alır.

$$Cov = VDV^T \quad (3.6)$$

Burada V kovaryans matrisinin özvektörlerini, D ise kovaryans matrisinin köşegeni olan özdeğerleri ifade etmektedir. Bir sonraki adımda özdeğerler ve özvektörleri azalan bir sırada sıralanır. Daha sonra, ilk K ($K \leq D$) tane özvektör farklı boyuttaki bir uzayda ifade edilen dönüştürülmüş yaklaşık görüntüyü hesaplamak için kullanılabilir. Özvektörler azalan şekilde sıralandığından ilk özvektörler yüksek varyansa sahiptir ve görüntüye dair bilginin büyük bir kısmını içermektedir. Dönüştürülmüş yaklaşık görüntüdeki pikseller eşitlik (3.7)'deki şekilde gösterilebilir:

$$z_i = [z_1, z_2, \dots, z_D]^T = V^T p_i, \quad i = 1, 2, \dots, W \quad (3.7)$$

Yalnızca ilk K temel bileşenini seçmek için (3.8) eşitliği hesaplanmalıdır:

$$z_i = \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_K \end{bmatrix}_i = \begin{bmatrix} V_{11} & V_{12} & \dots & V_{1K} & \dots & V_{1B} \\ V_{21} & V_{22} & \dots & V_{2K} & \dots & V_{2B} \\ \vdots & \vdots & \dots & \vdots & \dots & \vdots \\ V_{K1} & V_{K2} & \dots & V_{KK} & \dots & V_{KB} \end{bmatrix} \begin{bmatrix} p_1 \\ p_2 \\ \vdots \\ p_K \\ \vdots \\ p_B \end{bmatrix} \quad (3.8)$$


Bu adım görüntüdeki tüm pikseller için uygulanır. Ardından yeni görüntü yalnızca ilk K temel bileşenler seçilerek oluşturulur. Son olarak elde edilen dönüştürülmüş görüntü X_k eşitlik (3.9)'daki üç boyutlu görüntü (X_{yeni}) şekline dönüştürülür ve TBA ile boyut

indirgeme işlemi tamamlanmış olur.

$$X_k \in R^{K \times W} \rightarrow X_{yeni} \in R^{M \times N \times K} \quad (3.9)$$

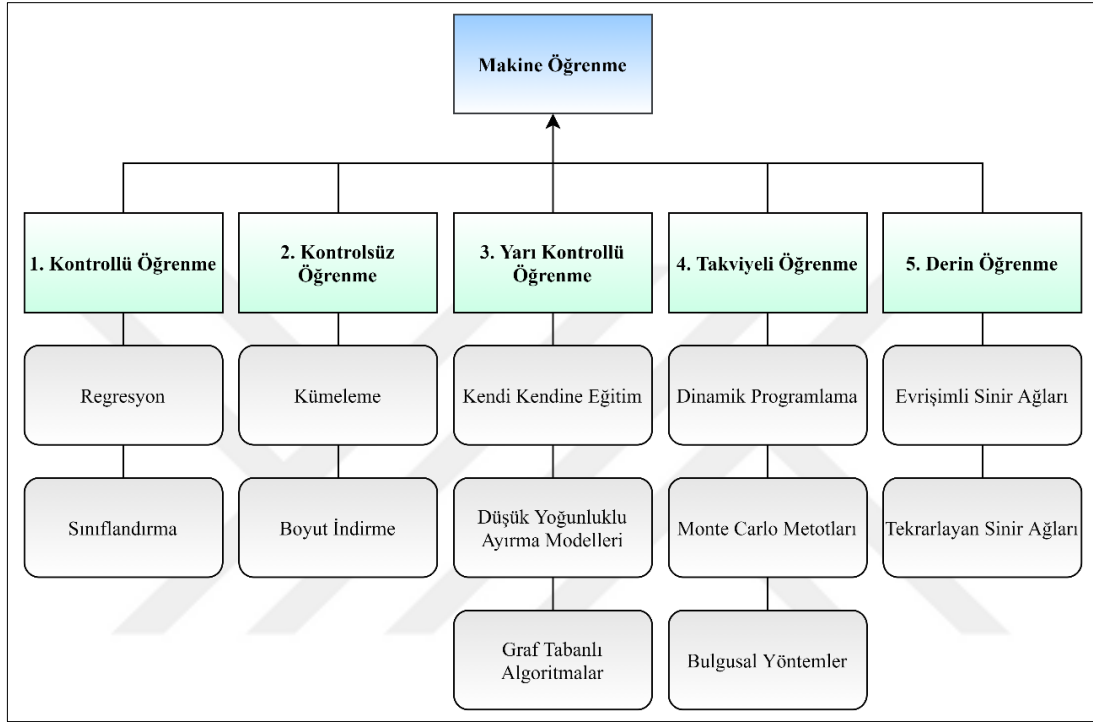
3.5 Makine Öğrenme Algoritmaları

MÖ yapay zekanın alt dallarından birisidir. Temelde MÖ iki tane birbiriyle ilişkili soruya odaklanmaktadır; Deneyim yoluyla otomatik olarak gelişen bilgisayar sistemleri nasıl inşa edilebilir? Bilgisayarlar, insanlar ve organizasyonlar dahil tüm öğrenme sistemlerini yöneten temel istatistiksel hesaplama-bilgi-kuramsal yasalar nelerdir? MÖ hem bu temel bilimsel ve mühendislik sorularını ele almak için hem de ürettiği ve birçok uygulamada yer aldığı son derece pratik bilgisayar yazılımı için önemlidir (Jordan ve Mitchell 2015). Veri madenciliği ve istatistiksel analize dayalı teknikleri kullanan MÖ, bilgisayarların insan öğrenme davranışını, muhakemeyi ve karar vermeyi taklit etmesini sağlar (Nassif vd. 2019). Yaklaşık son otuz yılda popüler olan MÖ algoritmaları kurallarla programlanmaktan ziyade birçok örnekten istatistiksel yapıyla kuralları ortaya çıkarmayı amaçlamaktadır (Şekil 3.5). MÖ algoritmaları bilgisayarlı görü, konuşma tanıma, robotik, doğal dil işleme, web arama, fiyat tahmini, reklam yerleştirme, dolandırıcılık tahmini, taşınmaz değerlendirme gibi alanlarda çözüm sunmaktadır (Alpaydın 2004, Jordan ve Mitchell 2015, Nassif vd. 2019, Seyrek vd. 2019).



Şekil 3.5 Klasik programlama ile MÖ'nün farkı.

Şekil 3.6'dan da görüleceği MÖ algoritmaları kontrollü öğrenme (supervised learning), kontrolsüz öğrenme (unsupervised learning), yarı kontrollü öğrenme (semi-supervised learning), takviyeli öğrenme (reinforcement learning) ve derin öğrenme (deep learning) 5 başlık altında incelenebilir (Nassif vd. 2019).




Şekil 3.6 MÖ türleri (Nassif vd. 2019).

Kontrollü öğrenmede MÖ algoritmasının eğitimi için etiketli veriler kullanılmaktadır. Veriler bir vektörle temsil edilebilen bir girdi ve istenen bir çıktıdan oluştuğu için etiketlenmiş veri olarak adlandırılmaktadır. Kontrollü öğrenmede eğitim kümesinin analizi sonucu çıktı ayrık (discrete) veri ise oluşturulan fonksiyon sınıflandırma; sürekli (continuous) veri ise regresyon olarak adlandırılmaktadır. Kontrollü MÖ algoritmalarının UA görüntülerinin sınıflandırılmasında kullanımı açısından düşünüldüğünde girdi n tane banttan oluşan bir piksel için öznitelik vektörü ($n \times I$) boyutundadır. Çıktıyı oluşturan etiket ise ($I \times I$) boyutunda bir değerdir. Yer sınıfı bilindiği için ve kontrollü MÖ algoritması özniteliklere göre yinelemeli olarak bu yer sınıfını tahmin etmeye çalıştığı için, MÖ modeli tahmin edilen ile gerçek sınıf arasındaki varyasyon boşluğunu azaltmak amacıyla düzeltilir. Bu öğrenme mekanizması kontrollü öğrenme olarak

tanımlanmaktadır. Kontrollü öğrenme işleminde çok sayıda etiketli veri kullanılmaktadır. Tez çalışması kapsamında kontrollü öğrenme algoritmalarından DVM, toplu öğrenme algoritmalarından RO ve DÖ algoritmalarından ESA kullanılmıştır. İlerleyen başlıklarda bahsi geçen algoritmalarından detaylı olarak bahsedilmiştir.

3.5.1 Destek Vektör Makineleri Algoritması

DVM, temelde iki sınıfı birbirinden optimum olarak ayırabilen hiper düzlemi belirleme prensibiyle çalışan, verinin dağılımına ilişkin herhangi bir varsayım yapmayan bir algoritmadır. DVM parametrik olmayan bir algoritmadır ve istatistiksel öğrenme teorisine dayanmaktadır (Vapnik 1995). DVM algoritmasının temel mantığı Şekil 3.7’de gösterildiği gibi iki sınıflı doğrusal verinin sınıflandırılmasının çözümüdür.



Şekil 3.7 İki sınıfı en optimum şekilde ayıran hiperdüzlem (İnt.Kyn.6).

Şekilde gösterilen mavi noktaların A sınıfını; yeşil noktaların da B sınıfını temsil ettiği varsayalım. Bu iki sınıf bir düzlem ile ayrılmak istendiğinde çeşitli konumlarda ve dönüklüklerde düzlemler tanımlanması mümkündür. Ancak sınıflar arasındaki uzaklığı maksimum yapan; yani şekilde kesikli siyah çizgiler ile gösterilen durumu sağlayabilen

yalnızca bir sınır pozisyonu bulunur. DVM algoritması, A ve B sınıfına eşit uzaklığa sahip olan, maksimum marjlinli ve sınıflandırma hatasını minimuma indirecek hiper düzlemi (şekilde kırmızı ile gösterilen düzlem) seçmeyi amaçlar. Bahsi geçen en geniş sınır pozisyonunu sağlayan; yani şekildeki kesikli siyah çizgilerle temsil edilen sınırları tanımlayan sınıf elemanları ise destek vektörleri olarak adlandırılmaktadır.

Bir DVM sınıflandırma problemi tanımlanırken eğitim veri setinin sınıflarının $\{+1, -1\}$ şeklinde olduğu varsayılırsa aşağıdaki (3.10), (3.11) ve (3.12) eşitlikleriyle tanımlanabilir:

$$H_0 : w \cdot x_i + b = 0 \quad (3.10)$$

$$H_1 : w \cdot x_i + b = +1 \quad (3.11)$$

$$H_2 : w \cdot x_i + b = -1 \quad (3.12)$$

Şekil 3.7'de de görülen düzlemlerden H_0 optimum hiper düzlemi, +1 (mavi renkli) sınıfındaki destek vektörlerinden geçen H_1 hiper düzlemi ve -1 (yeşil renkli) sınıfındaki destek vektöründen geçen düzlem olan H_2 hiper düzlemi sırasıyla (3.10), (3.11) ve (3.12) eşitlikleriyle ifade edilebilir. Burada w ağırlık vektörünü, x hiper düzlem üzerindeki noktayı, b ise vektörün uzayda yönelimini ifade eden sabit bir sayıyı temsil eder. Söz konusu hiperdüzlem (3.13) ve (3.14) eşitlikleriyle hesaplanmaktadır.

$$w \cdot x_i + b \geq +1, \text{ her } y = +1 \text{ için} \quad (3.13)$$

$$w \cdot x_i + b \geq -1, \text{ her } y = -1 \text{ için} \quad (3.14)$$

(3.13) ve (3.14) eşitsizlikleri tek bir eşitsizlik olarak eşitlik (3.15) şeklinde ifade edilir.

$$y_i(w \cdot x_i + b) - 1 \geq 0, \quad y_i \in \{+1, -1\} \quad (3.15)$$

Bir x_i destek vektörü ile H_0 optimum düzlemi arasındaki dik mesafe d eşitlik (3.16)'da yer alan formüle göre hesaplanır.

$$d = \frac{|w \cdot x_i \pm b|}{\|w\|} \quad (3.16)$$

Destek vektörleri arasındaki mesafe (d) maksimum olması için ağırlık vektörünün (w) minimum olması şarttır. Bu durumda optimizasyon problemi eşitlik (3.17)'deki şekilde ifade edilir.

$$\min \left[\frac{1}{2} \|w\|^2 \right] \quad (3.17)$$

Eşitlik (3.17)'de gösterilen ifade doğrusal olmayan bir optimizasyon problemidir. Bu problem Langrange denklemleri kullanılarak çözülebilmektedir. Langrange denklemleri ile çözülen bu problemde (3.18)'de gösterilen fonksiyon elde edilir. ($\lambda_i, i=1, 2, \dots, r$) ise Langrange çarpanlarını ifade etmektedir.

$$f(x) = \text{sign} \left(\sum_{i=1}^r \lambda_i \cdot y_i (x \cdot x_i) + b \right) \quad (3.18)$$

Uzaktan algılanmış görüntülerindeki piksellerin sınıflandırılması gibi gerçek hayatta karşılaşılan bazı sınıflandırma problemlerinde sınıflar doğrusal olarak ayrılmazlar (Kavzoğlu ve Çölkesen 2009). Eğitim verilerinde doğrusal denklemlerle tanımlanan bir hiper düzlemin mümkün olmadığı durumlarda, DVM algoritması doğrusal olmayan karar yüzeylerine izin verecek şekilde genişletilebilir (Cortes ve Vapnik 1995). Pozitif değer alan bu gevşek değişken (ξ) ile formülün yeniden düzenlenip amaç fonksiyonu halini almış şekli (3.19) ve (3.20) eşitliklerinde gösterilmiştir.

$$\min \left[\frac{\|w\|^2}{2} + C \sum_{i=1}^r \xi_i \right] \quad (3.19)$$

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad i = 1, \dots, N \quad (3.20)$$

(3.19) eşitliğindeki C parametresi, hiper düzlemin yanlış tarafında sınıflandırılan eğitim pikselleriyle ilişkili cezanın büyüklüğünü kontrol eden bir ceza terimidir. C parametresi kenar boşluğu maksimizasyonu ve hata minimizasyonu arasındaki dengenin kurulmasına izin verir (Foody ve Mathur 2004, Oommen vd. 2008).

DVM algoritmasında sınıfların ayırımındaki hiper düzlemin doğrusal eşitliklerle belirlenememesi durumunda veri dağılımı doğrusal olmayan fonksiyonlar kullanarak daha yüksek boyutlu bir uzaya taşınarak doğrusal olarak bölünmesi sağlanır (Mathur ve Foody 2008). Bu işlem için kullanılan fonksiyonlara kernel (çekirdek) fonksiyonu ismi verilmektedir. Kernel fonksiyonlarının genel ifadesi eşitlik (3.21)'de verilmiştir.

$$K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) \quad (3.21)$$

Kernel fonksiyonu kullanılarak elde edilen karar fonksiyonu eşitlik (3.22)'de verilmiştir.

$$f(x) = \text{sign} \left(\sum_{i=1}^r \lambda_i \cdot y_i \cdot K(x_i, x_j) + b \right) \quad (3.22)$$

Verinin yüksek boyutlu bir uzaya taşınması sürecinde sıklıkla kullanılan dört adet Kernel fonksiyonundan söz edilebilir. Bunlar Doğrusal (Lineer), Sigmoid, Radyal Tabanlı Fonksiyon (RTF) ve Polinom kernel fonksiyonlarıdır (Kavzoğlu ve Çölkesen 2009). Literatürdeki çalışmalar incelendiğinde RTF'nin yüksek doğruluk vermesi sebebiyle daha fazla tercih edildiği görülmektedir (Melgani ve Bruzzone 2004, Pal ve Mather 2005,

Kavzođlu ve ölkesen 2009, Mountrakis vd. 2011). RTF kernel fonksiyonunun formülü (3.23)'te verilmiştir.

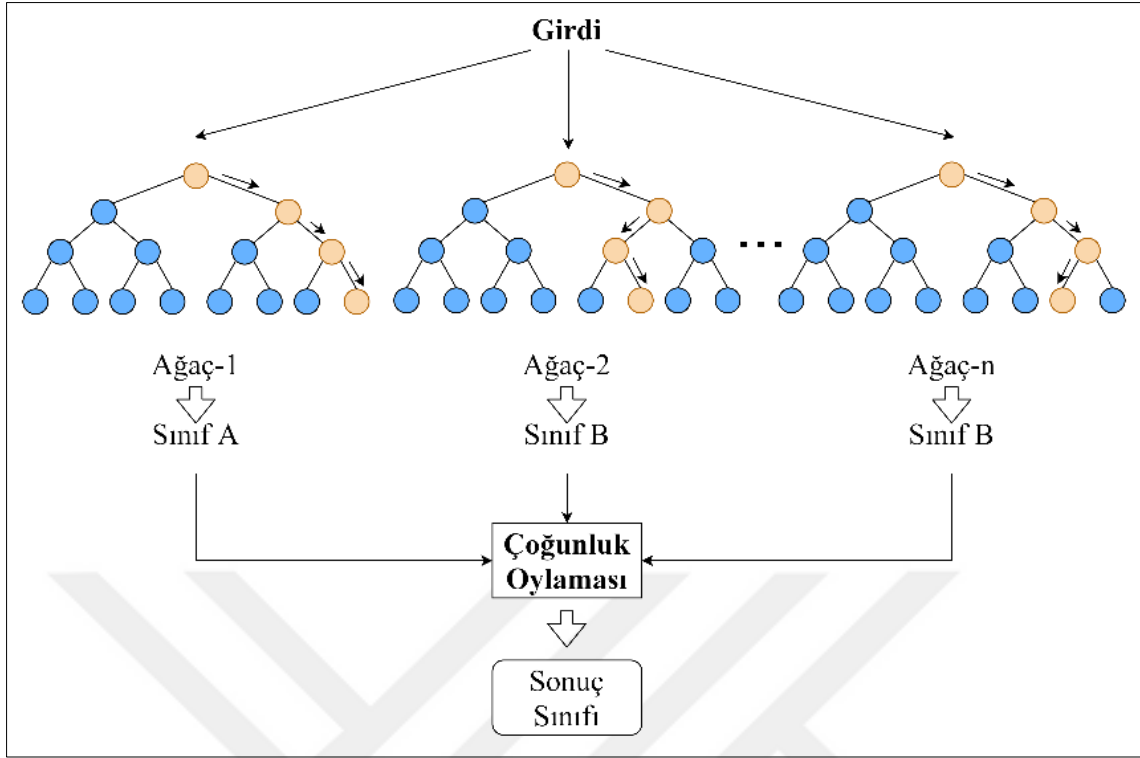
$$K(x_i, x_j) = e^{-\gamma \|x_i - x_j\|^2}, \quad \gamma > 0 \quad (3.23)$$

RTF fonksiyonunun düzenleme parametresi (C) ve kernel genişliđi parametresi (γ) olmak üzere iki tane kullanıcı tanımlı parametresi bulunmaktadır. Bu parametreler modelin doğruluđunu doğrudan etkilemektedir (Kavzođlu ve ölkesen 2010). Bu sebeple veri setine göre optimum kernel parametreleri optimizasyon ile belirlenmelidir.

3.5.2 Rastgele Orman Algoritması

Rastgele Orman (RO) algoritması, temelde karar ağalarını kullanan popüler bir toplu öğrenme algoritmasıdır. Breiman (2001) bir sınıflandırıcı kümesinin tek bir sınıflandırıcıdan daha iyi bir sınıflandırma performansı göstereceđi felsefesiyle Torbalama algoritmasını geliştirerek, her biri farklı eğitim kümesi ile eğitilmiş ve çok deđişkenli birçok karar ağacının birleştirilmesini öngören RO algoritmasını öne sürmüştür (Breiman 2001, Rodriguez-Galiano vd. 2012). RO algoritmasında karar ağaları CART (Classification and Regression Trees) algoritmasına göre yapılır. Ancak CART algoritmasında olduđu gibi budama işlemi gerçekleştirilmez (Breiman 2001). RO algoritmasında karar ağaları oluşturulurken sınıflara göre bir özniteliđin safsızlıđını ölçen bir öznitelik seçim ölçüsü olarak Gini İndeksi kullanılır (Pal 2005).

RO algoritmasının eğitilmesi aşamasında orijinal eğitim veri setinin 2/3'lük kısmı içerisinde torbalama kullanılarak alt eğitim kümeleri (in-bag) oluşturulur. Söz konusu alt kümeler karar ağalarının oluşturulmasında kullanılır. Orijinal eğitim verisinin geriye kalan 1/3'lük kısmı OOB (out-of-bag) olarak adlandırılır. OOB kümesi de algoritmanın ağa yapısının geçerliliđini test etmek için kullanılır. RO algoritmasının çalışma prensibi Şekil 3.8'de gösterilmiştir.

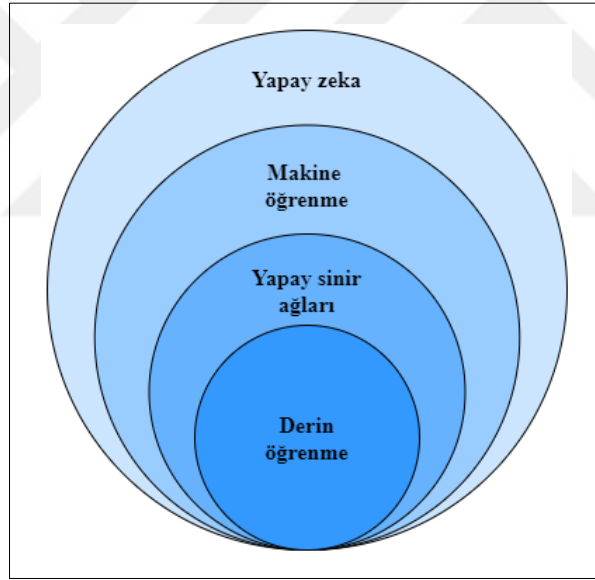


Şekil 3.8 RO algoritmasının çalışma prensibi.

RO algoritması için kullanıcı tarafından tanımlanan iki parametre bulunmaktadır. Bu parametrelerden ilki, karar ağacı oluşturulurken en iyi bölünmeyi belirlemek için her düğümdeki değişken sayısıdır ve (m) ile gösterilir. Düğümlerde sadece belirlenen özellikler araştırılır. İkinci parametre ise oluşturulacak ağaç sayısıdır ve (N) ile gösterilir. Bir piksel RO algoritması ile sınıflandırılırken N tane karar ağacından sınıflandırılır. Ağaçlardan çıkan N tane sınıflandırma sonucu değerlendirilir ve piksel en fazla oya sahip olan sınıfa atanır (Pal 2005). RO algoritması kullanıcı tarafından belirlenen parametrelere karşı duyarlı değildir. Sınıflandırma uygulamalarında algoritma eğitilirken genellikle m parametresi özellik sayısının karekökü olarak alınmaktadır. Düğümdeki özellik sayısının sınırlandırılması ağaçlar arasındaki korelasyonu ve modelin karmaşıklığını azaltmaktadır. Böylece RO algoritması büyük boyutlu verileri işleyebilir ve toplulukta çok sayıda karar ağacı oluşturabilir (Gislason vd. 2006).

3.5.3 Derin Öğrenme

DÖ; kontrollü veya kontrolsüz özellik çıkarma, dönüştürme, desen analizi ve sınıflandırma için birçok doğrusal olmayan gizli katmandan yararlanan bir MÖ tekniğidir (Deng ve Yu 2014). Başka bir tanıma göre ise DÖ, insan beyninin karmaşık problemler karşısındaki gözlem, analiz, öğrenme ve karar verme yeteneklerini taklit eden, kontrollü veya kontrolsüz olarak özellik çıkarımı, dönüşüm, sınıflandırma gibi uygulamaları büyük miktardaki verilerden yararlanmak suretiyle gerçekleştirebilen bir MÖ tekniğidir (Kayaalp ve Süzen 2018). Şekil 3.9'da yapay zekâ, MÖ, Yapay Sinir Ağları (YSA) ve DÖ arasındaki kavramsal ilişki gösterilmiştir. Buradan da anlaşılacağı üzere DÖ yapısı bir MÖ algoritmasıdır.



Şekil 3.9 Yapay zekâ, MÖ, YSA ve DÖ arasındaki ilişki.

MÖ algoritmaları kontrollü ve kontrolsüz sınıflandırma uygulamalarını gerçekleştirebilmektedir. Geleneksel MÖ teknikleri, karmaşık konumsal veya sıra bağımlılıkları olan ve bilgisayarlı görü ve konuşma tanıma gibi büyük miktarda öznelik mühendisliği gerektiren verileri analiz etmekte zorlanır (Ghatak 2019). Geleneksel MÖ tekniklerinden farklı olarak karmaşık verilerin hızlıca öğrenilmesi ve uygulanmasında insan faktörü devre dışı bırakılarak DÖ yöntemleri kullanılmaktadır (LeCun vd. 2015).


Çok kısa bir zamanda gelişen ve yaygınlaşan DÖ'nün sağlık bilişimi, ekonomi, enerji, kentsel bilişim, güvenlik, hidrolojik sistem modelleme, biyoenformatik ve hesaplamalı mekanik gibi alanlarda kullanımı giderek yaygınlaşmaktadır. ESA, TSA, Gürültü Giderici Otomatik Kodlayıcı (Denoising Autoencoder), Derin İnanç Ağları (Deep Belief Networks), Uzun Kısa Süreli Bellek (Long Short Term Memory) en popüler derin öğrenme yöntemleridir (Mosavi vd. 2019). İlerleyen başlıkta tez çalışmasında kullanılan ESA hakkında detaylı bilgiler verilmiştir.

3.5.4 Evrişimli Sinir Ağları (Convolutional Neural Networks)

Evrişimli ağlar veya Evrişimli Sinir Ağları (ESA) grid benzeri topolojiye sahip verileri işlemek için kullanılan, yapısında bulunan en az bir katmanında genel matris çarpımı yerine evrişim işlemi kullanılan özel bir tür sinir ağıdır (LeCun 1989, LeCun vd. 1998).


Hubel ve Wiesel (1962) kedilerin görsel korteksinde iki tane ana hücre tipi keşfetmişlerdir. İlk hücre tipi basit hücrelerdir ve belirli konumlara yerleştirilen açık veya koyu çubuklara tepki gösterir. İkinci tip olan daha karmaşık hücreler, birinci tip hücrelerden daha az katı yanıt profillerine sahiptir. Bu hücreler hala tercih edilen yönlere sahiptir, ancak birkaç farklı konumdaki bir çubuğa aynı güçlü şekilde yanıt verebilmektedir. Bu karmaşık hücrelerin büyük olasılıkla, tercihen aynı yönelimde ve konumları farklı olan birkaç basit hücreden girdi aldığı sonucuna varılmıştır.

Fukushima (1980), Hubel ve Wiesel (1962)'ın kedilerin görsel korteksleri hakkındaki bulgularını görsel sistemin işleyen bir modeline dönüştürmüştür. Neocognitron olarak isimlendirilen bu model modern evrişimli sinir ağlarının habercisidir. Modelin şematik gösterimi Şekil 3.10'da verilmiştir. Şekilden de görüleceği üzere iki ana hücre tipi içermektedir. S-hücreleri ismini kedi gözündeki birinci tip basit hücrelerden almaktadır ve bu hücrelerin temel özelliklerini kopyalar. Özellikle, S-hücresi yanıtlarını oluşturmak için giriş görüntüsündeki her konuma 2 boyutlu ağırlık gridi uygulanır. C hücreleri ise ismini kedi gözündeki ikinci tip olan karmaşık hücrelerden almaktadır ve bu hücrenin tepkisi aynı düzlemde ancak farklı konumlardan gelen birkaç S hücresinin doğrusal olmayan bir fonksiyonudur.



Şekil 3.10 Neocognitron ağıının şematik gösterimi (Fukushima 1980).

ESA'ların gücünün ilk büyük gösterimi LeCun vd. (1989) tarafından geri yayılım algoritması kullanılarak süpervizyonla eğitilmiş küçük bir ESA'nın el yazısıyla yazılan rakamların sınıflandırmasını gerçekleştirebildiği ile gösterilmiştir. Böylece LeNet modeli geliştirilmeye başlanmıştır. 1998 yılında LeCun ESA'nın el yazısı tanıma konusunda diğer modellerden daha yüksek başarı gösterdiği sonucuna ulaşmışlardır (LeCun vd. 1998). Ancak bu ağlar 2012 yılındaki ImageNet yarışmasında en yüksek başarıya sahip olan AlexNet ağıının tanıtımına kadar popüler olamamışlardır (Lindsay 2020). Şekil 3.11'de LeCun'un LeNet5 mimarisi şematik olarak gösterilmiştir.



Şekil 3.11 LeNet5 ESA mimarisinin şematik gösterimi (LeCun vd. 1998).

Krizhevsky vd. (2017) ImageNet yarışmasında tasarladıkları AlexNet mimarisiyle bilgisayarlı nesne tanımlama hata oranını %26,2'den %15,4'e düşürmüşlerdir. Bu çalışma itibariyle ESA giderek popülerleşmeye başlamıştır. Literatürde en bilinen ESA mimarileri AlexNet, VGG ve GoogLeNet, Microsoft ResNet, ZF Net, R-CNN, Fast R-CNN ve Faster R-CNN'dir (İnik ve Ülker 2017).

ESA, birden çok dizi biçiminde gelen verileri işlemek için tasarlanmıştır. Bu yapılar örnek olarak; sinyaller ve diziler olmak üzere 1 boyutlu veriler, görüntüler ve ses spektrogramları olmak üzere 2 boyutlu veriler, video ve hacimsel görüntüler olmak üzere 3 boyutlu veriler gösterilebilir (LeCun vd. 2015). Ayrıca DÖ kavramına dair temel mimari de ESA olarak kabul edilmektedir (İnik ve Ülker 2017). Genellikle ESA, evrişim katmanları (convolution layers), havuzlama katmanları (pooling layers) ve tam bağlı katmanlar (fully connected layers) olmak üzere üç temel bileşenden oluşmaktadır. Her bileşenin farklı bir rolü vardır (Li Y vd. 2018). Art arda sıralanan bu katmanlar ile, ilk giriş katmanından son sınıflandırma katmanına kadar sonuca etki eden çeşitli özellikler elde edilmekte ve son katman ile de sınıflandırma işlemi yapılmaktadır. Ağın eğitiminde iki temel aşamadan bahsedilebilir. Bu aşamalar ileri yayılım (forward propagation) ve geriye doğru yayılım (backpropagation) aşamalarıdır. İleri yayılımda amaç giriş görüntüsünü her katmandaki geçerli ağırlık (weight) ve yanlılık (bias) parametreleriyle temsil etmektir. Test için etiketlenmiş pikseller ile modelin tahminleri arasında zarar maliyeti hesaplanır. Daha sonra zarar maliyetine dayanarak, geriye doğru yayılım algoritması her parametrenin eğimini zincir kuralları ile hesaplar. Tüm parametreler gradyanlara göre güncellenir ve model bir sonraki iterasyon için hazırlanır. Bu aşamalar yeterli sayıda tekrarlandıktan sonra ağın öğrenme işlemi tamamlanır (İnik ve Ülker 2017, Bayati 2019). İlerleyen başlıklarda ESA'nın temel katmanları olan giriş katmanı, evrişim katmanı, havuzlama katmanı ve tam bağlı katman anlatılmıştır.

3.5.4.1 Giriş Katmanı (Input Layer)

ESA'nın ilk katmanı giriş katmanıdır. Giriş katmanında giriş verisi ağa ham olarak verilmektedir. ESA ile sınıflandırılacak hiperspektral görüntünün boyutu X olarak düşünülürse $X \in R^{M \times N \times D}$ olarak ifade edilir. Burada M satır sayısı, N sütun sayısı ve D

bant sayısıdır. X görüntüsünün yanında yer sınıf etiketlerini içeren görüntü y olarak isimlendirilirse $y \in R^{M \times N \times 1}$ boyutundadır. GT görüntüsündeki piksel etiketleri $Y = (0, y_1, y_2, \dots, y_c)$ olarak ifade edilebilir. Bu kümedeki 0 ifadesi, y verisinde o pikselin sınıfının belli olmadığını; y_c ifadesi ise bir sayıya göre kodlanmış sınıf numarasını ifade etmektedir. Hiperspektral görüntülerdeki pikseller, yüksek sınıf içi değişkenlik ve sınıflar arası benzerliğe sahip karma arazi örtüsü sınıfları tarafından temsil edilmektedir. Bu problemin üstesinden gelmek sınıflandırma modelleri için büyük bir zorluktur. Birbirleri arasında yüksek korelasyona sahip olan bu spektral fazlalığı ortadan kaldırmak için orijinal görüntüye TBA uygulanır (Roy vd. 2019). Böylelikle görüntünün spektral özellikleri büyük ölçüde korunarak daha az sayıda bant içermek suretiyle görüntü $X_m \in R^{M \times N \times B}$ boyutuna dönüştürülür.

X_m verisinin ESA modellerinin eğitiminde kullanılması için görüntü üst üste binen ve merkez pikselin sınıfına göre etiketlenmiş 3 boyutlu görüntü küpleri oluşturulmalıdır. Görüntü küplerinin pencere boyutu $S \times S$ olması varsayılırsa ilk aşamada X_m görüntüsüne $(S - 1)/2$ sayısında sıfır dolgu (zero padding) uygulanarak görüntü boyutu $X_m \in R^{(M+(S-1)) \times (N+(S-1)) \times B}$ şekline dönüştürülür. Daha sonra X_m görüntüsü üzerinde operatör gezdirilerek $P \in R^{S \times S \times B}$ şeklinde görüntü küpleri ve $y_p \in R^{1 \times 1 \times 1}$ sınıf etiketi oluşturulur. Görüntüden oluşan görüntü küplerinin sayısı $(M - S + 1) \times (N - S + 1)$ formülüyle bulunur. Sınıf etiketi 0 olan; yani ait olduğu bilinmeyen görüntü küpleri algoritmanın eğitiminde kullanılamayacağından bu görüntü küpleri silinmelidir. Kalan görüntü küpleri ESA modelinin eğitimi ve model doğruluğunun tespiti için eğitim ve test kümesi olarak ayrılır. Ayrılan $X_{\text{eğitim}}$ eğitim kümesi ve $y_{\text{eğitim}}$ sınıf etiketi matrisi ESA'nın giriş katmanıdır.

3.5.4.2 Evrişim Katmanı (Convolutional Layer)

Evrişim katmanı ESA'da en az bir tane bulunan ve ESA'nın temelini oluşturan öznetelik çıkarma katmanıdır. Evrişim katmanında çeşitli çekirdekler tüm görüntü üzerinde gezdirilir ve özellik haritaları oluşturulur (Guo vd. 2016). Görüntülerde komşu pikseller arasında, görüntü içindeki konumlarından bağımsız olarak birçok konumsal ilişki

bulunmaktadır (Fukushima 1980). Evrişim işlemi ile çeşitli filtreler bu konumsal ilişkileri ortaya çıkarmaktadır. Evrişim katmanının bazı avantajlar sağlamaktadır. Görüntünün tamamı üzerinden ağırlık paylaşımı, yanıt başına parametre sayısını azaltmaktadır. Yerel bağlantı komşu pikseller arasındaki korelasyonu öğrenmektedir. Giriş görüntüsünde kaydırılan bir nesne, karşılık gelen yanıtları benzer şekilde basitçe değiştirir, bu durum eşdeğerlilik (equivariance) olarak adlandırılır (Zeiler 2013). Evrişim işleminde girdi görüntü üzerinde çeşitli kenar çıkarma filtreleri uygulanır. Şekil 3.12’de evrişim işlemi için bir örnek gösterilmiştir.

1	3	5	2	6	1	*	1	0	-1	=	3	-8	1	1
7	0	2	4	1	3		1	0	-1		6	-5	5	-1
5	1	3	6	2	7		1	0	-1		-1	-3	5	6
2	4	3	0	0	1		1	0	-1		-2	4	5	11
1	7	3	9	2	1									
3	6	2	4	1	0									

Şekil 3.12 Evrişim işlemi (Ghatak 2019).

Yukarıdaki şekilde görüleceği üzere girdi görüntü 6×6, evrişim filtresi 3×3 boyutundadır. Evrişim filtresinin merkez pikseli (2, 2)’dir. Girdi görüntüde bu merkez piksele denk gelen matris elemanı merkeze alınacak şekilde, girdi görüntüsünün (1:3, 1:3) kısmı işleme alınır ve evrişim filtresiyle elemanlar birebir çarpılarak toplanır.

$$\begin{bmatrix} 1 & 3 & 5 \\ 7 & 0 & 2 \\ 5 & 1 & 3 \end{bmatrix} * \begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix} =$$

$$1 \times 1 + 3 \times 0 + 5 \times -1 + 7 \times 1 + 0 \times 0 + 2 \times -1 + 5 \times 1 + 1 \times 0 + 3 \times -1 = 3$$

Evrişim işlemi uygulandıktan sonra çıktı matrisinin ilk pikselinin değeri 3 olacaktır. Bu işlem sırasıyla belirlenen kaydırma adımı kadar kaydırılarak tüm piksellere uygulanır ve sonuç görüntüsü elde edilir. İşlem girdi matrisinin (2, 2) elemanından başlatıldığı için

girdi ve çıktı matrisinin boyutları aynı olmayacaktır. Evrişim işlemi gerçekleştirilirken 1 boyutlu evrişim için eşitlik (3.24), 2 boyutlu evrişim için eşitlik (3.25) ve 3 boyutlu evrişim için eşitlik (3.26) kullanılmaktadır.

$$v_{ij}^z = f \left(b_{ij} + \sum_{p=0}^{P_i-1} \sum_{s=0}^{S_i-1} w_{ijp}^s v_{(i-1)p}^{(z+s)} \right) \quad (3.24)$$

$$v_{ij}^{xy} = f \left(b_{ij} + \sum_{p=0}^{P_i-1} \sum_{q=0}^{Q_i-1} \sum_{r=0}^{R_i-1} w_{ijp}^{qrs} v_{(i-1)p}^{(x+q)(y+r)} \right) \quad (3.25)$$

$$v_{ij}^{xyz} = f \left(b_{ij} + \sum_{p=0}^{P_i-1} \sum_{s=0}^{S_i-1} \sum_{q=0}^{Q_i-1} \sum_{r=0}^{R_i-1} w_{ijp}^{qrs} v_{(i-1)p}^{(x+q)(y+r)(z+s)} \right) \quad (3.26)$$

Bu formüllerde, v özellik haritalarının çıktısını, S , Q , R sırasıyla spektral ve konumsal çekirdek boyutlarını, (s, q, r) çekirdek indekslerini ve (x, y, z) sırasıyla 2 konumsal ve 1 spektral olmak üzere özellik haritaları indekslerini ifade eder. Çekirdek parametreleri w sembolü belirtirken (i, j, p) sembolleri de sırasıyla girdi katmanı, çıktı katmanı ve özellik haritaları indekslerini tanımlar. P özellik haritaları sayısını, P_i de i . katmandaki özellik haritalarını temsil eder. Yanlılık terimi b ile gösterilirken f modelde kullanılan aktivasyon fonksiyonunu gösterir.


Evrişim işleminin ardından uygulanan aktivasyon fonksiyonu, önceki katmandan gelen girdi verilerini beklenen çıktıya daha yakın olan anlamlı bir gösterime dönüştüren matematiksel bir işlemdir (Ghatak 2019). Aktivasyon fonksiyonu geriye yayılım algoritmasının uygulanması aşamasında türevlenebilir ve doğrusal bir fonksiyon oluşturduğu için modelin öğrenme işleminde önemli bir rol oynamaktadır. Genellikle evrişimli yanıtlar eşitlik (3.27)'de verilen sigmoid, eşitlik (3.28)'de verilen tanh veya eşitlik (3.29)'da verilen düzeltilmiş doğrusal birimler (Rectified Linear Unit - ReLU) gibi doğrusal olmayan bir aktivasyon fonksiyonundan geçirilmektedir.

$$\sigma(Z) = \frac{1}{1 + \exp^{-Z}} \quad (3.27)$$

$$g(Z) = \frac{\exp^Z - \exp^{-Z}}{\exp^Z + \exp^{-Z}} \quad (3.28)$$

$$g(Z) = \max(Z, 0) \quad (3.29)$$

Nair ve Hinton (2010) tarafından önerilen ReLU fonksiyonu (Şekil 3.13) sigmoid ve tanh fonksiyonları ile kıyaslandığında üstel işlemler içermemesi ve doğrudan 0 değerinde eşiklenmesi sayesinde hesaplanması çok daha basittir. Sigmoid ve tanh fonksiyonlarında kaybolan gradyan problemi görüldüğünden ve çok yavaş bir şekilde yakınsadıklarından dolayı derin öğrenme problemlerinin çözümünde genellikle tercih edilmemektedir (Bhardwaj vd. 2018).




Şekil 3.13 ReLU aktivasyon fonksiyonunun grafiği (Agarap 2018).

3.5.4.3 Havuzlama Katmanı (Pooling Layer)

ESA mimarisinde evrişim katmanlarının ardından genellikle havuzlama katmanları bulunmaktadır. Havuzlama ile konumsal bilgi kaybı olmaksızın aktivasyon haritalarının

konumsal boyutunu ve ağıdaki parametre sayısını azaltmak amaçlanır. Böylece genel hesaplama karmaşıklığı azaltılır ve aşırı uyum (overfitting) sorununu kontrol almayı hedefler (Aloysius ve Geetha 2017). Bir havuzlama katmanı, bir evrişimli katmanın çıktısını girdi olarak alır ve alt örnekleme (subsampling) işlemi gerçekleştirir (Hinton vd. 2012). Çok bantlı görüntülerde havuzlama her banda ayrı ayrı uygulanır. Havuzlama işleminde havuz boyutu (pooling window size) ve kaydırma adımı (stride) olmak üzere iki parametre mevcuttur. Ayrıca havuzlama fonksiyonlarının da bazı çeşitleri bulunmaktadır. Bunlar maksimum havuzlama, ortalama havuzlama, stokastik havuzlama (Zeiler ve Fergus 2013), spektral havuzlama (Rippel vd. 2015), uzamsal piramit havuzlama ve çok ölçekli sırasız havuzlama operasyonlarıdır (Aloysius ve Geetha 2017). Genellikle maksimum havuzlama ve ortalama havuzlama yöntemleri kullanılmaktadır. Maksimum havuzlamada alt örnekleme yapılacak matris alt kümesindeki elemanların en yüksek değeri alınır. Ortalama havuzlamada ise alt örnekleme yapılacak matris alt kümesindeki elemanların aritmetik ortalamaları alınır. Şekil 3.14'te 5×5 boyutundaki girdi matrisine 1×1 kaydırma adımı ile 3×3 boyutunda havuzlama operasyonu uygulanması gösterilmiştir.



Şekil 3.14 5×5 boyutundaki girdi matrisine 1×1 kaydırma adımı ile 3×3 boyutunda havuzlama operasyonu uygulanması (Dumoulin ve Visin 2018).

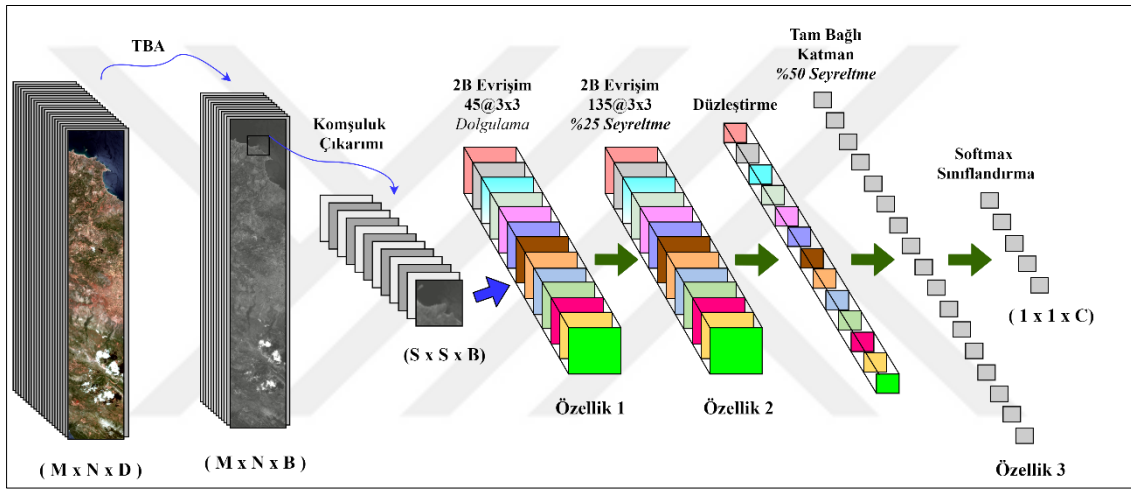
3.5.4.4 Tam Bağlı Katman (Fully Connected Layer)

Bir ESA mimarisinde evrişim, aktivasyon ve havuzlama katmanlarının ardından tam bağlantılı katman gelmektedir. Temelde geleneksel YSA'daki ile tamamen aynı olan tam bağlantılı katman kendisinden önceki katmanların öğrendiği matris formundaki parametreleri girdi olarak alır ve bu veriyi vektör formuna dönüştürür (Li Y vd. 2018). Yani bir önceki katmandaki tüm nöronları kendisinde bulunan başka nöronlara bağlar. Bu işlem düzleştirme (flattening) olarak adlandırılır. Birden fazla tam bağlantılı katman kullanılabilir ve nihai çıktı sınıf sayısı kadardır. Tam bağlantılı katmanın çıktısı Softmax gibi bir sınıflandırıcıya bağlanarak sınıflandırma işlemi gerçekleştirilebilir (Krizhevsky vd. 2017).

3.5.4.5 2B ESA Mimarisi

Önerilen 2B ESA mimarisi oluşturulurken Fokeas'ın (İnt.Kyn.7) Github sayfasında paylaştığı ESA modeli örnek alınmıştır. Şematik gösterimi Şekil 3.15'te verilen modelde orijinal hiperspektral görüntü küpü $X \in R^{M \times N \times D}$ olarak ifade edildiği düşünülün. Burada M satır sayısı, N sütun sayısı ve D bant sayısıdır. X görüntüsünün yanında yer sınıf etiketlerini içeren görüntü y olarak isimlendirilirse $y \in R^{M \times N \times 1}$ boyutundadır. GT görüntüsündeki piksel etiketleri $Y = (0, y_1, y_2, \dots, y_c)$ olarak ifade edilebilir. Eğitim kümesi oluşturulmadan önce X görüntüsü boyut indirgenmesi amacıyla TBA işlemine tabi tutulur ve ilk B tane temel bileşen ile görüntü küpü yeniden oluşturulur. Böylelikle orijinal görüntünün spektral özelliklerini büyük ölçüde koruyan ve daha az sayıda bant içeren $X_m \in R^{M \times N \times B}$ boyutuna dönüştürülür. Ağın eğitilmesi için komşuluk çıkarımı işlemiyle X_m verisi $P \in R^{S \times S \times B}$ boyutlarında $(M - S + 1) \times (N - S + 1)$ sayıda görüntü küpleri oluşturulur. Bu görüntü küplerinin karşılık gelen merkez piksellerine karşılık gelen sınıf etiketleri ile $y_p \in R^{1 \times 1 \times 1}$ şeklinde bir vektör oluşturulur. Bütün veri küplerinin ait olduğu sınıf bilinmediğinden bu görüntü küpleri ayıklanır. Kalan görüntü küpleri ESA modelinin eğitimi ve model doğruluğunun tespiti için eğitim ve test kümesi olarak ayrılır. Ayrılan $X_{eğitim}$ eğitim kümesi ve $y_{eğitim}$ sınıf etiketi matrisi ESA'nın giriş

katmanıdır. 2B ESA'nın ilk evrişim katmanında eğitim kümesindeki görüntü küplerine 3×3 boyutunda 45 filtre uygulanır ve bu katman sonucundaki çıkan özelliklere dolgulama işlemi uygulanır. Ardından uygulanan ikinci evrişim katmanında 3×3 boyutunda 135 filtre uygulanır. Oluşan sinir ağı düğümlerinde 25% seyreltme işlemi uygulandıktan sonra düzleştirme işlemi uygulanır. Böylece iki evrişim katmanı ile konumsal öznitelik öğrenme işlemi tamamlanır. Ardından 50% seyreltme ile tam bağlı katman uygulanır. Son olarak $1 \times 1 \times C$ olmak üzere Softmax sınıflandırma işlemi uygulanır. Burada C hiperspektral görüntüdeki sınıf sayısını ifade etmektedir.



Şekil 3.15 Önerilen 2B ESA modelinin şematik gösterimi.

Model kurulurken evrişim katmanlarındaki aktivasyon fonksiyonları ReLU seçilmiştir. Modelin optimizasyon fonksiyonu SGD (Stochastic Gradient Descent) (Zinkevich vd. 2010) kullanılmıştır. Yığın boyutu 256 ve epok sayısı 500 olarak uygulanmıştır. Salinas Scene veri seti için çıktı şeklini ve öğrenilen parametre sayılarını gösteren model özeti Çizelge 3.3'te verilmiştir.


Çizelge 3.3 Önerilen 2B ESA modelinin Salinas Scene veri seti için özeti.

Katman	Çıktı Şekli	Öğrenilen Parametre Sayısı
conv2d_1 (2B Evrişim)	(7, 7, 45)	6 120
conv2d_2 (2B Evrişim)	(5, 5, 135)	54 810
dropout_1 (Seyreltme)	(5, 5, 135)	0
flatten_1 (Düzleştirme)	(3375)	0
dense_1 (Yoğun)	(90)	303 840
dropout_2 (Seyreltme)	(90)	0
dense_2 (Yoğun)	(16)	1456

Eğitilebilir parametre sayısı: 366 226

3.5.4.6 3B+2B ESA Mimarisi

Bir önceki bölümde anlatılan 2B ESA mimarisinin oluşturulmasında eğitim ve test veri kümelerinin ayrılmasına kadar olan süreç 3B+2B ESA mimarisi için de aynı şekilde uygulanmaktadır. Bu ESA mimarisinin oluşturulmasında ise Roy vd. (2019)'un oluşturduğu HybridSN ESA modeli örnek alınmıştır. Bu aşda eğitim kümesine üç tane 3B evrişim katmanı sırasıyla uygulanır. Evrişim işlemlerindeki filtre boyutları $3 \times 3 \times 7$, $3 \times 3 \times 5$ ve $3 \times 3 \times 3$ olup filtre sayıları ise sırasıyla 8, 16 ve 32 şeklindedir. Her katmanda dolgulama işlemi de uygulanır. 3B evrişim katmanlarında gerçekleştirilen konumsal-spektral öznitelik çıkarımının ardından uygulanan 3×3 boyutunda 64 filtre içeren 2B evrişim katmanı ile konumsal öznitelik çıkarımı işlemi gerçekleştirilir. Düzleştirme işleminin ardından 40% oranında düğüm seyreltme ile tam bağlı katmanlar oluşturulur. Son olarak $1 \times 1 \times C$ olmak üzere Softmax sınıflandırma işlemi uygulanır. Detayları verilen 3B+2B ESA mimarisinin şematik gösterimi Şekil 3.16'da verilmiştir.



Şekil 3.16 Önerilen 3B+2B ESA mimarisinin şematik gösterimi.

3B+2B ESA modeli kurulurken evrişim katmanlarındaki aktivasyon fonksiyonları ReLU seçilmiştir. Modelin optimizasyon fonksiyonu olarak Adam (Kingma ve Ba 2014) optimizasyon algoritması kullanılmıştır. Yığın boyutu 256 ve epok sayısı 500 olarak uygulanmıştır. Salinas Scene veri seti için çıktı şeklini ve öğrenilen parametre sayılarını gösteren 3B+2B ESA modeli özeti Çizelge 3.4’te verilmiştir.

Çizelge 3.4 Önerilen 3B+2B ESA modelinin Salinas Scene veri seti için özeti.

Katman	Çıktı Şekli	Öğrenilen Parametre Sayısı
input_1 (Girdi Katman)	(7, 7, 15, 1)	0
conv3d_1 (3B Evrişim)	(7, 7, 15, 8)	512
conv3d_2 (3B Evrişim)	(7, 7, 15, 16)	5 776
conv3d_3 (3B Evrişim)	(7, 7, 15, 32)	13 856
reshape_1 (Yeniden Şekillendirme)	(7, 7, 480)	0
conv2d_1 (2B Evrişim)	(5, 5, 64)	276 544
flatten_1 (Düzleştirme)	(1600)	0
dense_1 (Yoğun)	(256)	409 856
dropout_1 (Seyreltme)	(256)	0
dense_2 (Yoğun)	(128)	32 896
dropout_2 (Seyreltme)	(128)	0
dense_3 (Yoğun)	(16)	2 064
Eğitilebilir parametre sayısı: 741 504		

3.6 Doğruluk Analizi

UA’da görüntülerin sınıflandırılması sürecinde yer doğrulama örneklerinin seçimi, kullanılan sınıflandırma modeli ve mevcutsa sınıflandırma modelinin kullanıcı tarafından belirlenen parametreleri haritaların doğruluğunu olumsuz yönde etkileyebilmektedir. Bu sebeple harita doğruluğunun belirlenmesi önem arz etmektedir. Üretilen tematik haritanın kullanıcıları haritanın kalitesinin belirlenmesi için, haritanın üreticisi de harita üretim sürecini değerlendirmek ve doğruluğu iyileştirmek için haritaların doğruluklarına ihtiyaç duymaktadır. Tematik haritaların doğruluğunun araştırılmasında çeşitli yöntemler mevcut olmasına rağmen en yaygın kullanılan yöntemlerden birisi, belirli bir alan kümesi için tahmin edilen ve gerçek sınıf etiketlerinin karşılaştırılmasıdır (Foody 2004). Bu karşılaştırmadan yararlanılarak hata matrisi oluşturulur ve bu matris üzerinden sınıflandırma haritasının doğruluğunu belirlemek için çeşitli hata metrikleri

hesaplanmaktadır.

Çalışmada gerçekleştirilen sınıflandırma işlemlerinin doğruluklarının analizi için genel doğruluk, üretici doğruluğu, kullanıcı doğruluğu ve Kappa katsayısı değerleri hesaplanmıştır. Bunun yanında aynı eğitim verisi ile eğitilen modellerin sınıflandırma performansları arasında istatistiksel olarak anlamlı bir fark olup olmadığı McNemar's Testi ile incelenmiştir.

Doğruluk analizinin gerçekleştirilebilmesi için yer sınıfını doğru temsil ettiği kabul edilen bir test veri setinin ayrılmış olması gerekmektedir. Bunun için ilk başta görüntü üzerinde sınıfları temsil eden bölgeler yersel çalışmalar, önceden üretilmiş haritalar veya yüksek çözünürlüklü görüntüler kullanılarak belirlenir. Bu veriye yer doğrulama verisi ismi verilmektedir. Tez kapsamında kullanılan veri setlerinin yer doğrulama verilerinin bir kısmı algoritmaların eğitimi için; geriye kalan kısmı ise algoritmaların başarısının testi için doğruluk analizinde referans veri olarak kullanılması için ayrılmıştır.

Doğruluk analizinin ilk adımında test piksellerinin gerçek sınıfları ile model tarafından atandıkları sınıflar karşılaştırılarak hata matrisi oluşturulmaktadır. Hata matrisinin şematik gösterimi Şekil 3.17'de verilmiştir.

		Referans (Test)			
		1	2	k	n
Sınıflandırılmış	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+}
	n	n_{+1}	n_{+2}	n_{+k}	n

Şekil 3.17 Hata matrisinin şematik gösterimi.

Kontrollü sınıflandırmada eğitim verisiyle sınıflandırma modeli oluşturulur. Ardından test için ayrılan veri seti söz konusu model kullanılarak sınıflandırılır. Sınıflandırma işlemi sonucunda test piksellerinin gerçek sınıfları ile model tarafından atandıkları sınıfları karşılaştırılarak hata matrisi oluşturulur. Sınıflandırılan görüntü verisinde sınıf sayısının k olduğu varsayılırsa hata matrisi $k \times k$ boyutundadır. Test piksellerinden gerçek sınıfı i olup sınıflandırma modeli tarafından i sınıfına atanan piksellerin sayısı belirlenerek hata matrisinin n_{ii} elemanına yazılır. Gerçek sınıfı i olup sınıflandırma modeli tarafından x sınıfına atanarak yanlış sınıflandırılan piksellerin sayısı ise n_{xi} elemanına yazılır. Bu işlem tüm sınıflar için tekrarlanıp matrisin tüm elemanları bulunarak hata matrisinin oluşturulması sağlanır.

Oluşturulan hata matrisinden genel doğruluk, üretici doğruluğu, kullanıcı doğruluğu ve Kappa katsayısı hesaplanması ilerleyen başlıklarda detaylı olarak anlatılmıştır.

3.6.1 Genel Doğruluk

Kontrollü sınıflandırmada en yaygın kullanılan doğruluk kriteri olan genel doğruluğun hesaplanması eşitlik (3.30)'da gösterilmiştir.

$$\frac{\sum_{i=1}^k n_{ii}}{\sum_{i=1}^k n_{+j}} = \frac{\sum_{i=1}^k n_{ii}}{n} \quad (3.30)$$

Genel doğruluk, kullanımı kolay bir performans metriğidir. Ancak her bir sınıfa ait sınıflandırma performansı hakkında bilgi vermemektedir. Ayrıca bazı sınıfların düşük doğrulukta sınıflandırma performansı göstermesi, yüksek doğruluğa sahip sınıflar tarafından maskelenebilmektedir (Sunar vd. 2011). Bu durumlarda her bir sınıfa ait üretici ve kullanıcı doğruluklarının hesaplanması sınıflandırma performansı hakkında daha detaylı bilgi verecektir.

3.6.2 Üretici ve Kullanıcı Doğrulukları

Hata matrisi üzerinden üretici doğruluğunun hesaplanması eşitlik (3.31)'de, kullanıcı doğruluğunun hesaplanması ise eşitlik (3.32)'de gösterilmiştir.

$$ÜD_j = \frac{n_{jj}}{n_{+j}} \quad (3.31)$$

$$KD_i = \frac{n_{ii}}{n_{i+}} \quad (3.32)$$

Üretici doğruluğu modelin sınıflandırma performansının göstergesidir. Kullanıcı doğruluğu ise sınıflandırılmış haritanın gerçek yeryüzünü ne kadar iyi temsil ettiğinin göstergesidir (Congalton ve Green 2019). Şekil 3.17'deki hata matrisinde 1 numaralı sınıf için düşünülürse; sınıflandırma sonucu üretilen tematik haritanın kullanıcısı, sınıflandırma algoritması tarafından 1 olarak etiketlenen bir pikselin gerçekte (arazide) 1 olma olasılığıyla daha çok ilgilenir. Bu durum harita doğruluğunun göstergesidir ve kullanıcı doğruluğu olarak adlandırılır (Richards 2013). Yani $ÜD_1$ değeri, 1 sınıfının yalnızca $ÜD_1$ kadarlık kısmının harita üzerinde doğru etiklendiğini göstermektedir.

3.6.3 Kappa İstatistiği

Kappa istatistiği, ikili çeşitlilik ölçümü için kullanılır ve sınıflandırma algoritmalarının kararlarının anlaşmasını ortaya çıkarmak için önerilir (Viera ve Garrett 2005). Kappa, anlaşma (agreement) (θ_1) ve anlaşmazlık (disagreement) (θ_2) ölçümleri üzerinden hesaplanır. Anlaşma ve anlaşmazlık ölçümleri üzerinden türetilmiş Kappa istatistiği formülü eşitlik (3.33)'te verilmiştir.

$$\kappa = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{+i} n_{i+}}{n^2 - \sum_{i=1}^k n_{+i} n_{i+}} \quad (3.33)$$

Kappa istatistiđi deęeri tek bařına kullanıldığında sınıflandırma performansı hakkında yeterli bilgi veremeyebilir. Bazı analistler hala Kappa kullanmak yerine genel doęruluk kullanmayı veya tam hata matrisi sunumunu tercih etmektedir (Richards 2013). Kappa deęeri 0 ile 1 arasında deęer almaktadır. Kappa deęerinin yorumlanmasına iliřkin ölçeklendirme ise Çizelge 3.5'te verilmiřtir.

Çizelge 3.5 Kappa İstatistiđi deęerinin yorumlanması (Viera ve Garrett 2005).

Kappa Deęer Aralıđı	Sınıflandırma Yorumu
< 0.40	Zayıf
0.41-0.60	Orta
0.61-0.75	İyi
0.76-0.80	Çok İyi
> 0.81	Neredeyse Mükemmel

3.6.4 McNemar's Testi

McNemar's Testi, sınıflandırma sonuçlarını en gelişmiş yöntemlerle elde edilen sınıflandırma sonuçlarıyla karşılařtırmak için kullanılan nesnel ve istatistiksel bir kriterdir. Bu test sınıflandırıcıların sonuçlarının istatistiksel olarak farklı olup olmadığını anlamının yaygın bir yoludur. Parametrik olmayan McNemar's Testi de tematik harita karşılařtırması için de uygundur (Foody 2004). McNemar's Testi için 2×2 boyutunda olumsuzluk tablosu oluşturulur (Şekil 3.18). Test veri setindeki her pikselin yer doęrulama sınıfı ile Model 1 ve Model 2 tarafından etiklendiđi sınıfları karşılařtırılır. Her iki algoritma tarafından doęru sınıflandırılan piksellerin sayısı matrisin n_{ii} elemanına; her iki algoritma tarafından yanlış sınıflandırılan piksellerin sayısı matrisin n_{ji} elemanına; Model 1'in doęru sınıflandırıp Model 2'nin yanlış sınıflandırdığı piksellerin sayısı matrisin n_{ij}

elemanına ve Model 2'nin doğru sınıflandırıp Model 1'in yanlış sınıflandırdığı piksellerin sayısı matrisin n_{ji} elemanına yazılır.

		Model 2 Doğru	Model 2 Yanlış
Model 1 Doğru		n_{ii}	n_{ij}
Model 1 Yanlış		n_{ji}	n_{jj}

Şekil 3.18 McNemar's Testi olumsuzluk tablosu.

Oluşturulan McNemar's olumsuzluk matrisindeki değerler kullanılarak eşitlik (3.34)'a göre bir istatistiksel değer hesaplanır (Japkowicz ve Shah 2011).

$$\chi_{Mc}^2 = \frac{(|n_{ij} - n_{ji}| - 1)^2}{n_{ij} + n_{ji}} \quad (3.34)$$

Hesaplanan istatistiksel değer %95 güven aralığında Ki-Kare tablo değeri olan $\chi_{1,0.05}^2 = 3,841$ değeriyle kıyaslanır. McNemar's testinde sıfır hipotezi Model 1 ve Model 2'nin aynı performansa sahip olduğunu; dolayısıyla aynı hata oranına sahip olduğunu varsaymaktadır (Japkowicz ve Shah 2011). Değerin $\chi_{1,0.05}^2 = 3,841$ 'den büyük çıkması durumunda sıfır hipotezi reddedilir. Başka bir deyişle Model 1 ile Model 2 arasındaki sınıflandırma doğruluğu arasında istatistiksel olarak anlamlı bir fark olduğu kanısına varılır.

4. UYGULAMA

Tez çalışmasında hiperspektral görüntülerin sınıflandırma işlemi için yapılması gereken ön işlemler ENVI 5.3 ve MATLAB R2019a yazılımlarında gerçekleştirilmiştir.

Sınıflandırma modellerinin geliştirilmesinde Python 3.7.9 tabanlı Spyder geliştirme ortamı kullanılmıştır. Kullanılan Python kütüphanelerine dair detaylar 0. numaralı başlık altında detaylandırılmıştır. Görüntülere TBA uygulanarak boyut indirilmesi gerçekleştirilmiştir. Görüntülere TBA uygulanması aşamasındaki analizler 4.1. numaralı başlık altında detaylı olarak verilmiştir.


TBA uygulanarak boyutu indirilmiş veri setlerine komşuluk çıkarımı uygulanarak 3B görüntü küpleri elde edilmiştir. Eğitim ve test amacıyla kullanılmayacak 3b görüntü küplerinin veri setinden çıkartılmasının ardından kalan yer doğrulama verileri eğitim ve test veri seti olmak üzere belirlenen oranda ayrılmıştır. Ardından veriler sınıflandırma modellerinin eğitimi için uygun bir biçimde şekillendirilmiştir.

Modellerin eğitimi aşamasında DVM algoritması için 5 katlı çapraz doğrulama işlemi ile optimum parametreler tespit edilmiştir. Modeller eğitilirken işlem süreleri tespit edilmiştir. DVM algoritmasının eğitim işlem süresinde optimum parametrelerin belirlendiği süre de dahildir. Modeller kurulduktan sonra ayrılan test veri setleri ile doğrulukları test edilmiştir. Sınıflandırma haritaları ArcMap 10.8 yazılımında hazırlanmıştır. McNemar's testi ise RStudio yazılımında gerçekleştirilmiştir.

İlerleyen başlıklarda öncelikle tüm veri setlerinin TBA ile boyut indirilmesi sürecine dair analizler verilmiş, ardından veri seti bazında elde edilen sınıflandırma sonuçları sistematik olarak incelenmiştir. Her veri seti için yer sınıfları, eğitim ve test verilerinin ayırımına dair detaylar verilmiş, modellerin kurulması ile alakalı bilgilerin ardından sırasıyla 30%, 50% ve 70% eğitim veri seti oranına göre kurulan sınıflandırma modellerinin performansları ve sınıflandırma haritaları sunulmuştur.

4.1 TBA ile Veri Setlerinin Boyutlarının İndirgenmesi


TBA yönteminde temel bileşenlerin bulunması aşamasında özdeğerler büyükten küçüğe doğru sıralanıp bu özdeğerlere karşılık gelen özvektörler seçilmektedir. Özdeğerin yüksek olması ilgili özvektörün veri hakkında daha yüksek bilgi içerdiğini; başka bir deyişle açıklanabilir varyansın yüksek olduğunu göstermektedir. Tez kapsamında kullanılan veriler için hesaplanan açıklanabilir varyansların grafikleri Şekil 4.1’de verilmiştir. Grafikler incelendiğinde tüm veri setleri için dördüncü temel bileşenden itibaren açıklanabilir varyansların sıfıra yakınsadıkları görülmektedir.



Şekil 4.1 Dioni (a), Loukia (b), DFC13 (c) ve Salinas Scene (d) veri setleri için temel bileşenlerin açıklanabilir varyansları.

Görüntülerin boyutlarının indirgenmesi aşamasında öne çıkan bir yöntem ya da kural bulunmamaktadır. Ancak özdeğerlerin kümülatif varyanslarının 95%’ini sağlayan özvektörlerin seçilmesi uygun görülmektedir (Çatalbaş 2014). Hiperspektral görüntülerin

TBA dönüşümünde hesaplanan temel bileşenler genellikle ilk iki bandında 95% açıklanabilir varyansı sağlamaktadır. Ancak iki temel bileşen ile algoritmaların öznetelik çıkarımları zorlaşacağından tez çalışmasında söz konusu kriter 99,5%'e çıkartılarak orijinal görüntüye en yakın miktarda özelliği sağlayabilecek temel bileşenler incelenmiştir. Tezde kullanılan veri setleri için hesaplanan kümülatif varyans grafikleri Şekil 4.2'de görülmektedir. Şekil 4.2a, Şekil 4.2b ve Şekil 4.2d incelendiğinde sırasıyla Dioni, Loukia ve Salinas Scene veri setleri için ilk dört temel bileşen 99,5% açıklanabilir varyans kriterini sağlarken Şekil 4.2c'de DFC13 veri setinde bu kriterin ilk üç temel bileşenin kullanımıyla sağlandığı açıkça görülmektedir. Kullanılan temel bileşen sayısı arttıkça kümülatif varyans değeri 100%'e (1.00) yakınsamaktadır. Sınıflandırma modelleri için uygulanacak TBA işleminin standartlaştırılması için kümülatif varyansın farklı sayıda bant kullanımında belirlenen eşişge ulaşması ve her model için aynı sayıda temel bileşen kullanılması maksadıyla bütün veri setleri için en yüksek açıklanabilir varyansa sahip ilk 15 temel bileşenin kullanılması uygun görülmüştür.



Şekil 4.2 Dioni (a), Loukia (b), DFC13 (c) ve Salinas Scene (d) veri setleri için temel bileşenlerin kümülatif varyansları.


4.2 Dioni Veri Seti Sınıflandırma Sonuçları

Dioni veri setinin geleneksel MÖ ve DÖ algoritmaları ile sınıflandırılmasında yer doğrulama verilerinin eğitim ve test verisi olarak ayrılmasında Python: Scikit-Learn kütüphanesinin `train_test_split` fonksiyonu kullanılmıştır. Eğitim küme boyutunun araştırılması amacıyla eğitim veri kümesinin boyutu sırasıyla 30%, 50% ve 70% olarak seçilmiştir. Çizelge 4.1’de Dioni veri setinin sınıflara göre yer doğrulama verilerinin içerdiği etiketli veri sayısı, bunun yanında eğitim veri setinin boyutuna göre eğitim ve test için ayrılan etiketli verilerin dağılımları gösterilmiştir.

Çizelge 4.1 Dioni veri setinde sınıflar ve 30%-50%-70% eğitim veri kümesi oranlarına göre eğitim ve test için ayrılan etiketli veri sayıları.


Sınıf No	Sınıf Adı	Toplam (n_i)	Oran $\frac{n_i}{\sum n}$ (%)	30% Eğitim Veri Seti		50% Eğitim Veri Seti		70% Eğitim Veri Seti	
				Eğitim 30%	Test 70%	Eğitim 50%	Test 50%	Eğitim 70%	Test 30%
1	Sürekli şehir yapısı	1262	6,3	379	883	631	631	883	379
2	Mineral çıkarım sahaları	204	1,0	61	143	102	102	143	61
3	Sulanmayan ekilebilir alanlar	614	3,1	184	430	307	307	430	184
4	Meyve bahçeleri	150	0,7	45	105	75	75	105	45
5	Zeytinlikler	1768	8,8	530	1238	884	884	1237	531
7	İğne yapraklı ormanlar	361	1,8	108	253	180	181	253	108
9	Yoğun sklerofil bitki örtüsü	5035	25,1	1511	3524	2518	2517	3524	1511
10	Seyrek sklerofil bitki örtüsü	6374	31,8	1912	4462	3187	3187	4462	1912
11	Seyrek bitki alanları	1754	8,8	526	1228	877	877	1228	526
12	Kayalar ve kumluklar	492	2,5	148	344	246	246	344	148
13	Su	1612	8,1	484	1128	806	806	1128	484
14	Kıyı suları	398	2,0	119	279	199	199	279	119

Rastgele olarak ayrımı gerçekleştirilen eğitim ve test kümelerinin dağılımları **Şekil 4.3**'te gösterilmiştir.



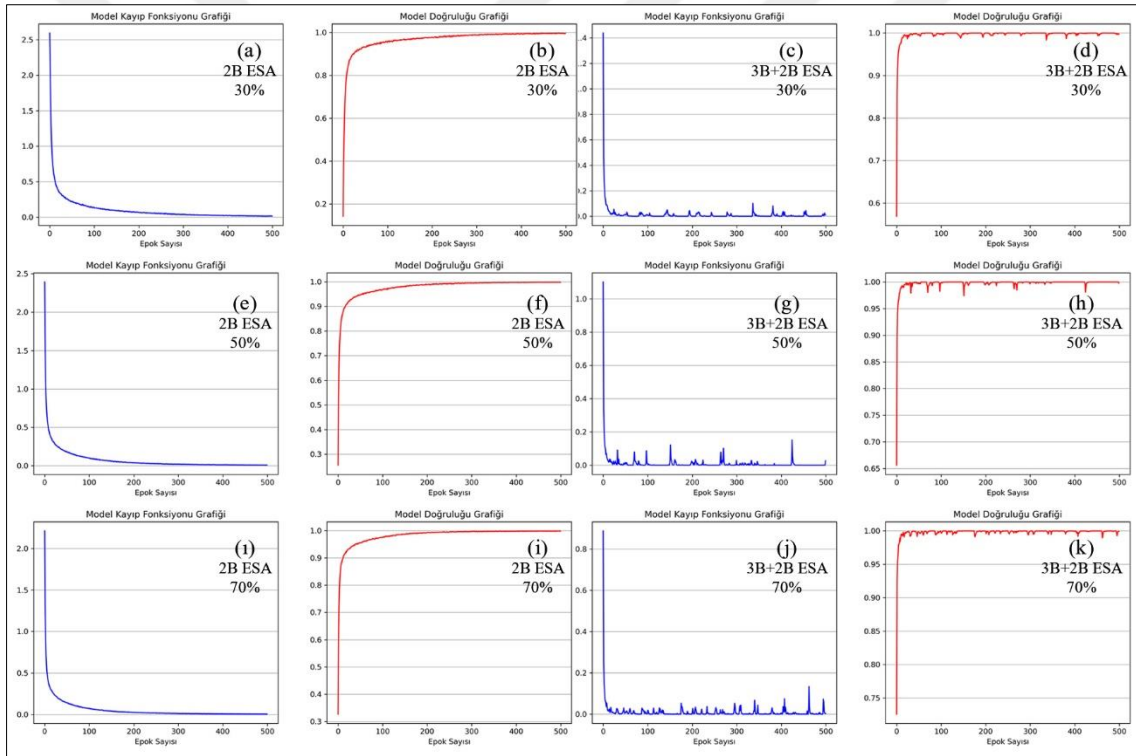
Şekil 4.3 Dioni veri seti (a) için eğitim-test piksellerinin sırasıyla 30%(b)-70%(c), 50%(d)-50%(e) ve 70%(f)-30%(g) dağılımları.

Dioni veri seti için DVM modelleri oluşturulurken literatürde de sıklıkla kullanılan RTF kernel fonksiyonu temsil edilmiştir. Yer doğrulama verisinin sırasıyla 30%, 50% ve 70% eğitim verisi olarak ayrıldığı durumlar için optimum parametrelerin tespiti 5 katlamalı çapraz doğrulama işlemi ile gerçekleştirilmiştir. Bütün veri küme boyutları için optimum parametreler $C=10$ ve $\gamma=0,1$ olarak belirlenmiştir. RO algoritmasında $m=4$ olarak belirlenirken N parametresi için her üç eğitim kümesi için öncül olarak 1000 karar ağacı ile modeller oluşturulmuştur. Öncül modellerin OOB hatalarını gösteren grafikler Şekil 4.4'te verilmiştir. OOB hatasının grafikleri incelendiğinde 30% (Şekil 4.4aŞekil 4.3), 50% (Şekil 4.4b) ve 70% (Şekil 4.4c) eğitim veri küme boyutları için yaklaşık 150 karar ağacından sonra hata stabil olarak ilerlediği görülmüştür ve bu veri kümeleri ile asıl modeller kurulurken her üç RO modeli için de $N=150$ olarak seçilmiştir.



Şekil 4.4 Dioni veri seti için sırasıyla 30% (a), 50% (b) ve 70% (c) eğitim kümesi boyutlarına göre RO algoritmasının OOB hataları.

ESA modellerinin eğitimi aşamasında her iki ESA modeli ve bütün eğitim veri kümesi boyutları için yığın boyutu 256 ve epok sayısı 500 olarak belirlenmiştir. Şekil 4.5'te her iki ESA modelinin farklı eğitim veri kümesi boyutlarına göre kayıp fonksiyonu ve model doğruluğu grafikleri verilmiştir. 2B ESA modellerinin tüm veri kümesi boyutları için kayıp fonksiyonu grafikleri incelendiğinde (Şekil 4.5a, Şekil 4.5e ve Şekil 4.5i) hataların düzenli olarak düştüğü ve ilerleyen epoklarda sıfıra yaklaştığı görülmektedir. 3B+2B ESA modellerinin kayıp fonksiyonu grafiklerinin (Şekil 4.5c, Şekil 4.5g ve Şekil 4.5j) birkaç epok sonunda hızlıca düştükleri, ilerleyen epokların bazılarında anlık sıçramalar ile hataların maksimum 0,15 civarına yükselip geri düştükleri görülmektedir.



Şekil 4.5 Dioni veri setinin sınıflandırılması için 30%, 50% ve 70% eğitim verisi ile oluşturulan ESA modellerinin kayıp fonksiyonu ve model doğruluğu grafikleri.

Veri seti için ilk aşamada algoritmalar 30% eğitim verisi ile eğitildikten sonra yer doğrulama verisinin eğitim verisinden artı kalan 70%'lik test veri seti ile hata matrisleri oluşturulmuştur (Ek 1, Ek 2,

Ek 3 ve Ek 4). Bu hata matrislerinden hesaplanan genel doğruluk, kappa, üretici ve kullanıcı doğrulukları ek olarak işlem süreleri Çizelge 4.2’de verilmiştir. Tablodaki değerler incelendiğinde 98,60% genel doğruluk ile en başarılı algoritmanın 3B+2B ESA olduğu görülmektedir. Sınıf bazındaki doğruluklar incelendiğinde ise 3B+2B ESA’nın birkaç sınıf haricinde en yüksek üretici ve kullanıcı doğruluklarına sahip olduğu, 2B ESA’nın ise sınıf bazındaki doğruluk ölçütlerine ve genel doğruluğa göre ikinci en başarılı algoritma olduğu görülmektedir. İşlem süreleri açısından incelendiğinde RO algoritmasının eğitiminin ve tüm görüntünün sınıflandırılması aşamasında en hızlı algoritma olduğu açıkça görülmektedir.

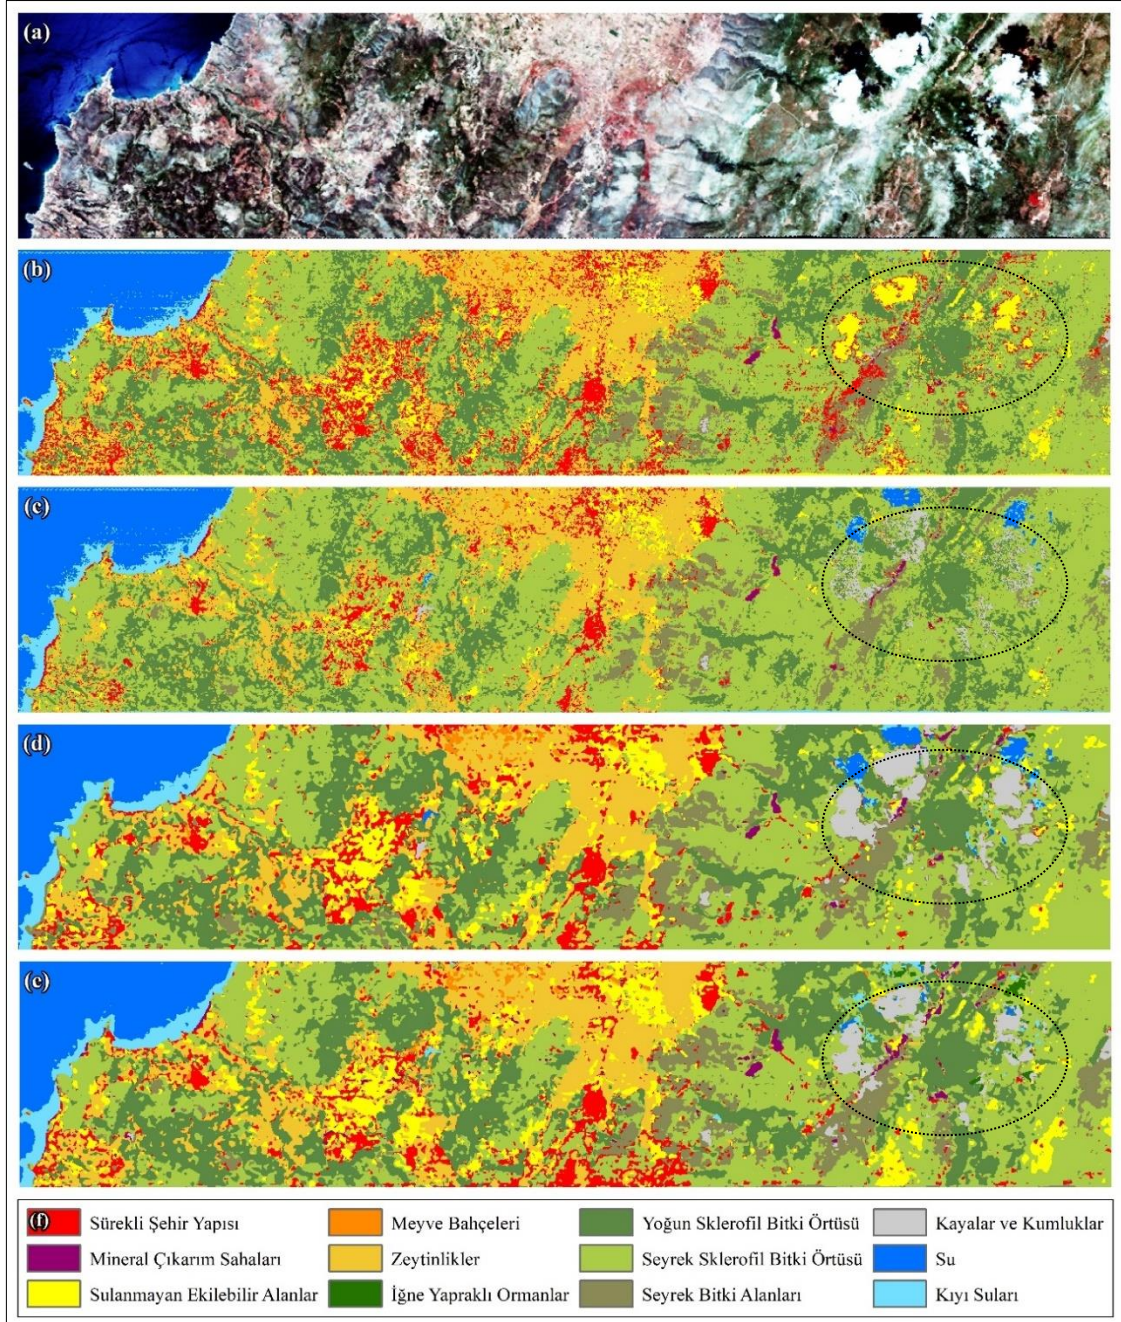
Çizelge 4.2 Dioni 30% veri seti için algoritmaların performansları.

Sınıf Adı	DVM		RO		2B ESA		3B+2B ESA	
	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)
Sürekli şehir yapısı	86,99	86,30	91,99	78,03	97,87	93,66	98,59	94,90
Mineral çıkarım sahaları	94,53	84,62	94,96	79,02	100,00	95,80	99,31	100,00
Sulanmayan ekilebilir alanlar	92,33	89,53	93,06	90,47	96,06	96,28	95,24	97,67
Meyve bahçeleri	86,32	78,10	90,70	74,29	94,74	85,71	97,65	79,05
Zeytinlikler	90,97	92,73	89,75	94,02	97,52	98,63	97,08	99,19
İğne yapraklı ormanlar	100,00	98,81	100,00	100,00	100,00	100,00	99,22	100,00
Yoğun sklerofil bitki örtüsü	96,16	93,90	96,57	91,94	98,27	98,52	98,01	99,29
Seyrek sklerofil bitki örtüsü	93,85	96,39	90,62	97,22	97,82	98,50	98,94	98,30
Seyrek bitki alanları	95,27	95,03	93,30	91,86	99,27	99,27	99,84	99,43
Kayalar ve kumluklar	99,41	97,38	98,22	96,22	99,71	99,42	99,71	99,71
Su	99,82	100,00	99,82	100,00	100,00	100,00	100,00	100,00
Kıyı suları	100,00	97,85	100,00	99,28	100,00	100,00	100,00	100,00
Genel Doğruluk	94,61%		93,66%		98,29%		98,60%	
Kappa	0,933		0,921		0,979		0,983	
İşlem Süreleri (saniye):	Eğitim	185,49	0,11		80,29		215,25	
	Sınıflandırma	23,39	7,21		390,17		479,12	

Dioni 30% verisi için eğitilen algoritmalar tarafından oluşturulan sınıflandırma haritaları Şekil 4.6’da verilmiştir. Sınıflandırma sonuçları incelendiğinde görüntünün sağ tarafında yer alan bulut 2B ESA ve 3B+2B ESA ile spektral imza açısından en benzer olduğu

kayalar ve kumluklar sınıfına atanırken söz konusu bulutun RO tarafından kayalar ve kumluklar yoğun sklerofil bitki örtüsü ve seyrek sklerofil bitki örtüsü olmak üzere üç farklı sınıfa atama yaptığı görülmektedir. DVM algoritması ise aynı alanı sulanmayan ekilebilir alan, yoğun sklerofil bitki örtüsü ve seyrek sklerofil bitki örtüsü olarak sınıflandırmıştır. Bulutun gölgesi ise RO ve 2B ESA algoritmaları tarafından su ve kıyı suları olarak etiketlenmiştir.





Şekil 4.6 Dioni 30% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).


Dioni veri seti için ikinci aşamada algoritmalar 50% eğitim verisi ile eğitildikten sonra yer doğrulama verisinin eğitim verisinden artı kalan 50%'lik test veri seti ile hata matrisleri oluşturulmuştur (Ek 5, Ek 6, Ek 7 ve Ek 8). Bu hata matrislerinden hesaplanan genel doğruluk, kappa, üretici ve kullanıcı doğrulukları ek olarak işlem süreleri Çizelge 4.3'te verilmiştir. Tablodaki değerler incelendiğinde 99,17% genel doğruluk ile en

başarılı algoritmanın 2B ESA olduğu görülmektedir. Sınıf bazındaki doğruluklar incelendiğinde ise 2B ESA'nın birkaç sınıf haricinde en yüksek üretici ve kullanıcı doğruluklarına sahip olduğu, 3B+2B ESA'nın ise sınıf bazındaki doğruluk ölçütlerine ve genel doğruluğa göre ikinci en başarılı algoritma olduğu görülmektedir. Ancak 3B+2B ESA modeli mineral çıkarım sahaları ve meyve bahçeleri sınıflarında kullanıcı doğrulukları açısından diğer modellere göre oldukça düşük çıktığı görülmektedir. Ek 8'de söz konusu model için oluşturulan hata matrisi incelendiğinde söz konusu sınıfların diğer sınıflara oranla daha az sayıda test pikseline sahip olduğu görülürken mineral çıkarım sahaları sınıfının seyrek bitki alanları sınıfıyla; meyve bahçeleri sınıfının ise zeytinlikler sınıfları ile karıştığı görülmüştür. İşlem süreleri açısından incelendiğinde RO algoritmasının eğitiminin ve tüm görüntünün sınıflandırılması aşamasında en hızlı algoritma olduğu açıkça görülmektedir.

Çizelge 4.3 Dioni 50% veri seti için algoritmaların performansları.

Sınıf Adı	DVM		RO		2B ESA		3B+2B ESA	
	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)
Sürekli şehir yapısı	91,50	88,75	91,89	80,82	99,20	97,78	98,52	94,77
Mineral çıkarım sahaları	98,94	91,18	95,60	85,29	100,00	99,02	100,00	53,92
Sulanmayan ekilebilir alanlar	94,24	90,55	96,79	88,27	98,36	97,39	98,69	98,37
Meyve bahçeleri	91,78	89,33	90,91	80,00	98,48	86,67	100,00	42,67
Zeytinlikler	93,27	95,59	90,53	95,14	97,67	99,43	93,20	99,21
İğne yapraklı ormanlar	100,00	99,45	100,00	100,00	99,45	100,00	99,45	100,00
Yoğun sklerofil bitki örtüsü	96,64	94,91	96,40	93,52	99,01	99,36	97,74	99,76
Seyrek sklerofil bitki örtüsü	95,03	97,14	92,20	97,11	99,34	99,15	99,24	98,02
Seyrek bitki alanları	97,02	96,47	94,12	93,16	99,55	99,89	94,81	100,00
Kayalar ve kumluklar	100,00	99,59	99,58	96,34	100,00	99,59	100,00	98,37
Su	100,00	100,00	99,88	100,00	100,00	100,00	100,00	100,00
Kıyı suları	100,00	100,00	100,00	99,50	100,00	100,00	100,00	100,00
Genel Doğruluk	95,92%		94,46%		99,17%		97,92%	
Kappa	0,949		0,931		0,990		0,974	
İşlem Süreleri (saniye):	Eğitim	496,57	0,15		106,98		295,71	
	Sınıflandırma	32,60	7,24		404,67		499,71	

Dioni 50% verisi için eğitilen algoritmalar tarafından oluşturulan sınıflandırma haritaları Şekil 4.7'de verilmiştir. Sınıflandırma sonuçları incelendiğinde sınıflandırma sonuçlarının 30% eğitim verisi ile kurulan modellerin sınıflandırma sonuçlarına yakın oldukları görülmektedir. Görüntünün sağında yer alan bulut ve gölgesinin ESA modelleri ile oluşturulan sınıflandırma haritalarında (Şekil 4.7d ve Şekil 4.7e) sırasıyla kayalar ve kumluklar ile su sınıflarına atandıkları görülmektedir.



Şekil 4.7 Dioni 50% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).


Dioni veri seti için üçüncü aşamada algoritmalar 70% eğitim verisi ile eğitildikten sonra yer doğrulama verisinin eğitim verisinden artı kalan 30%'lik test veri seti sınıflandırılarak hata matrisleri oluşturulmuştur (Ek 9, Ek 10, Ek 11 ve Ek 12). Bu hata matrislerinden hesaplanan genel doğruluk, kappa, üretici ve kullanıcı doğrulukları ek olarak işlem süreleri Çizelge 4.4'te verilmiştir. Tablodaki değerler incelendiğinde

99,48% genel doğruluk ile en başarılı algoritmanın 3B+2B ESA olduğu görülmektedir. Sınıf bazındaki doğruluklar incelendiğinde ise 3B+2B ESA'nın birkaç sınıf haricinde en yüksek üretici ve kullanıcı doğruluklarına sahip olduğu, iğne yapraklı ormanlar sınıfının tüm algoritmalar tarafından 100% doğrulukla sınıflandırıldığı ve su ile kıyı suları sınıflarına sahip test piksellerinin tamamının ESA modellerinde 100% doğrulukla sınıflandırıldıkları görülmektedir. İşlem süreleri açısından incelendiğinde RO algoritmasının eğitiminin ve tüm görüntünün sınıflandırılması aşamasında en hızlı algoritma olduğu açıkça görülmektedir.

Çizelge 4.4 Dioni 70% veri seti için algoritmaların performansları.

Sınıf Adı	DVM		RO		2B ESA		3B+2B ESA	
	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)
Sürekli şehir yapısı	93,58	88,39	91,35	83,64	99,74	99,47	99,73	98,68
Mineral çıkarım sahaları	98,31	95,08	100,00	85,25	100,00	98,36	100,00	100,00
Sulanmayan ekilebilir alanlar	91,21	90,22	95,93	89,67	98,91	98,37	98,90	97,28
Meyve bahçeleri	93,02	88,89	89,47	75,56	100,00	88,89	100,00	86,67
Zeytinlikler	93,25	96,23	90,81	94,92	98,69	99,62	97,60	99,62
İğne yapraklı ormanlar	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
Yoğun sklerofil bitki örtüsü	96,63	94,84	97,33	93,91	99,08	99,60	99,41	99,80
Seyrek sklerofil bitki örtüsü	95,27	97,02	92,84	97,70	99,53	99,22	99,69	99,53
Seyrek bitki alanları	97,16	97,72	95,74	94,11	99,62	100,00	100,00	99,81
Kayalar ve kumluklar	100,00	100,00	99,32	97,97	100,00	99,32	100,00	100,00
Su	99,79	100,00	99,79	100,00	100,00	100,00	100,00	100,00
Kıyı suları	100,00	99,16	100,00	99,16	100,00	100,00	100,00	100,00
Genel Doğruluk	96,04%		95,02%		99,42%		99,48%	
Kappa	0,951		0,938		0,993		0,994	
İşlem Süreleri (saniye):	Eğitim	956,67	0,19		133,54		405,49	
	Sınıflandırma	41,40	7,74		406,90		506,72	

Dioni 70% verisi için eğitilen algoritmalar tarafından oluşturulan sınıflandırma haritaları Şekil 4.8'de verilmiştir. Sınıflandırma sonuçları incelendiğinde sınıflandırma sonuçlarının 30% ve 50% eğitim verisi ile kurulan modellerin sınıflandırma sonuçlarına yakın oldukları görülmektedir.



Şekil 4.8 Dioni 70% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).

Her veri kümesi boyutu için algoritmaların arasındaki genel doğruluk farklarının anlamlı olup olmadıklarının test edilmesi için uygulanan McNemar's testi sonuçları Çizelge 4.5'te verilmiştir. Hesaplanan test sonuçları 95% güven aralığında $\chi^2=3,841$ değeriyle karşılaştırıldığında 70% veri kümesi ile eğitilen 2B ESA ile 3B+2B ESA arasındaki farkın χ^2 tablo değerinden düşük olduğu görülebilir. Dolayısıyla bu iki ESA modelinin 70% veri

seti ile eğitildiğinde sınıflandırma performansları arasında anlamlı bir farklılık olmadığını söylemek mümkündür.

Çizelge 4.5 Dioni veri seti için hesaplanan McNemar's testi sonuçları.

Model 1 - Model 2	30% Veri Kümesi Boyutu		50% Veri Kümesi Boyutu		70% Veri Kümesi Boyutu	
	χ^2_{mc}	Anlamlı mı?	χ^2_{mc}	Anlamlı mı?	χ^2_{mc}	Anlamlı mı?
DVM - RO	23,642	Evet	44,688	Evet	13,688	Evet
DVM - 2B ESA	366,330	Evet	255,420	Evet	170,730	Evet
DVM - 3B+2B ESA	414,430	Evet	75,002	Evet	177,560	Evet
RO - 2B ESA	499,290	Evet	401,890	Evet	241,850	Evet
RO - 3B+2B ESA	524,500	Evet	191,550	Evet	245,820	Evet
2B ESA - 3B+2B ESA	8,329	Evet	71,516	Evet	0,214	Hayır

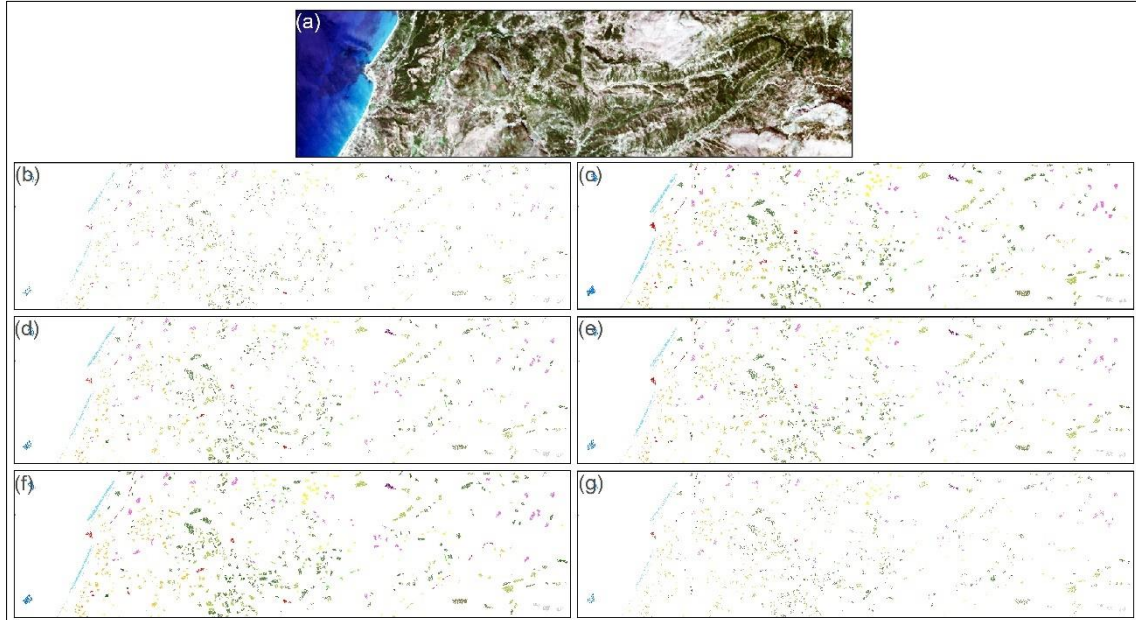
4.3 Loukia Veri Seti Sınıflandırma Sonuçları

Loukia veri setinin geleneksel MÖ ve DÖ algoritmaları ile sınıflandırılmasında eğitim veri kümesinin boyutu sırasıyla 30%, 50% ve 70% olarak seçilmiştir. Çizelge 4.6'da Loukia veri setinin sınıflara göre yer doğrulama verilerinin içerdiği etiketli veri sayısı, bunun yanında eğitim veri setinin boyutuna göre eğitim ve test için ayrılan etiketli verilerin dağılımları gösterilmiştir.

Çizelge 4.6 Loukia veri setinde sınıflar ve 30%-50%-70% eğitim veri kümesi oranlarına göre eğitim ve test için ayrılan etiketli veri sayıları.


Sınıf No	Sınıf Adı	Toplam	Oran n_i $\sum n$ (%)	30% Eğitim Veri Seti		50% Eğitim Veri Seti		70% Eğitim Veri Seti	
				Eğitim 30%	Test 70%	Eğitim 50%	Test 50%	Eğitim 70%	Test 30%
1	Sürekli şehir yapısı	288	2,1	86	202	144	144	202	86
2	Mineral çıkarım sahaları	67	0,5	20	47	34	33	47	20
3	Sulanmayan ekilebilir alanlar	542	4,0	163	379	271	271	379	163
4	Meyve bahçeleri	79	0,6	24	55	40	39	55	24
5	Zeytinlikler	1401	10,4	420	981	700	701	981	420
6	Geniş yapraklı ormanlar	223	1,7	67	156	112	111	156	67
7	İğne yapraklı ormanlar	500	3,7	150	350	250	250	350	150
8	Karışık ormanlar	1072	7,9	321	751	536	536	750	322
9	Yoğun sklerofil bitki örtüsü	3793	28,1	1138	2655	1896	1897	2655	1138
10	Seyrek sklerofil bitki örtüsü	2803	20,8	841	1962	1401	1402	1962	841
11	Seyrek bitki alanları	404	3,0	121	283	202	202	283	121
12	Kayalar ve kumluklar	487	3,6	146	341	243	244	341	146
13	Su	1393	10,3	418	975	696	697	975	418
14	Kıyı suları	451	3,3	135	316	226	225	316	135

Rastgele olarak ayrımı gerçekleştirilen eğitim ve test kümelerinin dağılımları Şekil 4.9’da gösterilmiştir.



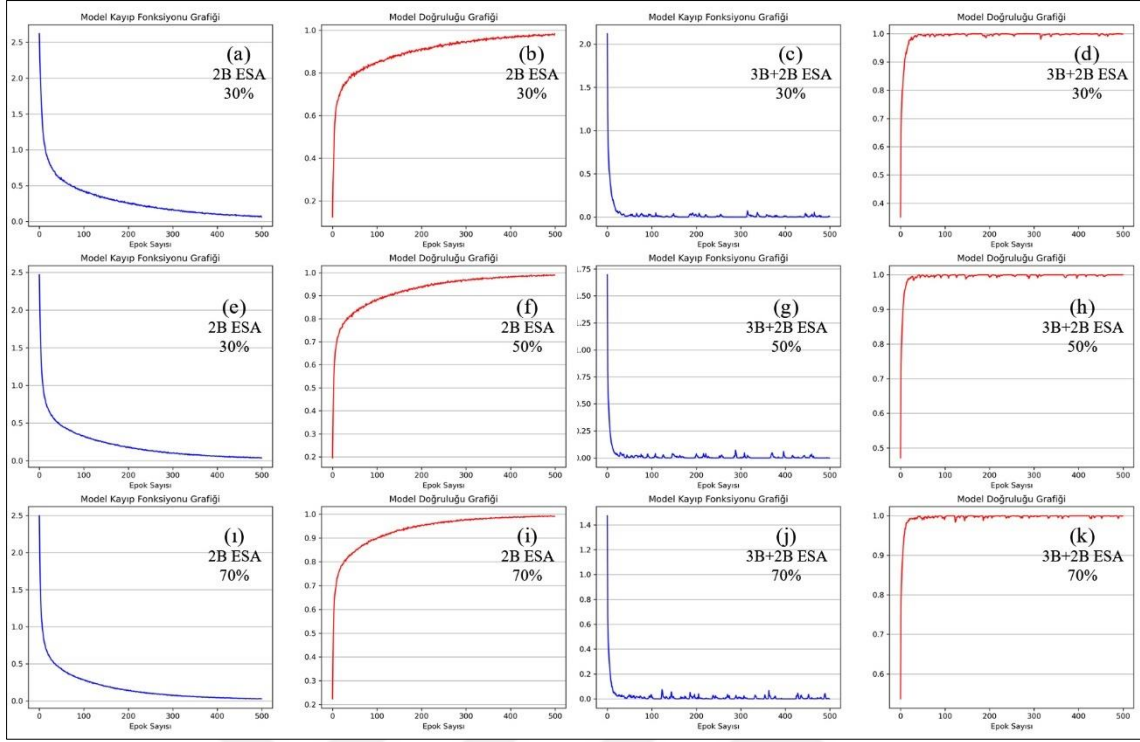
Şekil 4.9 Loukia veri seti (a) için eğitim-test piksellerinin sırasıyla 30%(b)-70%(c), 50%(d)-50%(e) ve 70%(f)-30%(g) dağılımları.

Loukia veri seti için DVM modelleri oluşturulurken RTF kernel fonksiyonu ile 30%, 50% ve 70% eğitim verisi küme boyutları için 5 katlamalı çapraz doğrulama işlemi ile optimum parametreler araştırılmıştır. Bütün veri küme boyutları için optimum parametreler $C=10$ ve $\gamma=0,1$ olarak belirlenmiştir. RO algoritmasında $m=4$ olarak belirlenirken N parametresi için her üç eğitim kümesi için öncül olarak 1000 karar ağacı ile modeller oluşturulmuştur. Öncül modellerin OOB hatalarını gösteren grafikler Şekil 4.10'da verilmiştir. OOB hatasının grafikleri incelendiğinde 30% (Şekil 4.10a, Şekil 4.3), 50% (Şekil 4.10b) ve 70% (Şekil 4.10c) eğitim veri küme boyutları için yaklaşık 150 karar ağacından sonra hata stabil olarak ilerlediği görülmüştür ve bu veri kümeleri ile asıl modeller kurulurken her üç RO modeli için de $N=150$ olarak seçilmiştir.



Şekil 4.10 Loukia veri seti için sırasıyla 30% (a), 50% (b) ve 70% (c) eğitim kümesi boyutlarına göre RO algoritmasının OOB hataları.

ESA modellerinin eğitimi aşamasında her iki ESA modeli ve bütün eğitim veri kümesi boyutları için yığın boyutu 256 ve epok sayısı 500 olarak belirlenmiştir. Şekil 4.11'de her iki ESA modelinin farklı eğitim veri kümesi boyutlarına göre kayıp fonksiyonu ve model doğruluğu grafikleri verilmiştir. 2B ESA modellerinin tüm veri kümesi boyutları için kayıp fonksiyonu grafikleri incelendiğinde (Şekil 4.11a, Şekil 4.11e ve Şekil 4.11i) hataların düzenli olarak azaldığı ancak 400'lerden sonraki epoklarda sifira yaklaştığı görülmektedir. 3B+2B ESA modellerinin kayıp fonksiyonu grafiklerinin (Şekil 4.11c, Şekil 4.11g ve Şekil 4.11j) birkaç on epok sonunda hızlıca düştükleri görülmektedir.



Şekil 4.11 Loukia veri setinin sınıflandırılması için 30%, 50% ve 70% eğitim verisi ile oluşturulan ESA modellerinin kayıp fonksiyonu ve model doğruluğu grafikleri.


Veri seti için ilk aşamada algoritmalar 30% eğitim verisi ile eğitildikten sonra yer doğrulama verisinin eğitim verisinden artı kalan 70%'lik test veri seti ile hata matrisleri oluşturulmuştur (Ek 13, Ek 14, Ek 15 ve Ek 16). Bu hata matrislerinden hesaplanan genel doğruluk, kappa, üretici ve kullanıcı doğrulukları ek olarak işlem süreleri Çizelge 4.7'de verilmiştir. Tablodaki değerler incelendiğinde 93,97% genel doğruluk ile en başarılı algoritmanın 3B+2B ESA olduğu görülmektedir. Sınıf bazındaki doğruluklar incelendiğinde ise 3B+2B ESA'nın üç sınıf için 100% doğruluğa sahip olduğu ve diğer sekiz sınıf için algoritmalar arasındaki en yüksek üretici ve kullanıcı doğruluklarına sahip olduğu görülmüştür. 2B ESA'nın ise sınıf bazındaki doğruluk ölçütlerine ve genel doğruluğa göre ikinci en başarılı algoritma olduğu görülmektedir. Üretici ve kullanıcı doğrulukları birlikte incelendiğinde DVM ve RO modelleri geniş yapraklı ormanlar ve karışık ormanlar sınıfları için diğer modellerden düşük doğruluğa sahiptir. Kullanıcı doğrulukları incelendiğinde ise RO modelinde meyve bahçeleri ve geniş yapraklı ormanlar sınıfları için üretici doğruluğuna göre çok daha düşük doğruluğa sahip olduğu görülmüştür. İşlem süreleri açısından incelendiğinde RO algoritmasının eğitiminin ve

tüm görüntünün sınıflandırılması aşamasında en hızlı algoritma olduğu açıkça görülmektedir.

Çizelge 4.7 Loukia 30% veri seti için algoritmaların performansları.

Sınıf Adı	DVM		RO		2B ESA		3B+2B ESA	
	Ür. D. (%)	Knl. D. (%)	Ür. D. (%)	Knl. D. (%)	Ür. D. (%)	Knl. D. (%)	Ür. D. (%)	Knl. D. (%)
Sürekli şehir yapısı	86,44	75,74	90,21	63,86	92,55	86,14	94,30	90,10
Mineral çıkarım sahaları	100,00	70,21	100,00	85,11	100,00	97,87	100,00	100,00
Sulanmayan ekilebilir alanlar	88,92	91,03	90,98	87,86	92,13	95,78	98,58	91,56
Meyve bahçeleri	86,49	58,18	96,30	47,27	77,55	69,09	90,20	83,64
Zeytinlikler	94,09	92,56	90,86	90,21	95,04	95,72	95,86	96,74
Geniş yapraklı ormanlar	75,00	57,69	90,43	54,49	92,11	67,31	93,08	77,56
İğne yapraklı ormanlar	84,01	70,57	87,50	64,00	91,33	78,29	97,29	82,00
Karışık ormanlar	72,87	67,24	73,81	66,05	88,04	89,21	89,94	94,01
Yoğun sklerofil bitki örtüsü	79,48	86,37	78,36	87,27	89,02	92,54	91,28	93,79
Seyrek sklerofil bitki örtüsü	85,79	85,88	82,50	87,92	91,39	90,93	92,17	92,35
Seyrek bitki alanları	87,77	86,22	93,10	66,78	94,35	94,35	94,50	97,17
Kayalar ve kumluklar	96,04	92,38	90,86	90,32	99,39	95,31	98,80	96,77
Su	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
Kıyı suları	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
Genel Doğruluk	86.12%		85.14%		92.38%		93,97%	
Kappa	0,834		0,822		0,909		0,928	
İşlem Süreleri (saniye):	Eğitim	94,37	0,09		65,04		172,13	
	Sınıflandırma	18,01	5,39		268,04		341,95	

Loukia 30% verisi için eğitilen algoritmalar tarafından oluşturulan sınıflandırma haritaları Şekil 4.12’de verilmiştir. Sınıflandırma sonuçları incelendiğinde DVM modelinin sınıflandırma haritası için görüntünün sol tarafında yer alan denizde kıyı suları ile su sınıflarının kesiştiği bölgede hatalı sınıflandırılan piksellerin olduğu görülmektedir. Ayrıca DVM ve RO modellerin sınıflandırma haritalarında ESA modellerinin sınıflandırma haritalarına göre daha yoğun miktarda tuz-biber etkisi görülmektedir. Bunun yanında mineral çıkarım sahalarının şekilsel olarak çıkarımı diğer modellere göre daha yetersizdir.



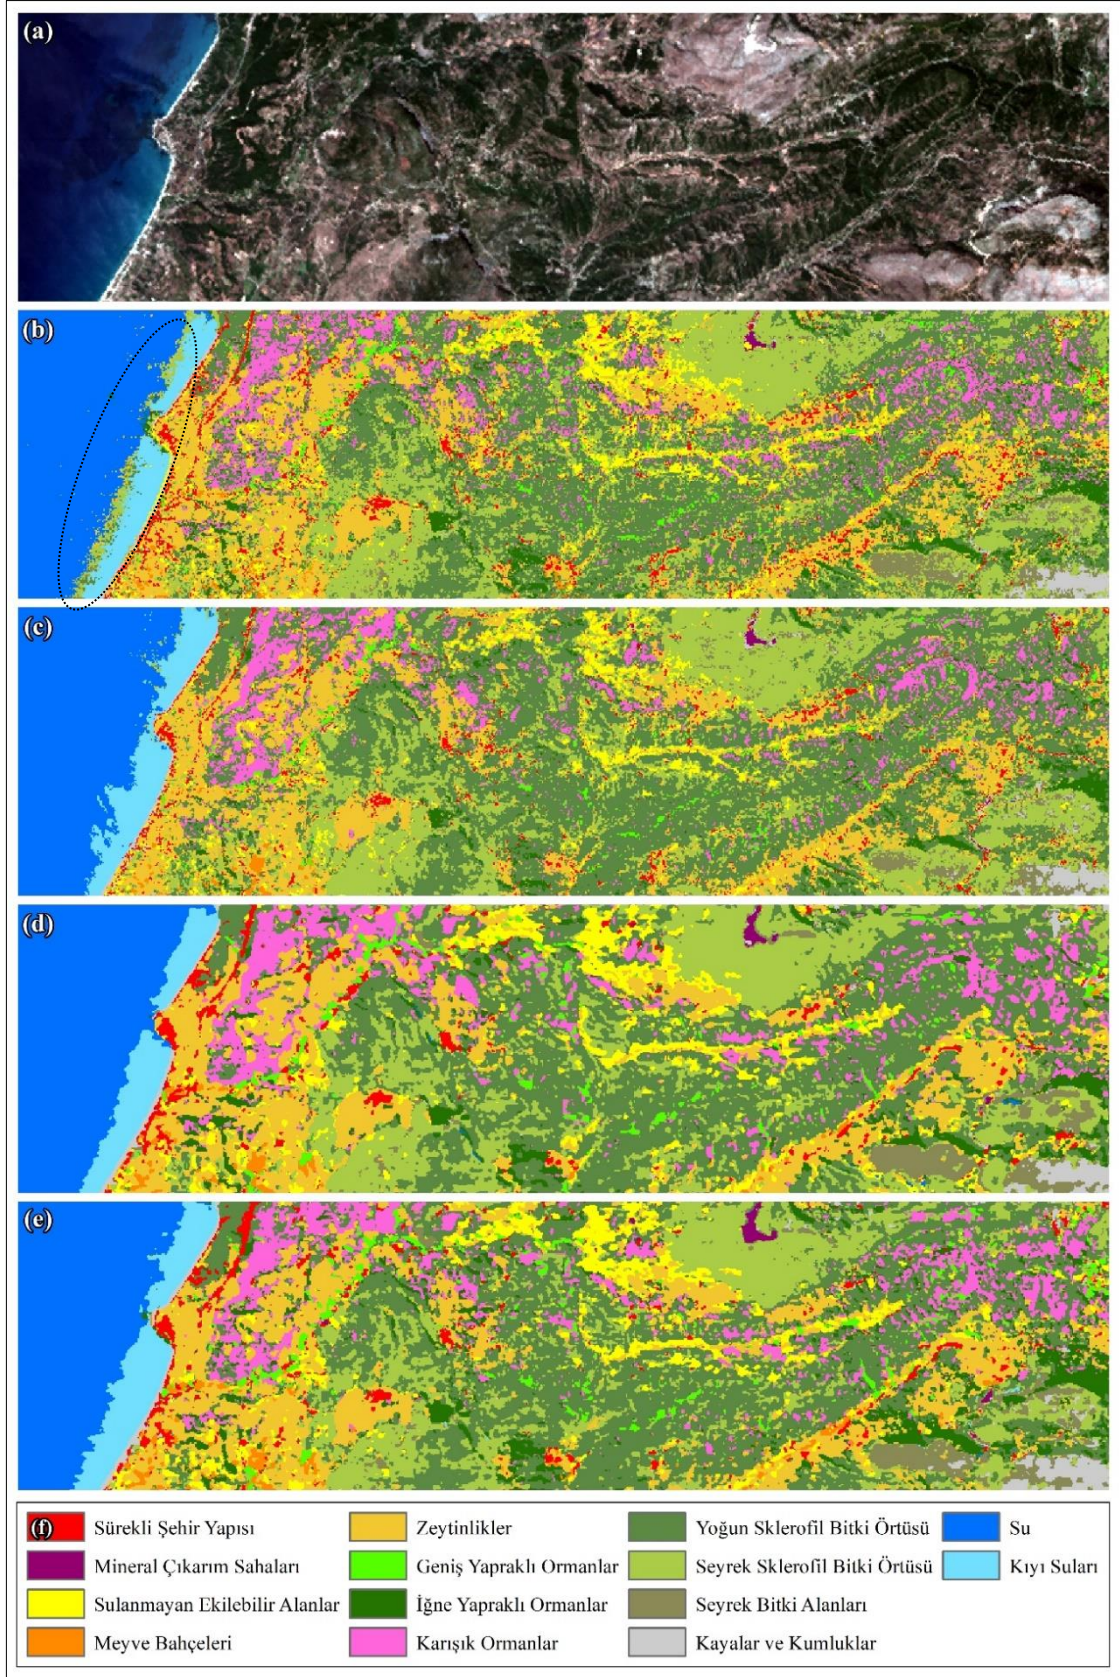
Şekil 4.12 Loukia 30% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).

Veri seti için ikinci aşamada algoritmalar 50% eğitim verisi ile eğitildikten sonra yer doğrulama verisinin eğitim verisinden artı kalan 50%'lik test veri seti ile hata matrisleri oluşturulmuştur (Ek 17, Ek 18, Ek 19 ve Ek 20). Bu hata matrislerinden hesaplanan genel doğruluk, kappa, üretici ve kullanıcı doğrulukları ek olarak işlem süreleri Çizelge 4.8'de verilmiştir. Tablodaki değerler incelendiğinde 96,73% genel doğruluk ile en başarılı algoritmanın 3B+2B ESA olduğu görülmektedir. Sınıf bazındaki doğruluklar incelendiğinde 30% veri seti ile eğitilen 3B+2B ESA modelinde olduğu gibi mineral çıkarım sahaları, su ve kıyı suları sınıflarının 100% doğruluğa sahip oldukları görülürken altı sınıfta 3B+2B ESA ile sınıflandırmadaki üretici ve kullanıcı doğruluklarının en yüksek olduğu görüşmüştür. 2B ESA ise sınıf bazındaki doğruluk ölçütlerine ve genel doğruluğa göre ikinci en başarılı algoritmadır. Meyve bahçeleri sınıfı için kullanıcı doğruluğunun düşük olması durumu DVM ve RO modellerinin yanında 2B ESA için de geçerlidir. İşlem süreleri açısından incelendiğinde RO algoritmasının eğitiminin ve tüm görüntünün sınıflandırılması aşamasında en hızlı algoritma olduğu açıkça görülmektedir.

Çizelge 4.8 Loukia 50% veri seti için algoritmaların performansları.

Sınıf Adı	DVM		RO		2B ESA		3B+2B ESA	
	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)
Sürekli şehir yapısı	86,03	81,25	92,16	65,28	98,44	87,50	97,79	92,36
Mineral çıkarım sahaları	100,00	84,85	96,67	87,88	100,00	96,97	100,00	100,00
Sulanmayan ekilebilir alanlar	94,81	94,46	92,42	90,04	94,22	96,31	98,14	97,42
Meyve bahçeleri	96,30	66,67	94,74	46,15	93,10	69,23	88,57	79,49
Zeytinlikler	93,35	96,15	90,15	92,72	95,51	97,00	97,05	98,43
Geniş yapraklı ormanlar	80,20	72,97	87,65	63,96	93,94	83,78	97,14	91,89
İğne yapraklı ormanlar	87,96	76,00	86,93	69,20	97,74	86,40	92,83	93,20
Karışık ormanlar	75,67	73,69	77,63	66,04	92,07	93,10	96,79	95,71
Yoğun sklerofil bitki örtüsü	82,13	86,24	79,36	89,40	92,67	94,57	95,14	97,05
Seyrek sklerofil bitki örtüsü	87,91	86,59	86,44	87,73	94,00	94,94	96,72	94,72
Seyrek bitki alanları	91,84	89,11	92,07	74,75	96,06	96,53	96,62	99,01
Kayalar ve kumluklar	97,07	95,08	94,02	90,16	99,57	95,90	98,37	98,77
Su	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
Kıyı suları	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
Genel Doğruluk	88,13%		86,67%		94,93%		96,73%	
Kappa	0,859		0,840		0,940		0,961	
İşlem Süreleri (saniye):	Eğitim	254,88	0,11		85,33		231,78	
	Sınıflandırma	26,41	5,53		288,92		352,57	

Loukia 50% verisi için eğitilen algoritmalar tarafından oluşturulan sınıflandırma haritaları Şekil 4.13'te verilmiştir. Sınıflandırma sonuçları incelendiğinde 30% veri kümesiyle eğitilen RO modelinin sınıflandırma haritasında olduğu gibi 50% eğitim verisiyle eğitilen RO modelinin sınıflandırma haritasında da denizdeki kıyı suları ile su sınıflarının kesiştiği bölgede hatalı sınıflandırılan piksellerin olduğu görülmektedir.




Şekil 4.13 Loukia 50% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).

Veri seti için üçüncü aşamada algoritmalar 70% eğitim verisi ile eğitildikten sonra yer doğrulama verisinin eğitim verisinden artı kalan 30%'luk test veri seti ile hata matrisleri oluşturulmuştur (Ek 21, Ek 22, Ek 23 ve Ek 24). Bu hata matrislerinden hesaplanan genel doğruluk, kappa, üretici ve kullanıcı doğrulukları ek olarak işlem süreleri Çizelge 4.9'da verilmiştir. Tablodaki değerler incelendiğinde 97,40% genel doğruluk ile en başarılı algoritmanın 3B+2B ESA olduğu görülmektedir. Sınıf bazındaki doğruluklar incelendiğinde ise 3B+2B ESA'nın iğne yapraklı ormanlar sınıfı haricinde en yüksek üretici ve kullanıcı doğruluklarına sahip olduğu, 2B ESA'nın ise sınıf bazındaki doğruluk ölçütlerine ve genel doğruluğa göre ikinci en başarılı algoritma olduğu görülmektedir. Meyve bahçeleri sınıfının kullanıcı doğruluğunun en düşük RO modeli için olmak üzere tüm modellerde diğer sınıflardan düşük olduğu görülmüştür. Bunun yanında geniş ve iğne yapraklı ormanlar sınıfları için MÖ modelleri ESA modellerinden daha düşük sınıflandırma performansına sahiptir. İşlem süreleri açısından incelendiğinde RO algoritmasının eğitiminin ve tüm görüntünün sınıflandırılması aşamasında en hızlı algoritma olduğu açıkça görülmektedir.

Çizelge 4.9 Loukia 70% veri seti için algoritmaların performansları.

Sınıf Adı	DVM		RO		2B ESA		3B+2B ESA	
	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)
Sürekli şehir yapısı	95,00	88,37	88,24	69,77	96,55	97,67	98,80	95,35
Mineral çıkarım sahaları	100,00	95,00	100,00	95,00	100,00	100,00	100,00	100,00
Sulanmayan ekilebilir alanlar	96,27	95,09	93,46	87,73	98,76	97,55	95,86	99,39
Meyve bahçeleri	100,00	75,00	100,00	54,17	100,00	79,17	100,00	79,17
Zeytinlikler	94,69	97,62	91,71	94,76	97,87	98,33	98,35	99,05
Geniş yapraklı ormanlar	86,89	79,10	89,13	61,19	91,18	92,54	95,38	92,54
İğne yapraklı ormanlar	84,03	80,67	88,14	69,33	97,86	91,33	97,84	90,67
Karışık ormanlar	77,88	79,81	81,63	71,74	95,41	96,89	98,11	96,89
Yoğun sklerofil bitki örtüsü	84,29	86,29	80,17	89,19	94,79	95,96	96,24	96,75
Seyrek sklerofil bitki örtüsü	88,94	87,04	86,02	87,04	95,58	95,12	96,24	97,27
Seyrek bitki alanları	95,80	94,21	98,04	82,64	99,17	98,35	99,17	98,35
Kayalar ve kumluklar	98,62	97,95	97,24	96,58	100,00	99,32	98,65	100,00
Su	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
Kıyı suları	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
Genel Doğruluk	89,68%		87,63%		96,64%		97,40%	
Kappa	0,887		0,852		0,960		0,969	
İşlem Süreleri (saniye):	Eğitim	484,65	0,14		98,92		283,21	
	Sınıflandırma	34,16	5,71		287,25		347,44	

Loukia 70% verisi için eğitilen algoritmalar tarafından oluşturulan sınıflandırma haritaları Şekil 4.14'te verilmiştir. Sınıflandırma sonuçları incelendiğinde RO modeli için su ve kıyı suları sınıflarındaki yanlış sınıflandırmalar gözle görülür şekilde devam etmiştir. Ancak 3B+2B ESA modelinde söz konusu sınıflar için üretici ve kullanıcı doğrulukları 100% çıkmasına rağmen gözle fark edilir şekilde hatalı sınıflandırmalar meydana gelmiştir (Şekil 4.14e).



Şekil 4.14 Loukia 70% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).

Her veri kümesi boyutu için algoritmaların arasındaki genel doğruluk farklarının anlamlı olup olmadıklarının test edilmesi için uygulanan McNemar's testi sonuçları Çizelge 4.10'da verilmiştir. Hesaplanan test sonuçları 95% güven aralığında $\chi^2=3,841$ değeriyle karşılaştırıldığında bütün veri kümesi boyutlarında algoritmaların sınıflandırma performansları aralarındaki farkların anlamlı olduğu görülmektedir.

Çizelge 4.10 Loukia veri seti için hesaplanan McNemar's testi sonuçları.

Model 1 - Model 2	30% Veri Kümesi Boyutu		50% Veri Kümesi Boyutu		70% Veri Kümesi Boyutu	
	χ^2_{mc}	Anlamlı mı?	χ^2_{mc}	Anlamlı mı?	χ^2_{mc}	Anlamlı mı?
DVM - RO	7,094	Evet	12,721	Evet	15,821	Evet
DVM - 2B ESA	282,133	Evet	277,833	Evet	192,588	Evet
DVM - 3B+2B ESA	420,430	Evet	426,515	Evet	239,174	Evet
RO - 2B ESA	365,227	Evet	381,141	Evet	277,769	Evet
RO - 3B+2B ESA	497,892	Evet	531,427	Evet	326,412	Evet
2B ESA - 3B+2B ESA	36,158	Evet	47,841	Evet	8,108	Evet

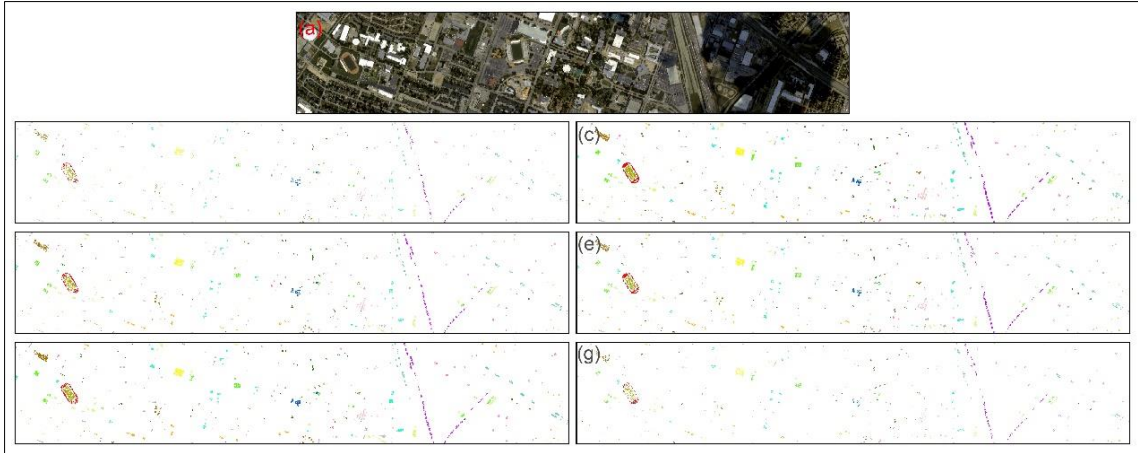
4.4 DFC13 Veri Seti Sınıflandırma Sonuçları

DFC13 veri setinin geleneksel MÖ ve DÖ algoritmaları ile sınıflandırılmasında eğitim veri kümesinin boyutu sırasıyla 30%, 50% ve 70% olarak seçilmiştir. Çizelge 4.11'de DFC13 veri setinin içerdiği 15 yer sınıfına göre yer doğrulama verilerinin içerdiği etiketli veri sayıları, bunun yanında eğitim veri setinin boyutuna göre eğitim ve test için ayrılan etiketli verilerin dağılımları gösterilmiştir.

Çizelge 4.11 DFC13 veri setinde sınıflar ve 30%-50%-70% eğitim veri kümesi oranlarına göre eğitim ve test için ayrılan etiketli veri sayıları.

Sınıf No	Sınıf Adı	Toplam	Oran $\frac{n_i}{\sum n}$ (%)	30% Eğitim Veri Seti		50% Eğitim Veri Seti		70% Eğitim Veri Seti	
				Eğitim 30%	Test 70%	Eğitim 50%	Test 50%	Eğitim 70%	Test 30%
1	Sağlıklı çimen	1374	8,0	412	962	687	687	962	412
2	Yıpranmış çimen	1454	8,4	436	1018	727	727	1018	436
3	Sentetik çimen	795	4,6	239	556	398	397	556	239
4	Ağaç	1264	7,3	379	885	632	632	885	379
5	Toprak	1298	7,5	389	909	649	649	909	389
6	Su	339	2,0	102	237	169	170	237	102
7	Ticari Yapı	1476	8,5	443	1033	738	738	1033	443
8	Konut	1354	7,8	406	948	677	677	948	406
9	Yol	1554	9,0	466	1088	777	777	1088	466
10	Otoyol	1424	8,2	427	997	712	712	997	427
11	Tren yolu	1566	9,1	470	1096	783	783	1096	470
12	Park alanı 1	1429	8,3	429	1000	714	715	1000	429
13	Park alanı 2	635	3,7	191	444	318	317	444	191
14	Tenis Kortu	510	3,0	153	357	255	255	357	153
15	Koşu Pisti	798	4,6	239	559	399	399	559	239


Rastgele olarak ayrımı gerçekleştirilen eğitim ve test kümelerinin dağılımları Şekil 4.15'te gösterilmiştir.



Şekil 4.15 DFC13 veri seti (a) için eğitim-test piksellerinin sırasıyla 30%(b)-70%(c), 50%(d)-50%(e) ve 70%(f)-30%(g) dağılımları.

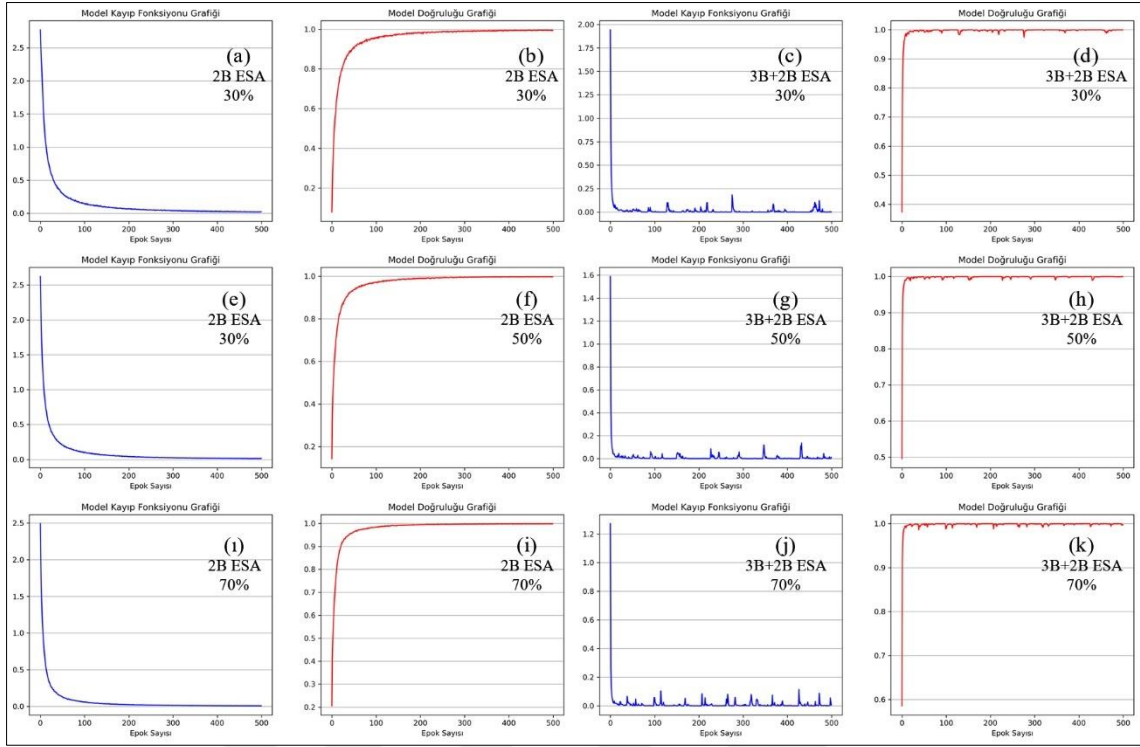
DFC13 veri seti için DVM modelleri oluşturulurken RTF kernel fonksiyonu ile 30%, 50% ve 70% eğitim verisi küme boyutları için 5 katlamalı çapraz doğrulama işlemi ile

optimum parametreler araştırılmıştır. Bütün veri küme boyutları için optimum parametreler $C=100$ ve $\gamma=0,1$ olarak belirlenmiştir. RO algoritmasında $m=4$ olarak belirlenirken N parametresi için her üç eğitim kümesi için öncül olarak 1000 karar ağacı ile modeller oluşturulmuştur. Öncül modellerin OOB hatalarını gösteren grafikler Şekil 4.16 Şekil 4.10'da verilmiştir. OOB hatasının grafikleri incelendiğinde 30% (Şekil 4.16a), 50% (Şekil 4.16b) ve 70% (Şekil 4.16c) eğitim veri küme boyutları için yaklaşık 150 karar ağacından sonra hata stabil olarak ilerlediği görülmüştür ve bu veri kümeleri ile asıl modeller kurulurken her üç RO modeli için de $N=150$ olarak seçilmiştir.



Şekil 4.16 DFC13 veri seti için sırasıyla 30% (a), 50% (b) ve 70% (c) eğitim kümesi boyutlarına göre RO algoritmasının OOB hataları.

ESA modellerinin eğitimi aşamasında her iki ESA modeli ve bütün eğitim veri kümesi boyutları için yığın boyutu 256 ve epok sayısı 500 olarak belirlenmiştir. Şekil 4.17'de her iki ESA modelinin farklı eğitim veri kümesi boyutlarına göre kayıp fonksiyonu ve model doğruluğu grafikleri verilmiştir. 2B ESA modellerinin tüm veri kümesi boyutları için kayıp fonksiyonu grafikleri incelendiğinde (Şekil 4.17a, Şekil 4.17e ve Şekil 4.17i) hataların düzenli olarak düştüğü ve Loukia veri setine göre (Şekil 4.11) daha az epok tekrarında sifıra yaklaştığı görülmektedir. 3B+2B ESA modellerinin kayıp fonksiyonu grafiklerinin (Şekil 4.17c, Şekil 4.17g ve Şekil 4.17j) birkaç epok sonunda hızlıca düştükleri, ilerleyen epokların bazılarında anlık sıçramalar ile hataların maksimum 0,1 civarına yükselip geri düştükleri görülmektedir.



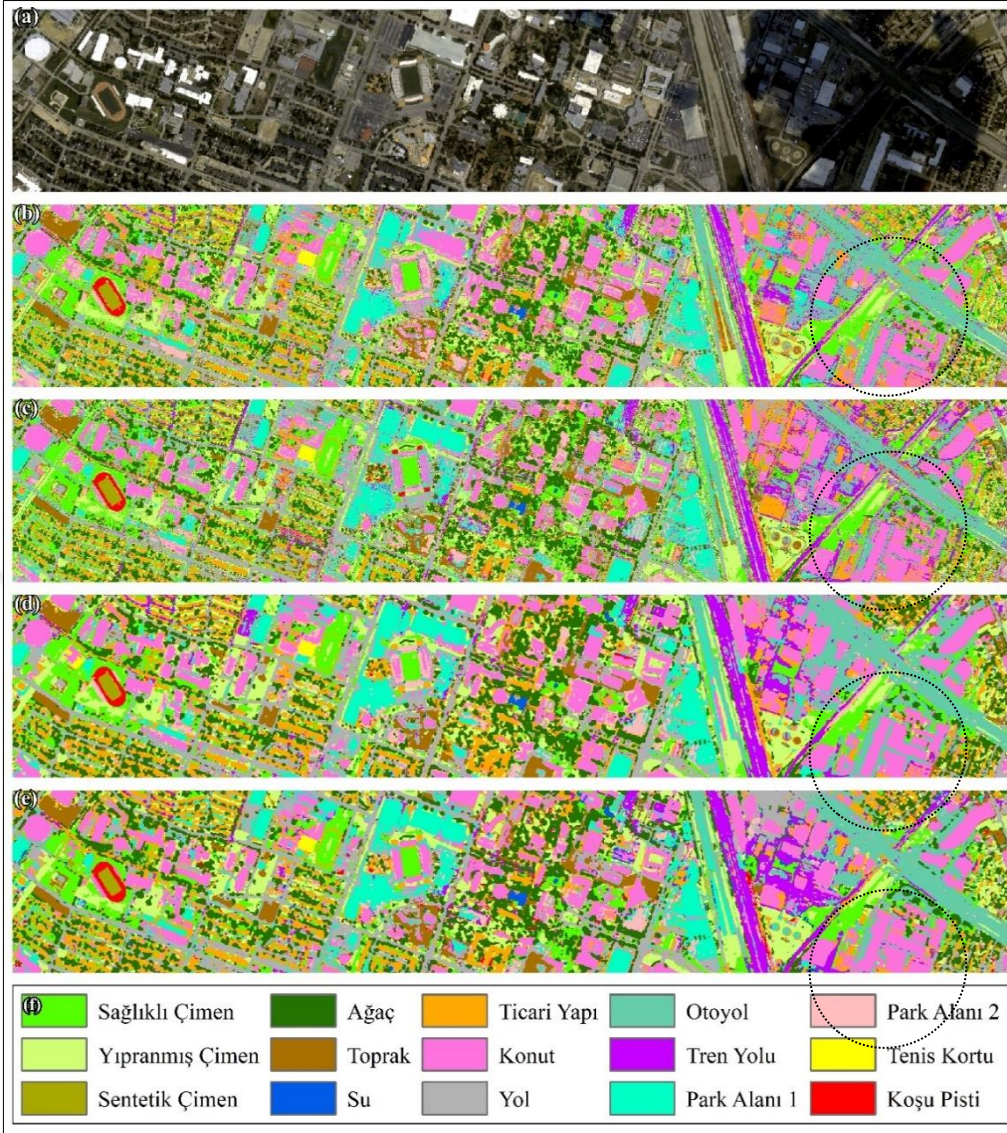
Şekil 4.17 DFC13 veri setinin sınıflandırılması için 30%, 50% ve 70% eğitim verisi ile oluşturulan ESA modellerinin kayıp fonksiyonu ve model doğruluğu grafikleri.

Veri seti için ilk aşamada algoritmalar 30% eğitim verisi ile eğitildikten sonra yer doğrulama verisinin eğitim verisinden artı kalan 70%'lik test veri seti ile hata matrisleri oluşturulmuştur (Ek 25, Ek 26, Ek 27 ve Ek 28). Bu hata matrislerinden hesaplanan genel doğruluk, kappa, üretici ve kullanıcı doğrulukları ek olarak işlem süreleri Çizelge 4.12'de verilmiştir. Tablodaki değerler incelendiğinde 99,67% genel doğruluk ile en başarılı algoritmanın 3B+2B ESA olduğu görülmektedir. Sınıf bazındaki doğruluklar incelendiğinde ise 3B+2B ESA'nın dört sınıf için 100% doğruluğa sahip olduğu ve diğer dört sınıf için algoritmalar arasındaki en yüksek üretici ve kullanıcı doğruluklarına sahip olduğu görülmüştür. 2B ESA'nın ise sınıf bazındaki doğruluk ölçütlerine ve genel doğruluğa göre ikinci en başarılı algoritma olduğu görülmektedir. İşlem süreleri açısından incelendiğinde RO algoritmasının eğitiminin ve tüm görüntünün sınıflandırılması aşamasında en hızlı algoritmadır.

Çizelge 4.12 DFC13 30% veri seti için algoritmaların performansları.

Sınıf Adı	DVM		RO		2B ESA		3B+2B ESA	
	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)
Sağlıklı çimen	98,36	99,79	98,16	99,79	99,48	100,00	99,59	100,00
Yıpranmış çimen	99,70	99,12	98,82	98,82	99,90	99,51	99,90	99,61
Sentetik çimen	100,00	100,00	100,00	99,46	100,00	100,00	100,00	100,00
Ağaç	99,55	99,21	99,66	98,42	100,00	100,00	99,44	100,00
Toprak	99,67	99,56	97,93	99,12	99,89	100,00	100,00	100,00
Su	100,00	99,58	100,00	99,58	100,00	100,00	100,00	100,00
Ticari Yapı	96,26	97,19	94,48	97,68	98,38	99,81	99,13	98,84
Konut	95,55	97,47	97,97	96,52	100,00	99,05	100,00	100,00
Yol	94,89	97,33	92,82	93,84	99,45	99,08	99,72	99,54
Otoyol	96,19	96,29	94,58	94,58	99,01	100,00	99,70	100,00
Tren yolu	97,21	95,53	94,73	95,07	99,91	99,27	100,00	99,91
Park alanı 1	94,38	95,80	89,90	94,30	99,30	99,80	99,10	99,60
Park alanı 2	87,50	77,25	91,33	71,17	99,07	95,95	99,54	97,07
Tenis Kortu	99,17	100,00	97,01	100,00	99,17	100,00	99,16	99,72
Koşu Pisti	100,00	98,57	100,00	98,03	100,00	99,82	99,82	100,00
Genel Doğruluk	97,17%		96,13%		99,55%		99,67%	
Kappa	0,969		0,958		0,995		0,996	
İşlem Süreleri (saniye):	Eğitim	125,68	0,26		75,04		197,23	
	Sınıflandırma	26,60	14,79		784,37		951,52	

DFC13 30% verisi için eğitilen algoritmalar tarafından oluşturulan sınıflandırma haritaları Şekil 4.18’de verilmiştir. Sınıflandırma sonuçları incelendiğinde RO ve DVM modellerinin sınıflandırma haritalarında nesnelere çıkarımında daha fazla tuz-biber etkisi görülmektedir. Tüm modelleri için değerlendirme yapılacak olursa gölge etkisinde olmayan alanlarda iyi bir sınıflandırma performansı yakalanmıştır. Bulut gölgesinde kalan alanda bütün modellerin bina çıkarımlarını daha belirgin şekilde doğru yaptığı görülürken bulut binaların arasında kalan bölgenin otoyol ve tren yolu olarak yanlış sınıflandırıldığı görülmektedir.



Şekil 4.18 DFC13 30% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejanti (f).

Veri seti için ikinci aşamada algoritmalar 50% eğitim verisi ile eğitildikten sonra yer doğrulama verisinin eğitim verisinden artı kalan 50%'lik test veri seti ile hata matrisleri oluşturulmuştur (Ek 29, Ek 30, Ek 31 ve Ek 32). Bu hata matrislerinden hesaplanan genel doğruluk, kappa, üretici ve kullanıcı doğrulukları ek olarak işlem süreleri Çizelge 4.13'te verilmiştir. Tablodaki değerler incelendiğinde 99,86% genel doğruluk ile en başarılı algoritmanın 3B+2B ESA olduğu görülmektedir. Sınıf bazındaki doğruluklar incelendiğinde ise 3B+2B ESA'nın altı sınıf için 100% doğruluğa sahip olduğu ve diğer iki sınıf için algoritmalar arasındaki en yüksek üretici ve kullanıcı doğruluklarına sahip

olduğu görülmüştür. 2B ESA'nın ise sınıf bazındaki doğruluk ölçütlerine ve genel doğruluğa göre ikinci en başarılı algoritma olduğu görülmektedir. İşlem süreleri açısından incelendiğinde RO algoritmasının eğitiminin ve tüm görüntünün sınıflandırılması aşamasında en hızlı algoritma olduğu açıkça görülmektedir.

Çizelge 4.13 DFC13 50% veri seti için algoritmaların performansları.

Sınıf Adı	DVM		RO		2B ESA		3B+2B ESA	
	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)
Sağlıklı çimen	98,71	99,85	97,31	100,00	99,28	100,00	99,85	100,00
Yıpranmış çimen	99,59	99,04	99,03	98,35	99,86	99,31	100,00	99,86
Sentetik çimen	100,00	100,00	100,00	99,50	100,00	100,00	100,00	100,00
Ağaç	99,68	99,53	100,00	98,26	100,00	100,00	99,53	100,00
Toprak	99,85	99,38	99,08	99,23	100,00	100,00	100,00	100,00
Su	100,00	99,41	100,00	99,41	100,00	100,00	100,00	100,00
Ticari Yapı	97,57	98,10	95,65	98,24	99,46	100,00	100,00	99,46
Konut	96,92	97,49	98,05	96,60	100,00	100,00	100,00	100,00
Yol	97,07	97,94	94,30	95,75	99,74	99,49	99,87	99,87
Otoyol	97,50	98,46	95,79	95,79	99,44	100,00	100,00	100,00
Tren yolu	97,83	98,08	95,81	96,42	100,00	99,74	99,87	100,00
Park alanı 1	94,17	97,20	90,72	95,66	99,72	99,72	99,86	99,86
Park alanı 2	92,25	78,86	93,60	73,82	100,00	98,11	99,05	99,05
Tenis Kortu	99,22	99,61	97,33	100,00	99,22	100,00	99,22	99,22
Koşu Pisti	100,00	99,75	99,74	97,99	100,00	99,75	100,00	100,00
Genel Doğruluk	97,94%		96,75%		99,77%		99,86%	
Kappa	0,978		0,965		0,977		0,998	
İşlem Süreleri (saniye):	Eğitim	335,22	0,30		95,87		271,98	
	Sınıflandırma	35,24	15,05		815,61		981,09	

DFC13 50% verisi için eğitilen algoritmalar tarafından oluşturulan sınıflandırma haritaları Şekil 4.19'da verilmiştir. Sınıflandırma sonuçları incelendiğinde özellikle RO ve ESA modellerinin sınıflandırma haritalarında (Şekil 4.19c, Şekil 4.19d ve Şekil 4.19e) gölge alana denk gelen bölgede binaların aralarında kalan alanların otoyol ve tren yolu olarak bariz bir şekilde yanlış sınıflandırıldıkları görülmektedir.



Şekil 4.19 DFC13 50% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejanti (f).

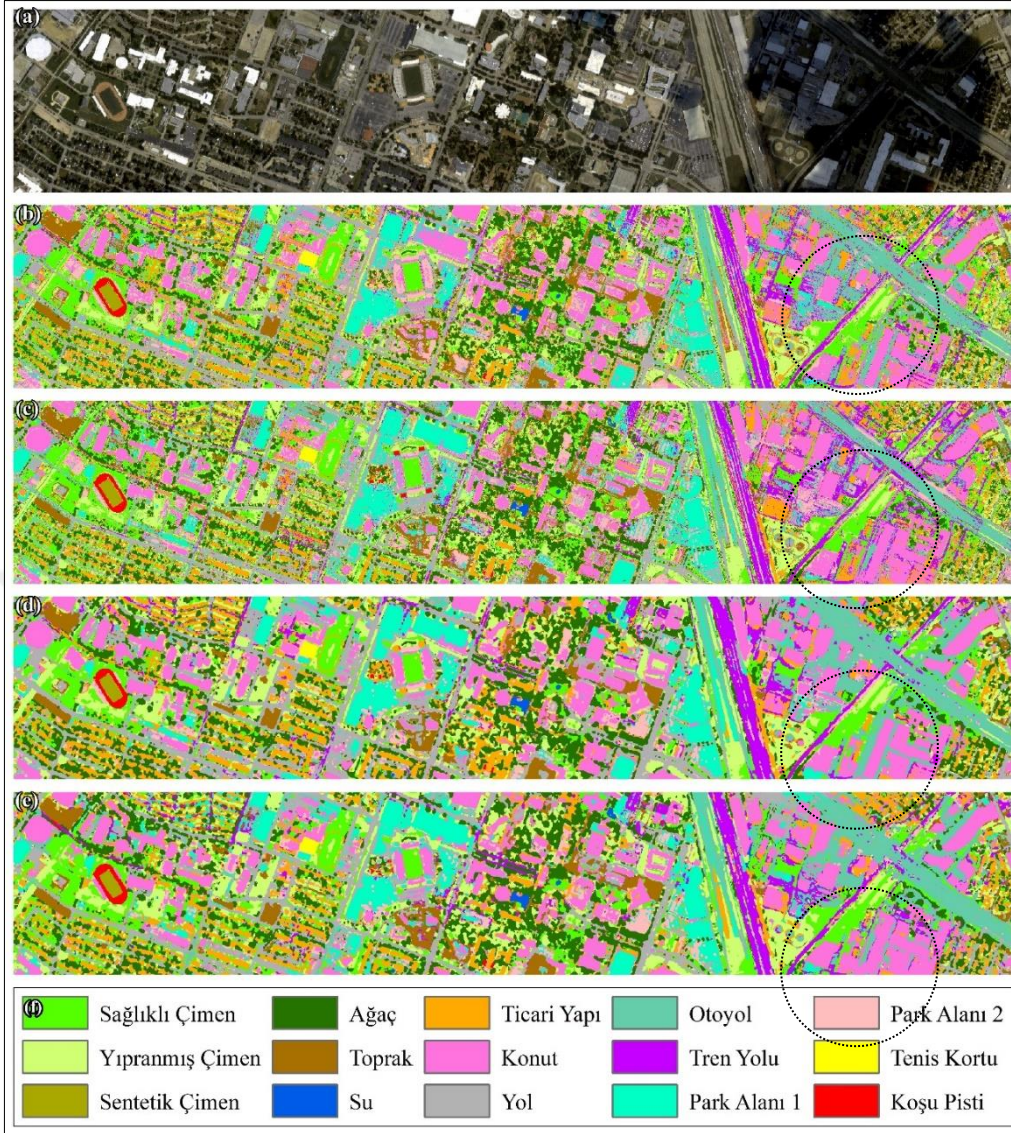
Veri seti için üçüncü aşamada algoritmalar 70% eğitim verisi ile eğitildikten sonra yer doğrulama verisinin eğitim verisinden artı kalan 30%'luk test veri seti ile hata matrisleri oluşturulmuştur (Ek 33, Ek 34, Ek 35 ve Ek 36). Bu hata matrislerinden hesaplanan genel doğruluk, kappa, üretici ve kullanıcı doğrulukları ek olarak işlem süreleri Çizelge 4.14'de verilmiştir. Tablodaki değerler incelendiğinde 99,92% genel doğruluk ile en başarılı algoritmanın 3B+2B ESA olduğu görülmektedir. Sınıf bazındaki doğruluklar incelendiğinde ise 3B+2B ESA'nın sekiz sınıf için 100% doğruluğa sahip olduğu ve diğer bir tane sınıf için algoritmalar arasındaki en yüksek üretici ve kullanıcı doğruluklarına

sahip olduğu görülmüştür. 2B ESA'nın ise sınıf bazındaki doğruluk ölçütlerine ve genel doğruluğa göre 3B+2B ESA modeline çok yakın bir sınıflandırma performansına sahip olduğu görülmektedir. İşlem süreleri açısından incelendiğinde RO algoritması eğitim ve tüm görüntünün sınıflandırılması aşamasında en hızlı algoritmadır.

Çizelge 4.14 DFC13 70% veri seti için algoritmaların performansları.

Sınıf Adı	DVM		RO		2B ESA		3B+2B ESA	
	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)
Sağlıklı çimen	99,28	100,00	98,10	100,00	99,52	100,00	100,00	100,00
Yıpranmış çimen	99,54	99,31	98,85	98,62	99,77	99,54	99,77	100,00
Sentetik çimen	100,00	100,00	100,00	99,58	100,00	100,00	100,00	100,00
Ağaç	99,74	99,74	100,00	98,94	100,00	100,00	100,00	99,74
Toprak	99,49	99,49	99,49	99,74	100,00	100,00	100,00	100,00
Su	100,00	99,02	100,00	99,02	100,00	100,00	100,00	100,00
Ticari Yapı	97,33	98,65	95,64	99,10	100,00	100,00	100,00	100,00
Konut	96,77	96,06	98,23	95,81	100,00	100,00	100,00	100,00
Yol	97,66	98,71	96,10	95,28	100,00	99,79	100,00	100,00
Otoyol	98,14	98,59	96,28	96,96	99,30	100,00	100,00	99,77
Tren yolu	98,53	99,79	95,82	97,66	100,00	100,00	99,79	100,00
Park alanı 1	95,87	97,44	92,55	95,57	100,00	100,00	100,00	99,77
Park alanı 2	91,02	79,58	90,06	75,92	100,00	97,91	99,48	99,48
Tenis Kortu	99,35	99,35	99,35	100,00	99,35	100,00	99,35	100,00
Koşu Pisti	100,00	100,00	99,58	99,16	100,00	100,00	100,00	100,00
Genel Doğruluk	98,20%		97,16%		99,86%		99,92%	
Kappa	0,980		0,969		0,998		0,999	
İşlem Süreleri (saniye):	Eğitim	636,91	0,41		121,98		381,36	
	Sınıflandırma	43,38	16,14		822,84		1004,09	

DFC13 70% verisi için eğitilen algoritmalar tarafından oluşturulan sınıflandırma haritaları Şekil 4.20'de verilmiştir. Sınıflandırma sonuçları incelendiğinde özellikle diğer eğitim veri kümesi boyutlarında olduğu gibi gölge alana denk gelen bölgede binaların aralarında kalan alanların otoyol ve tren yolu olarak bariz bir şekilde yanlış sınıflandırıldıkları görülmektedir.



Şekil 4.20 DFC13 70% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).

Her veri kümesi boyutu için algoritmaların arasındaki genel doğruluk farklarının anlamlı olup olmadıklarının test edilmesi için uygulanan McNemar's testi sonuçları Çizelge 4.15'te verilmiştir. Hesaplanan test sonuçları 95% güven aralığında $\chi^2=3,841$ değeriyle karşılaştırıldığında her üç eğitim kümesi boyutu için 2B ESA ile 3B+2B ESA arasında hesaplanan McNemar's değerleri kritik değerden küçük olduğu için bu modellerin sınıflandırma performanslarının aynı olduğu yorumu yapılır.

Çizelge 4.15 DFC13 veri seti için hesaplanan McNemar's testi sonuçları.

Model 1 - Model 2	30% Veri Kümesi Boyutu		50% Veri Kümesi Boyutu		70% Veri Kümesi Boyutu	
	χ^2_{mc}	Anlamlı mı?	χ^2_{mc}	Anlamlı mı?	χ^2_{mc}	Anlamlı mı?
DVM - RO	38,675	Evet	39,848	Evet	23,024	Evet
DVM - 2B ESA	242,718	Evet	143,308	Evet	82,102	Evet
DVM - 3B+2B ESA	263,375	Evet	149,588	Evet	81,515	Evet
RO - 2B ESA	378,049	Evet	250,302	Evet	136,063	Evet
RO - 3B+2B ESA	391,263	Evet	254,603	Evet	137,170	Evet
2B ESA - 3B+2B ESA	3,015	Hayır	1,885	Hayır	0,444	Hayır


4.5 Salinas Scene Veri Seti Sınıflandırma Sonuçları

Salinas Scene veri setinin geleneksel MÖ ve DÖ algoritmaları ile sınıflandırılmasında eğitim veri kümesinin boyutu sırasıyla 30%, 50% ve 70% olarak seçilmiştir. Çizelge 4.16'da Salinas Scene veri setinin sınıflara göre yer doğrulama veri sayısı, eğitim veri boyutuna göre eğitim ve test için ayrılan etiketli verilerin dağılımları gösterilmiştir.

Çizelge 4.16 Salinas Scene veri setinde sınıflar ve 30%-50%-70% eğitim veri kümesi oranlarına göre eğitim ve test için ayrılan etiketli veri sayıları.


Sınıf No	Sınıf Adı	Toplam	Oran $\frac{n_i}{\sum n}$ (%)	30% Eğitim Veri Seti		50% Eğitim Veri Seti		70% Eğitim Veri Seti	
				Eğitim 30%	Test 70%	Eğitim 50%	Test 50%	Eğitim 70%	Test 30%
1	Brokoli_yeşil_otlar_1	2009	3,7	603	1406	1005	1004	1406	603
2	Brokoli_yeşil_otlar_2	3726	6,9	1118	2608	1863	1863	2608	1118
3	Nadas_toprak	1976	3,7	593	1383	988	988	1383	593
4	Nadas_toprak_kaba_saban	1394	2,6	418	976	697	697	976	418
5	Nadas_toprak_düz	2678	4,9	803	1875	1339	1339	1875	803
6	Anız	3959	7,3	1188	2771	1979	1980	2771	1188
7	Kereviz	3579	6,6	1074	2505	1789	1790	2505	1074
8	Üzümler_terbiyelenmemiş	11271	20,8	3381	7890	5635	5636	7890	3381
9	Toprak_üzüm_bağı_yetişen	6203	11,5	1861	4342	3101	3102	4342	1861
10	Mısır_yaşlanmış	3278	6,0	983	2295	1639	1639	2295	983
11	Roman_marulu_4_hafta	1068	2,0	320	748	534	534	748	320
12	Roman_marulu_5_hafta	1927	3,6	578	1349	964	963	1349	578
13	Roman_marulu_6_hafta	916	1,7	275	641	458	458	641	275
14	Roman_marulu_7_hafta	1070	2,0	321	749	535	535	749	321
15	Üzüm_bağı_terbiyelenmemiş	7268	13,4	2180	5088	3634	3634	5087	2181
16	Üzüm_bağı_düşey_çit	1807	3,3	542	1265	904	903	1265	542

Rastgele olarak ayrımı gerçekleştirilen eğitim ve test kümelerinin dağılımları Şekil 4.21’de gösterilmiştir.



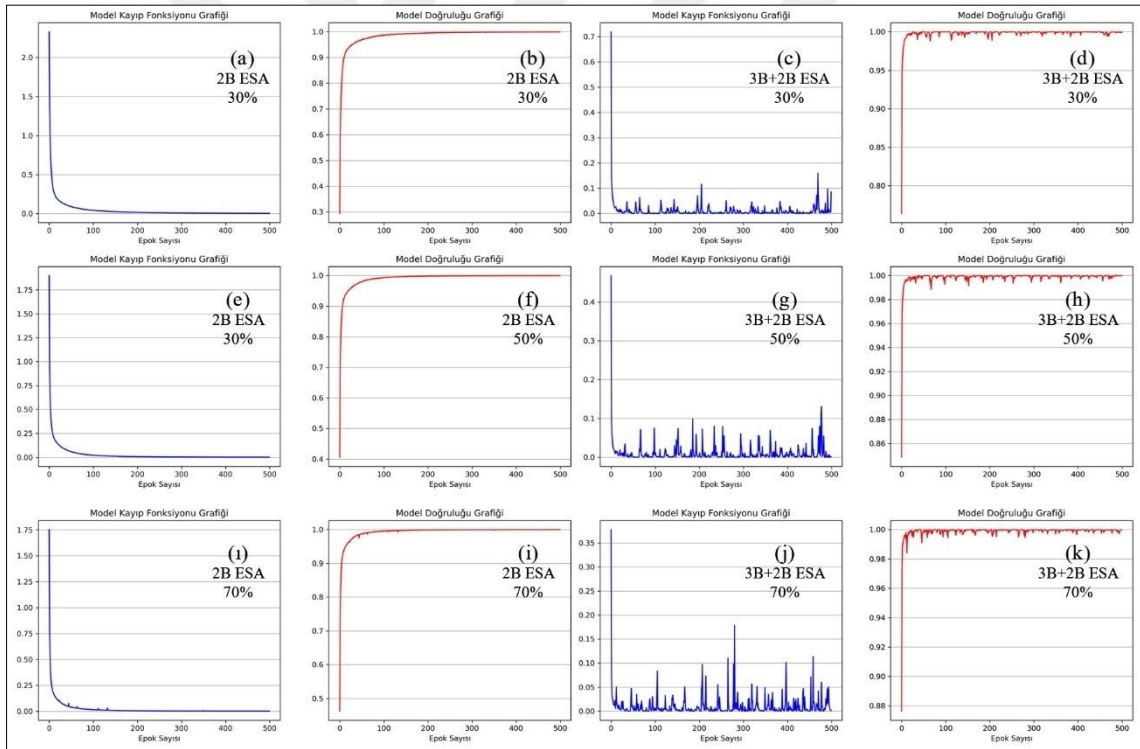
Şekil 4.21 Salinas Scene veri seti (a) için eğitim-test piksellerinin sırasıyla 30%(b)-70%(c), 50%(d)-50%(e) ve 70%(f)-30%(g) dağılımları.

DFC13 veri seti için DVM modelleri oluşturulurken RTF kernel fonksiyonu ile 30%, 50% ve 70% eğitim verisi küme boyutları için 5 katlamalı çapraz doğrulama işlemi ile optimum parametreler araştırılmıştır. Bütün veri küme boyutları için $\gamma=0,1$ olarak belirlenirken 30% ve 50% eğitim küme boyutu için $C=1000$; 70% eğitim veri küme boyutu için de $C=100$ olarak belirlenmiştir. RO algoritmasında $m=4$ olarak belirlenirken N parametresi için her üç eğitim kümesi için öncül olarak 1000 karar ağacı ile modeller oluşturulmuştur. Öncül modellerin OOB hatalarını gösteren grafikler Şekil 4.22’de verilmiştir. OOB hatasının grafikleri incelendiğinde 30% (Şekil 4.22a), 50% (Şekil 4.22b) ve 70% (Şekil 4.22c) eğitim veri küme boyutları için yaklaşık 150 karar ağacından sonra hata stabil olarak ilerlediği görülmüştür ve bu veri kümeleri ile asıl modeller kurulurken her üç RO modeli için de $N=150$ olarak seçilmiştir.



Şekil 4.22 Salinas Scene veri seti için sırasıyla 30% (a), 50% (b) ve 70% (c) eğitim kümesi boyutlarına göre RO algoritmasının OOB hataları.

ESA modellerinin eğitimi aşamasında her iki ESA modeli ve bütün eğitim veri kümesi boyutları için yığın boyutu 256 ve epok sayısı 500 olarak belirlenmiştir. Şekil 4.23'te her iki ESA modelinin farklı eğitim veri kümesi boyutlarına göre kayıp fonksiyonu ve model doğruluğu grafikleri verilmiştir. 2B ESA modellerinin tüm veri kümesi boyutları için kayıp fonksiyonu grafikleri incelendiğinde (Şekil 4.23a, Şekil 4.23e ve Şekil 4.23i) hataların üç modelde de yaklaşık 150. epok tekrarına kadar hızlıca düştükleri ve sıfıra yakınsayarak ilerledikleri görülmektedir. 3B+2B ESA modellerinin kayıp fonksiyonu grafiklerinin (Şekil 4.23c, Şekil 4.23g ve Şekil 4.23j) birkaç epok sonunda hızlıca düştükleri, ilerleyen epokların bazılarında anlık sıçramalar ile hataların maksimum 0,175 civarına yükselip geri düştükleri görülmektedir. Bu sıçramalar modellerin doğruluk grafiklerine (Şekil 4.23d, Şekil 4.23h ve Şekil 4.23k) ciddi bir şekilde yansımamıştır.



Şekil 4.23 Salinas Scene veri setinin sınıflandırılması için 30%, 50% ve 70% eğitim verisi ile oluşturulan ESA modellerinin kayıp fonksiyonu ve model doğruluğu grafikleri.

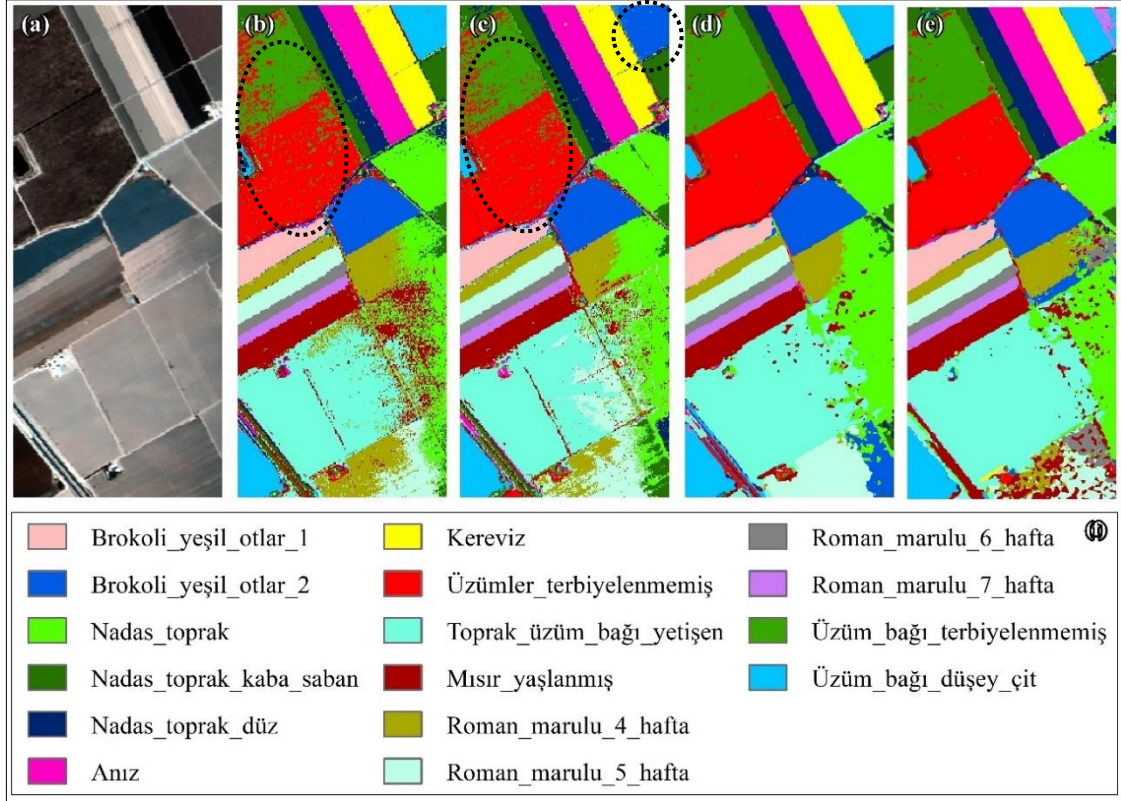
Veri seti için ilk aşamada algoritmalar 30% eğitim verisi ile eğitildikten sonra yer doğrulama verisinin eğitim verisinden artı kalan 70%'lik test veri seti ile hata matrisleri

oluşturulmuştur (Ek 37, Ek 38, Ek 39 ve Ek 40). Bu hata matrislerinden hesaplanan genel doğruluk, kappa, üretici ve kullanıcı doğrulukları ek olarak işlem süreleri Çizelge 4.17’de verilmiştir. Tablodaki değerler incelendiğinde 99,64% genel doğruluk ile en başarılı algoritmanın 2B ESA olduğu görülmektedir. Sınıf bazındaki doğruluklar incelendiğinde ise 2B ESA modelinin sekiz sınıf için 100% doğruluğa sahip olduğu ve diğer beş sınıf için algoritmalar arasındaki en yüksek üretici ve kullanıcı doğruluklarına sahip olduğu görülmüştür. 3B+2B ESA modelinin ise sınıf bazındaki doğruluk ölçütlerine ve genel doğruluğa göre 2B ESA modeline çok yakın bir sınıflandırma performansı ile ikinci en başarılı algoritma olduğu görülmektedir. İşlem süreleri açısından incelendiğinde RO modeli eğitiminin ve tüm görüntünün sınıflandırılması aşamasında en hızlı algoritmadır.

Çizelge 4.17 Salinas Scene 30% veri seti için algoritmaların performansları.

Sınıf Adı	DVM		RO		2B ESA		3B+2B ESA	
	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)
Brokoli_yeşil_otlar_1	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
Brokoli_yeşil_otlar_2	100,00	99,92	100,00	99,88	100,00	100,00	100,00	100,00
Nadas_toprak	98,70	98,99	97,39	99,78	100,00	100,00	99,93	100,00
Nadas_toprak_kaba_saban	99,38	98,98	99,28	99,59	100,00	99,80	100,00	96,21
Nadas_toprak_düz	98,61	98,72	99,57	98,88	99,89	100,00	98,22	99,95
Anız	99,96	99,96	99,93	99,93	100,00	100,00	100,00	100,00
Kereviz	100,00	99,96	100,00	99,76	100,00	100,00	100,00	100,00
Üzümler_terbiyelenmemiş	86,74	90,71	84,43	92,61	98,84	99,51	98,11	99,35
Toprak_üzüm_bağı_yetişen	99,47	100,00	99,24	99,79	99,98	100,00	100,00	100,00
Mısır_yaşlanmış	98,38	97,73	98,71	96,43	99,87	99,96	99,65	100,00
Roman_marulu_4_hafta	98,14	98,66	97,58	97,06	100,00	99,87	99,60	99,87
Roman_marulu_5_hafta	99,63	99,93	98,90	100,00	99,93	100,00	100,00	100,00
Roman_marulu_6_hafta	99,84	99,69	99,07	99,22	100,00	100,00	100,00	100,00
Roman_marulu_7_hafta	99,60	99,33	98,40	98,53	100,00	100,00	100,00	100,00
Üzüm_bağı_terbiyelenmemiş	84,81	78,58	86,79	73,84	99,28	98,19	99,12	97,03
Üzüm_bağı_düşey_çit	99,76	99,84	99,76	99,37	100,00	100,00	100,00	100,00
Genel Doğruluk	94,86%		94,48%		99,64%		99,36%	
Kappa	0,943		0,938		0,996		0,993	
İşlem Süreleri (saniye):	Eğitim	1143,49	0,08		145,81		433,33	
	Sınıflandırma	10,11	2,22		133,22		160,40	

Salinas Scene 30% verisi için eğitilen algoritmalar tarafından oluşturulan sınıflandırma haritaları Şekil 4.24'te verilmiştir. Sınıflandırma sonuçları incelendiğinde özellikle DVM ve RO modellerinin sınıflandırma haritalarında yüksek oranda tuz-biber etkisi gözlenmiştir. Görüntünün alt kısmında yer alan tarla bütünlük açısından en doğru olarak 2B ESA tarafından sınıflandırılmıştır.



Şekil 4.24 Salinas Scene 30% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).

Veri seti için ikinci aşamada algoritmalar 50% eğitim verisi ile eğitildikten sonra yer doğrulama verisinin eğitim verisinden artı kalan 50%'lik test veri seti ile hata matrisleri oluşturulmuştur (Ek 41, Ek 42, Ek 43 ve Ek 44). Bu hata matrislerinden hesaplanan genel doğruluk, kappa, üretici ve kullanıcı doğrulukları ek olarak işlem süreleri Çizelge 4.18'de verilmiştir. Tablodaki değerler incelendiğinde 99,92% genel doğruluk ile en başarılı algoritmanın 2B ESA olduğu görülmektedir. Sınıf bazındaki doğruluklar incelendiğinde ise 2B ESA modelinin on sınıf için 100% doğruluğa sahip olduğu ve diğer iki sınıf için

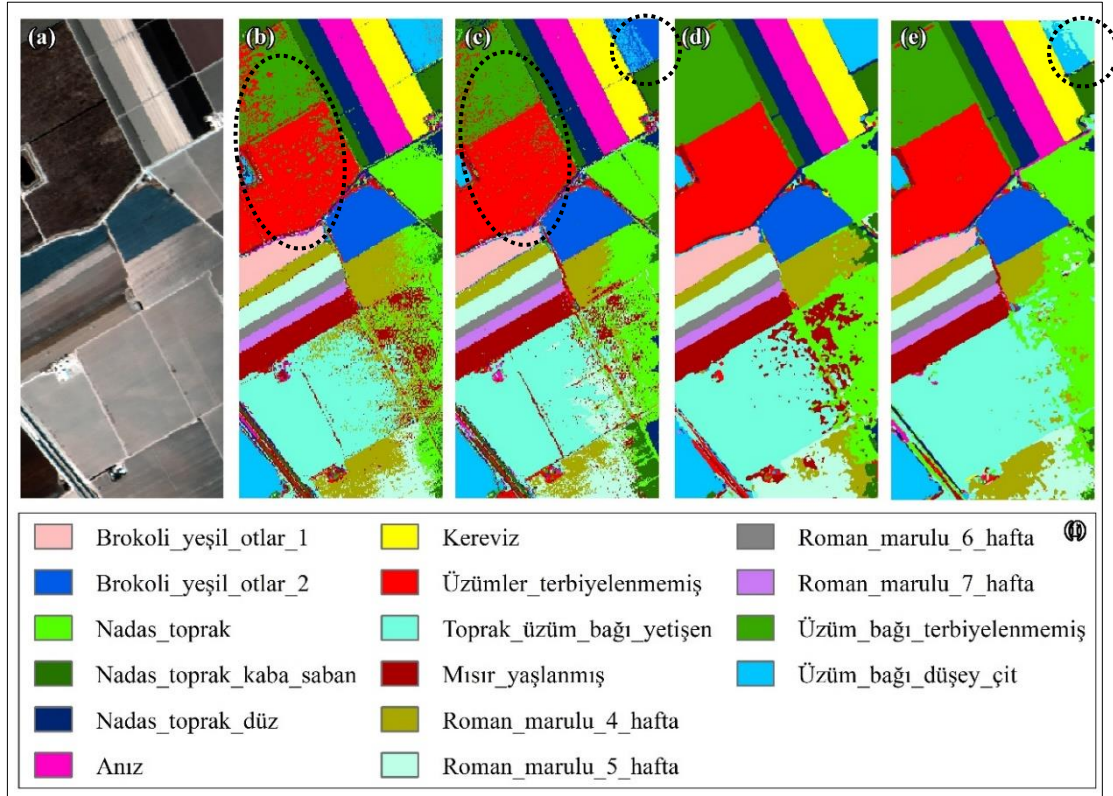
algoritmalar arasındaki en yüksek üretici ve kullanıcı doğruluklarına sahip olduğu görülmüştür. 3B+2B ESA modelinin ise sınıf bazındaki doğruluk ölçütlerine ve genel doğruluğa göre 2B ESA modeline çok yakın bir sınıflandırma performansı ile ikinci en başarılı algoritma olduğu görülmektedir. İşlem süreleri açısından incelendiğinde RO modeli eğitiminin ve tüm görüntünün sınıflandırılması aşamasında en hızlı algoritmadır.

Çizelge 4.18 Salinas Scene 50% veri seti için algoritmaların performansları.

Sınıf Adı	DVM		RO		2B ESA		3B+2B ESA	
	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)	Ür. D. (%)	Kul. D. (%)
Brokoli_yeşil_otlar_1	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
Brokoli_yeşil_otlar_2	100,00	100,00	100,00	99,95	100,00	100,00	100,00	100,00
Nadas_toprak	99,49	99,49	99,30	99,90	100,00	100,00	100,00	100,00
Nadas_toprak_kaba_saban	99,57	99,28	99,42	99,00	100,00	99,86	100,00	99,57
Nadas_toprak_düz	99,25	99,40	99,25	99,25	99,93	100,00	99,78	100,00
Anız	100,00	99,95	100,00	99,95	100,00	100,00	100,00	100,00
Kereviz	100,00	99,94	100,00	99,89	100,00	100,00	100,00	100,00
Üzümler_terbiyelenmemiş	86,79	91,52	86,54	92,94	99,91	99,75	99,72	99,72
Toprak_üzüm_bağı_yetişen	99,52	99,97	99,36	99,97	100,00	100,00	100,00	100,00
Mısır_yaşlanmış	98,78	98,54	99,13	97,86	99,88	100,00	99,94	100,00
Roman_marulu_4_hafta	99,44	99,25	98,87	98,13	100,00	100,00	100,00	100,00
Roman_marulu_5_hafta	99,90	100,00	99,18	100,00	100,00	100,00	100,00	100,00
Roman_marulu_6_hafta	100,00	99,78	99,13	99,34	100,00	100,00	100,00	100,00
Roman_marulu_7_hafta	99,44	99,63	98,69	98,69	100,00	99,81	100,00	100,00
Üzüm_bağı_terbiyelenmemiş	85,93	78,48	87,84	77,74	99,64	99,86	99,59	99,56
Üzüm_bağı_düşey_cit	99,89	99,89	99,78	99,67	100,00	100,00	100,00	100,00
Genel Doğruluk	95,15%		95,24%		99,92%		99,87%	
Kappa	0,946		0,947		0,999		0,999	
İşlem Süreleri (saniye):	Eğitim	2972,73	0,11		211,55		655,03	
	Sınıflandırma	15,29	2,29		130,84		163,41	

Salinas Scene 50% verisi için eğitilen algoritmalar tarafından oluşturulan sınıflandırma haritaları Şekil 4.25'te verilmiştir. Sınıflandırma sonuçları incelendiğinde 50% veri kümesi boyutu kullanımında da DVM ve RO modelleri için tuz-biber etkisinin devam ettiği görülmüştür. Özellikle yer doğrulama örneklerinin mevcut olduğu bölgelerle

kıyaslandığında (Şekil 3.4) 2B ESA'nın sınıflandırma sonucuyla büyük benzerlik göstermektedir.



Şekil 4.25 Salinas Scene 50% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).

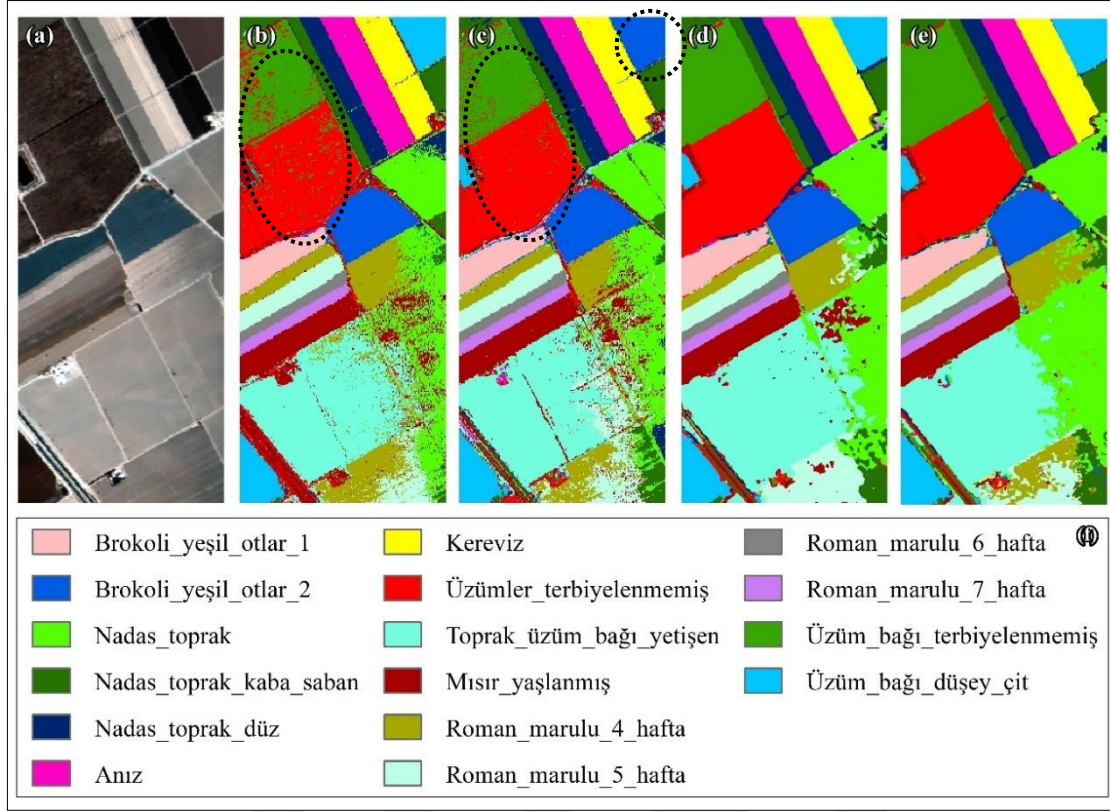
Veri seti için üçüncü aşamada algoritmalar 70% eğitim verisi ile eğildikten sonra yer doğrulama verisinin eğitim verisinden artı kalan 30%'luk test veri seti ile hata matrisleri oluşturulmuştur (Ek 45, Ek 46, Ek 47 ve Ek 48). Bu hata matrislerinden hesaplanan genel doğruluk, kappa, üretici ve kullanıcı doğrulukları ek olarak işlem süreleri Çizelge 4.19'de verilmiştir. Tablodaki değerler incelendiğinde 99,98% genel doğruluk ile en başarılı algoritmanın 2B ESA olduğu görülmektedir. Sınıf bazındaki doğruluklar incelendiğinde ise 2B ESA modelinin on dört sınıf için 100% doğruluğa sahip olduğu ve diğer iki sınıf için algoritmalar arasındaki en yüksek üretici ve kullanıcı doğruluklarına sahip olduğu görülmüştür. 3B+2B ESA modelinin ise sınıf bazındaki doğruluk ölçütlerine ve genel doğruluğa göre on dört sınıfta 100%'lük üretici ve kullanıcı doğruluğuna sahip olduğu ve 2B ESA modeline çok yakın bir sınıflandırma performansı ile ikinci en başarılı algoritma

olduğu görülmektedir. İşlem süreleri açısından incelendiğinde RO modeli eğitiminin ve tüm görüntünün sınıflandırılması aşamasında en hızlı algoritmadır.

Çizelge 4.19 Salinas Scene 70% veri seti için algoritmaların performansları.

Sınıf Adı	DVM		RO		2B ESA		3B+2B ESA	
	Ür. D. (%)	Knl. D. (%)	Ür. D. (%)	Knl. D. (%)	Ür. D. (%)	Knl. D. (%)	Ür. D. (%)	Knl. D. (%)
Brokoli_yeşil_otlar_1	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
Brokoli_yeşil_otlar_2	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
Nadas_toprak	99,33	99,66	99,50	99,83	100,00	100,00	100,00	100,00
Nadas_toprak_kaba_saban	99,76	99,04	99,28	99,52	100,00	100,00	100,00	100,00
Nadas_toprak_düz	99,01	99,38	99,38	99,25	100,00	100,00	100,00	100,00
Anız	100,00	100,00	99,92	99,92	100,00	100,00	100,00	100,00
Kereviz	100,00	99,91	100,00	99,91	100,00	100,00	100,00	100,00
Üzümler_terbiyelenmemiş	88,79	91,10	87,86	93,94	99,91	100,00	99,82	99,91
Toprak_üzüm_bağı_yetişen	99,57	99,95	99,36	100,00	100,00	100,00	100,00	100,00
Mısır_yaşlanmış	98,58	98,78	98,88	98,47	100,00	100,00	100,00	100,00
Roman_marulu_4_hafta	99,07	99,69	99,37	97,81	100,00	100,00	100,00	100,00
Roman_marulu_5_hafta	100,00	100,00	99,83	100,00	100,00	100,00	100,00	100,00
Roman_marulu_6_hafta	100,00	100,00	99,28	99,64	100,00	100,00	100,00	100,00
Roman_marulu_7_hafta	99,69	99,38	99,37	98,75	100,00	100,00	100,00	100,00
Üzüm_bağı_terbiyelenmemiş	85,89	82,07	89,72	80,01	100,00	99,86	99,86	99,72
Üzüm_bağı_düşey_çit	100,00	99,63	100,00	99,63	100,00	100,00	100,00	100,00
Genel Doğruluk	95,55%		95,81%		99,98%		99,94%	
Kappa	0,950		0,953		0,999		0,999	
İşlem Süreleri (saniye):	Eğitim	5720,01	0,17		317,99		909,17	
	Sınıflandırma	22,58	2,37		133,52		163,74	

Salinas Scene 70% verisi için eğitilen algoritmalar tarafından oluşturulan sınıflandırma haritaları Şekil 4.26'da verilmiştir. Sınıflandırma sonuçları incelendiğinde görüntünün yukarı bölgesinde yer alan tarla DVM, 2B ESA ve 3B+2B ESA tarafından Üzüm_bağı_düşey_çit olarak sınıflandırılırken RO tarafından Brokoli_yeşil_otlar_2 olarak sınıflandırılmıştır.



Şekil 4.26 Salinas Scene 70% veri seti (a) için DVM (b), RO (c), 2B ESA (d) ve 3B+2B ESA (e) algoritmaları ile oluşturulan sınıflandırma haritaları ve lejantı (f).

Her veri kümesi boyutu için algoritmaların arasındaki genel doğruluk farklarının anlamlı olup olmadıklarının test edilmesi için uygulanan McNemar's's testi sonuçları Çizelge 4.20'de verilmiştir. Hesaplanan test sonuçları 95% güven aralığında $\chi^2=3,841$ değeriyle karşılaştırıldığında her üç eğitim kümesi boyutu için DVM ile RO arasında hesaplanan McNemar's değerleri ve 50% ve 70% eğitim veri kümesi boyutları için 2B ESA ile 3B+2B ESA modelleri arasında hesaplanan McNemar's değerleri kritik değerden küçüktür. Dolayısıyla bahsedilen model çiftlerinin kendi aralarında sınıflandırma performanslarının aynı olduğu yorumu yapılır.

Çizelge 4.20 Salinas Scene veri seti için hesaplanan McNemar's testi sonuçları.

Model 1 - Model 2	30% Veri Kümesi Boyutu		50% Veri Kümesi Boyutu		70% Veri Kümesi Boyutu	
	χ^2_{mc}	Anlamlı mı?	χ^2_{mc}	Anlamlı mı?	χ^2_{mc}	Anlamlı mı?
DVM - RO	12,868	Evet	0,570	Hayır	2,443	Hayır
DVM - 2B ESA	1722,543	Evet	1278,130	Evet	715,012	Evet
DVM - 3B+2B ESA	1498,467	Evet	1241,042	Evet	701,167	Evet
RO - 2B ESA	1867,049	Evet	1251,176	Evet	672,037	Evet
RO - 3B+2B ESA	1655,407	Evet	1221,749	Evet	658,247	Evet
2B ESA - 3B+2B ESA	43,75	Evet	3,521	Hayır	3,125	Hayır



5. SONUÇLAR ve TARTIŞMA

Bu tez çalışmasında hiperspektral görüntülerin sınıflandırılmasında geleneksel MÖ yöntemlerinden olan DVM ve RO algoritmaları ile popüler görüntü sınıflandırma yöntemlerinden olan ESA tabanlı olan 2B ESA ve 3B+2B ESA modelleri kıyaslanmıştır. Görüntülerin ulaşılabilir olmaması ve yer doğrulama verilerinin oluşturulması zor ve yüksek maliyetli olduğundan, literatürde de sıklıkla kullanılan karşılaştırma veri setlerinden yararlanılmıştır. Literatürdeki birçok çalışmada genellikle birkaç veri setinin kullanılması ve diğer veri setleri üzerinde algoritmaların performanslarının araştırılması konusunda bir açık olması sebebiyle tez çalışmasında yaygın kullanılan Salinas Scene veri setinin yanında güncel karşılaştırma veri setlerinden olan HyRANK ve DFC13 veri setleri de kullanılmıştır. Bu veri setlerinden HyRANK veri seti EO-1 Hyperion uydu platformundan elde edilmiş olup 30 metre konumsal çözünürlüğe sahiptir ve yer sınıfları CORINE kriterlerine göre belirlenmiştir. DFC13 veri seti hava aracıyla elde edildiğinden 2,5 metre konumsal çözünürlüğe sahiptir ve yer sınıfları bu çözünürlükteki bir verinin rahatlıkla sağlayacağı daha özel ölçekte detaylandırılmış sınıflara sahiptir. Salinas Scene veri seti 3,7 metre konumsal çözünürlüğe sahiptir ve aynı türler içinde zamansal ve şekilsel farklılıklara sahip zirai sınıflardan oluşmaktadır. Üç veri setinin konumsal ve spektral çözünürlükleri ile içerdiği yer sınıfları birlikte değerlendirildiğinde, bu verilerin aynı tez çalışması kapsamında değerlendirilmesi tez çalışmasının geniş bir perspektif göz önünde bulundurularak gerçekleştirildiğinin de göstergesidir. Diğer bir durum ise Dioni ve DFC13 verilerinde bulunan gölge alanlardır. Bu alanların da doğrudan sınıflandırma işlemine tabi tutulmasıyla bu gibi durumlarda sınıflandırma modellerinin testi de gerçekleştirmiştir.

Hiperspektral görüntülerde bantlar arasında yüksek korelasyon bulunması durumu MÖ algoritmaları açısından istenen bir durum değildir. Bu problemle başa çıkılması için literatürdeki birçok çalışmada olduğu gibi TBA kullanılarak veri boyutu indirgenmiştir. Temel bileşenlerin seçimine dair literatürde önerilen 95% açıklanabilir varyans şartı tezde kullanılan verilerde 1-2 temel bileşenle sağlanmaktadır. Açıklanabilir varyansın 99,5% olma şartı ise genellikle 4-5 bantta sağlanmaktadır. Yapılan değerlendirmeler ve kullanılan modellerin gereklilikleri değerlendirildiğinde tüm veri setleri için 15 temel

bileşen kullanılması uygun görülmüştür. Böylelikle veri seti açısından evrensel bir sınıflandırma modellemesi sağlanacaktır.

Tez kapsamında kullanılan MÖ algoritmaları kullanıcı tarafından tanımlanan bazı parametrelere sahiptir. Bu parametrelerin seçimi modelin sınıflandırma doğruluğunu önemli ölçüde etkilemekle beraber veri setine göre de kullanılacak parametreler değişiklik göstermektedir. Dolayısıyla ortaya bir optimizasyon problemi çıkmaktadır. DVM algoritmasında C parametresi, çekirdek fonksiyonu ve bu fonksiyonun gerektirdiği parametreler mevcuttur. Tez çalışmasında DVM için literatürdeki yapılan çalışmalarda da başarısını kanıtlamış RTF çekirdek fonksiyonu kullanılmıştır ve eğitim veri setlerine göre 5 katlı çapraz doğrulama ile optimum parametreler tespit edilmiştir. RO algoritmasının kullanıcı tanımlı m ve N parametrelerinin duyarlılığı DVM'ye göre daha düşüktür. RO algoritmasında m parametresi için yapılan çalışmalarda önerilen, bant sayısının karekökünün tam sayıya yuvarlanmış şekli kullanılmıştır. Bütün veri setleri için 15 temel bileşen kullanıldığından dolayı m değeri de tüm RO modelleri için 4 olarak kullanılmıştır. N parametresinin belirlenmesi için ise OOB hataları incelenmiştir ve yine bütün verilerde N parametresi 150 olarak belirlenmiştir.

ESA mimarileri uygulanırken hiperspektral verilerin sınıflandırılmasında yüksek performans gösteren modeller tespit edilip bu mimariler üzerinde geliştirmeler yapılmıştır. Özellikle 3B+2B ESA modelinde konumsal-spektral öğrenme işlemi gerçekleştirilmesi hiperspektral verilerin sınıflandırılmasında önem arz etmektedir.

Modellerin sınıflandırma performanslarını bu bölümde daha kolay incelemek için genel doğruluklar Çizelge 5.1'de verilmiştir. Tabloda sonuçlar veri setlerine göre, veri setlerinin altında ise eğitim veri kümesi oranlarına göre gösterilmiştir.

Çizelge 5.1 Modellerin veri setleri ve eğitim veri küme oranlarına göre genel doğrulukları.

Veri Seti	Eğitim Veri Oranı	DVM	RO	2B ESA	3B+2B ESA
Dioni (30m)	30%	94,61%	93,66%	98,29%	98,60%
	50%	95,92%	94,46%	99,17%	97,92%
	70%	96,04%	95,02%	99,42%	99,48%
Loukia (30 m)	30%	86,12%	85,14%	92,38%	93,97%
	50%	88,13%	86,67%	94,93%	96,73%
	70%	89,68%	87,63%	96,64%	97,40%
DFC13 (2,5 m)	30%	97,17%	96,13%	99,55%	99,67%
	50%	97,94%	96,75%	99,77%	99,86%
	70%	98,20%	97,16%	99,86%	99,92%
Salinas Scene (3,7 m)	30%	94,86%	94,48%	99,64%	99,36%
	50%	95,15%	95,24%	99,92%	99,87%
	70%	95,55%	95,81%	99,98%	99,94%

MÖ ve ESA modellerinin eğitilmesi aşamasında veri setlerinin yer doğrulama verilerinin 30%, 50% ve 70%'lik kısımlarının eğitimde kullanılmasının etkisi de incelenmiştir. Dioni veri setinde 30% eğitim verisi kullanıldığında en yüksek doğruluk 98,60% ile 3B+2B ESA modeliyle elde edilirken en düşük doğruluğa 93,66% ile RO modeli sahiptir. 50% eğitim verisi kullanılarak gerçekleştirilen sınıflandırma işleminde 99,17% doğrulukla 2B ESA en iyi sınıflandırma performansında sahipken 94,46% doğrulukla en düşük doğruluk RO algoritmasında gözlenmiştir. Bu veri seti ve eğitim verisi oranında meyve bahçeleri ve zeytinlikler sınıflarında 3B+2B ESA modelinin 100% üretici doğruluğuna sahipken kullanıcı doğruluğu tarafında çok düşük doğruluk gösterdiği görülmektedir. Bu da bazı durumlarda modelin kompleksliğinin bazı sınıflarda gözle görülür şekilde aşırı uyum sorununa yol açtığını göstermektedir. 70% eğitim verisi kullanılması durumunda da 3B+2B ESA modeli 99,48% ile en iyi genel doğruluğa sahipken RO modeli 95,02% ile en düşük doğruluğu vermiştir. Görüntüde bulut ve gölge alanlardaki piksellerin sınıflandırılmasında ESA modelleri beklendiği üzere sırasıyla kayalıklar ve kumluklar ve su olarak sınıflandırırken DVM ve kısmen RO bu alanları diğer arazi sınıflarına göre

etiketlemiştir. Alana dair gerçek arazi sınıfları tam olarak bilinmediğinden DVM'nin sınıflandırma sonuçları hakkında bir yorumlama yapılması mümkün değildir.

Loukia veri setinin 30% eğitim verisi ile sınıflandırılmasında 3B+2B ESA modeli 93,97% ile en iyi sınıflandırma sonucuna sahipken 85,14% doğruluk sergilemiştir. Eğitim verisinin 50% ve 70% kullanımında sırasıyla 96,73% ve 97,40% genel doğruluk ile 3B+2B ESA modeli en iyi performansı gösterirken sırasıyla 86,67% ve 87,63% ile en düşük doğruluğu RO modeli göstermiştir. Eğitim verisindeki 40%'lık artış miktarı 3B+2B ESA modelinde ~3,5%'lik genel doğruluk artışı sağlamıştır. Loukia veri setinin sınıflandırma haritaları incelendiğinde bütün eğitim veri boyutları için denizde su ve kıyı sularının birleştiği bölgede DVM'nin hatalı sınıflandırmalar gerçekleştirdiği görülmüştür. Modellerde genellikle meyve bahçeleri sınıfı için sınıflandırma performansı kötüdür. Bu durumun oluşmasında söz konusu sınıfta yer doğrulama için ayrılan piksellerin diğer sınıflara göre çok daha düşük miktarda olmasının (< 0,1%) etkisi de göz ardı edilmemelidir.

Kullanılan veriler arasında en yüksek konumsal çözünürlüğe sahip olan DFC13 verisinin sınıflandırılmasında 30%, 50% ve 70% eğitim verisi kullanılması durumunda sırasıyla 99,67%, 99,86% ve 99,92%'lik genel doğrulukla en iyi sınıflandırma performansını 3B+2B ESA modeli gösterirken yine sırasıyla 96,13%, 96,75% ve 97,16%'lık genel doğrulukla RO modeli en düşük sınıflandırma performansına sahiptir. Düşük miktarda eğitim verisi kullanımında dahi tüm algoritmaların bu veri setindeki başarısı oldukça yüksektir. Bunun olası sebeplerinden birisi görüntünün konumsal çözünürlüğün yüksek olması, böylece daha az miktarda katışimli piksele sahip olmasıdır. Ancak görüntüdeki gölge alanda hatalı sınıflandırmalar olduğu da görülmektedir.

Temelde sebze, toprak ve üzüm bağları sınıfları olmak üzere çeşitli zamansal ve şekilsel farklılıklar gösteren 16 sınıftan oluşan Salinas Scene verisinin sınıflandırılmasında ise 30%, 50% ve 70% eğitim verisi kullanılması durumunda sırasıyla 99,64%, 99,92% ve 99,98%'lik genel doğrulukla en iyi sınıflandırma performansını 2B ESA modeli gösterirken yine sırasıyla 94,48%, 95,24% ve 95,81%'lik genel doğrulukla RO modeli en düşük sınıflandırma performansına sahiptir. DVM ile RO modellerinin arasında bütün eğitim küme boyutlarında McNemar's test sonuçlarına dayanarak sınıflandırma performansı açısından anlamlı bir farklılık tespit edilememiştir. Ayrıca söz konusu

modellerin sınıflandırma haritalarında yer doğrulama verisine göre çok miktarda tuz-biber etkisi ve hatalı sınıflandırma olduğu göze çarpmaktadır. Bunun yanı sıra 50% ve 70% eğitim küme boyutları için 2B ESA ve 3B+2B ESA modellerinin sınıflandırma performansları arasında anlamlı bir farklılık bulunamamıştır.

Kullanılan veri setleri ve veri boyutları için elde edilen sınıflandırma doğrulukları göz önünde bulundurulduğunda Salinas Scene veri seti haricinde konumsal-spektral öğrenme gerçekleştirmesi sayesinde 3B+2B ESA modelinin diğer modellere göre daha yüksek başarı gösterdiği görülmüştür. Salinas Scene veri setinde ise 2B ESA modeli yüksek başarı göstermiştir. Buradan yola çıkarak hiperspektral görüntülerin sınıflandırılmasında ESA modellerinin kullanımının MÖ modellerine göre daha avantajlı olduğunu söylemek mümkündür. Eğitim veri kümesi açısından değerlendirildiğinde beklendiği üzere 70% eğitim veri kümesi ile eğitilen modeller daha az miktardaki eğitim veri kümesi boyutlarına göre daha yüksek genel doğruluk vermektedir. Veri setlerinde en yüksek doğruluk veren algoritmalar üzerinden bir değerlendirme yapıldığında 30% ile 70% eğitim veri kullanılması durumunda minimum 0,25% ile maksimum 3,43%'lük bir artış gözlenmiştir.

Literatürde HyRANK veri seti ile sadece birkaç çalışma yapıldığı görülmüştür. Hang vd. (2020) Dioni veri seti ile eğitim Loukia ile test ettikleri SSAtt modeliyle 58,55% genel doğruluk elde etmiştir. Çalışmada özellikle az sayıda yer doğrulama verisi barındıran sınıfların elimine edilip sadece yedi tane yer doğrulama sınıfı kullanıldığı göz ardı edilmemelidir. Christovam vd. (2019) 85% eğitim veri kümesiyle gerçekleştirdikleri çalışmada 91% genel doğrulukla RO-TBA yöntemini başarılı bulmuşlardır. Sonuçlar incelendiğinde meyve bahçeleri sınıfı için düşük sınıflandırma doğruluğu elde etmişlerdir. Tez çalışmasında Dioni ve Loukia 30% eğitim veri seti için 3B+2B ESA modeliyle elde edilen genel doğruluk sırasıyla 98,6% ve 93,97%'dir. Sonuçlar incelendiğinde deneyler birebir aynı şartlarda gerçekleştirilmemesine rağmen tez çalışmasında daha iyi sınıflandırma performansı elde edildiği söylenebilir.

Hang vd. (2020) DFC13 veri seti ile SSAtt isimli DÖ modeli 90,38% genel doğruluk elde etmiştir. Çalışmada her sınıftan 181-198 arasında eğitim pikseli kullanılırken görüntüdeki gölge alan kesilmiştir. Hong vd. (2020) FuNet-M mimarisiyle DFC13 veri seti için 88,62% doğruluk elde etmiştir. Bu çalışmada görüntüdeki bulut gölgesi giderildikten

sonra kullanılmıştır. Zhao X vd. (2020) bölgenin LiDAR verisiyle birlikte kullandığı DFC13 verisiyle HRWN ismini verdiği ESA modeliyle 93,61% genel doğruluk elde etmiştir. Bu çalışmalarla kıyaslandığında 30% eğitim verisiyle ve söz konusu veri setiyle 3B+2B ESA modeliyle 99,67% doğruluk elde edilmiştir. Ancak çalışmalar arasında gölge giderimi, LiDAR kullanımı ve tez çalışmasında olduğu gibi eğitim ve validasyon verisinin birleştirilerek kullanımı gibi temel farklılıklar da mevcuttur.

Literatürde birçok çalışmada kullanılan Salinas Scene veri seti için genellikle yüksek genel doğruluk değerleri hesaplanmaktadır. Gualtieri vd. (1999) çalışmasında Salinas 98 C ismiyle anılan Salinas Scene verisiyle DVM yöntemiyle 1% eğitim verisi kullanarak 89% genel doğruluğa ulaşmıştır. Hu vd. (2015) önerdikleri ESA modeliyle Salinas Scene verisini kullanarak 92,60% genel doğruluk elde etmişlerdir. Çalışmada her sınıftan 200'er tane eğitim pikseli kullanıp geriye kalan kısmı test için kullanmışlardır. Roy vd. (2019) HybridSN ESA modeliyle, KÇ3B-ESA modeliyle Salinas Scene veri seti için 100% genel doğruluk elde etmişlerdir. Tez çalışmasında söz konusu veri seti için 30% eğitim 2B ESA modeliyle 99,64% genel doğruluk elde edilmiştir. Elde edilen sonuçlar karşılaştırıldığında güncel çalışmalara yakın genel doğruluklara ulaşıldığı söylenebilir.

Tez çalışmasında 30% eğitim verisi ile eğitilen verilerde de yüksek doğruluk elde edildiği göz önünde bulundurulursa yer doğrulama verilerinin seçiminde maliyet de dikkate alınarak az sayıda yer örneği ile de yüksek sınıflandırma doğruluğu sağlanması mümkün olabilir. RO algoritması tez kapsamında yapılan deneylerde her ne kadar diğer modellere göre düşük performans gösterse de modelin basitliği, işlem süresi ve kullanıcı tanımlı parametrelere karşı aşırı duyarlı olmaması gibi olumlu yönleriyle hız gerektiren çalışmalarda kullanılabilir. ESA modelleri yüksek işlem sürelerine rağmen en iyi sınıflandırma sonuçlarını vermişlerdir. DVM algoritması zaman yönünden hızlı olmaması, kullanıcı tanımlı parametrelere karşı yüksek hassasiyette olması ve ESA modelleri kadar yüksek doğruluk sağlamaması sebepleriyle karşılaştıran modeller arasında en son tercih edilmesi gereken modeldir.

6. KAYNAKLAR

- Agarap A F, 2018, Deep Learning Using Rectified Linear Units (ReLU), arXiv preprint arXiv:1803.08375, 1, 1-7.
- Aloysius N, Geetha M, 2017, A Review on Deep Convolutional Neural Networks, 2017 International Conference on Communication and Signal Processing (ICCSP), 6-7 April 2017, Chennai, India, 0588-0592.
- Alpaydın E, 2004, Introduction to Machine Learning, The MIT Press, 415, London.
- Bayati A M A, 2019, Evrişimsel Sinir Ağlarını Kullanarak Drone Tarafından Elde Edilen Görüntülerde Nesne Tanıma, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 58, Konya.
- Bera S, Shrivastava V K, 2020, Analysis of Various Optimizers on Deep Convolutional Neural Network Model in the Application of Hyperspectral Remote Sensing Image Classification, International Journal of remote sensing, 41, 7, 2664-2683.
- Bhardwaj A, Di W, Wei J, 2018, Deep Learning Essentials: Your Hands-on Guide to the Fundamentals of Deep Learning and Neural Network Modeling, Packt Publishing Ltd, 246, Birmingham - Mumbai.
- Breiman L, 2001, Random Forests, Machine learning, 45, 1, 5-32.
- Camps-Valls G, Bruzzone L, 2005, Kernel-based Methods for Hyperspectral Image Classification, IEEE Transactions on Geoscience and Remote Sensing, 43, 6, 1351-1362.
- Chan J C-W, Paelinckx D, 2008, Evaluation of Random Forest and Adaboost Tree-based Ensemble Classification and Spectral Band Selection for Ecotope Mapping Using Airborne Hyperspectral Imagery, Remote Sensing of Environment, 112, 6, 2999-3011.

- Chang C-I, 2003, *Hyperspectral Imaging: Techniques for Spectral Detection and Classification*, Springer Science & Business Media, 374, New York.
- 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.
- Chen Y, Lin Z, Zhao X, Wang G, Gu Y, 2014, Deep Learning-based Classification of Hyperspectral Data, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7, 6, 2094-2107.
- Christovam L E, Pessoa G G, Shimabukuro M H, Galo M L B T, 2019, Land Use and Land Cover Classification Using Hyperspectral Imagery: Evaluating the Performance of Spectral Angle Mapper, Support Vector Machine and Random Forest, *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, 10–14 June 2019, Enschede, The Netherlands, 1841-1847.
- Cihan M, Ceylan M, 2020, KÇ3B-ESA: Hiperspektral Görüntü Sınıflandırması için Yeni 3B Evrişimli Sinir Ağı ve Uzaktan Algılama Uygulaması, *Avrupa Bilim ve Teknoloji Dergisi*, Özel Sayı (Eylül 2020), 65-71.
- Congalton R G, Green K, 2019, *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*, CRC Press, 328, Boca Raton, FL.
- Cortes C, Vapnik V, 1995, Support-Vector Networks, *Machine learning*, 20, 3, 273-297.
- Çatalbaş M C, 2014, *Temel Bileşenler Analizi ve Kanonik Korelasyon Analizi ile İmge Tanıma ve Sınıflandırma*, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 103, Ankara.
- Dalponte M, Bruzzone L, Vescovo L, Gianelle D, 2009, The Role of Spectral Resolution and Classifier Complexity in the Analysis of Hyperspectral Images of Forest Areas, *Remote Sensing of Environment*, 113, 11, 2345-2355.
- Debes C, Merentitis A, Heremans R, Hahn J, Frangiadakis N, van Kasteren T vd., 2014,

- Hyperspectral and LiDAR Data Fusion: Outcome of the 2013 GRSS Data Fusion Contest, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7, 6, 2405-2418.
- Demir B, 2010, *Hiperspektral Görüntülerin Yüksek Doğruluklu Sınıflandırılması*, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 176, Kocaeli.
- Deng L, Yu D, 2014, *Deep Learning: Methods and Applications*, Foundations and trends in signal processing, 7, 3-4, 197-387.
- Dumoulin V, Visin F, 2018, *A Guide to Convolution Arithmetic for Deep Learning*, arXiv preprint arXiv:1603.07285, 1, 1-31.
- Fauvel M, Tarabalka Y, Benediktsson J A, Chanussot J, Tilton J C, 2012, *Advances in Spectral-Spatial Classification of Hyperspectral Images*, *Proceedings of the IEEE*, 101, 3, 652-675.
- Foody G M, 2004, *Thematic Map Comparison*, *Photogrammetric Engineering & Remote Sensing*, 70, 5, 627-633.
- Foody G M, Mathur A, 2004, *A Relative Evaluation of Multiclass Image Classification by Support Vector Machines*, *IEEE Transactions on Geoscience and Remote Sensing*, 42, 6, 1335-1343.
- Fukushima K, 1980, *Neocognitron: A Self-Organizing Neural Network Model for a Mechanism of Visual Pattern Recognition Unaffected by Shift in Position*, *Biological Cybernetics*, 36, 193-202.
- Gao J, 2009, *Digital Analysis of Remotely Sensed Imagery*, McGraw-Hill Education, 645, E Book.
- Ghamisi P, Yokoya N, Li J, Liao W, Liu S, Plaza J vd., 2017, *Advances in Hyperspectral Image and Signal Processing: A Comprehensive Overview of the State of the Art*, *IEEE Geoscience and Remote Sensing Magazine*, 5, 4, 37-78.

- Ghatak A, 2019, Deep Learning with R, Springer, 245, Kolkata.
- Gislason P O, Benediktsson J A, Sveinsson J R, 2006, Random Forests for Land Cover Classification, Pattern Recognition Letters, 27, 4, 294-300.
- Grahn H, Geladi P, 2007, Techniques and Applications of Hyperspectral Image Analysis, John Wiley & Sons, 368, West Sussex.
- Gualtieri J, Chettri S R, Crompton R, Johnson L, 1999, Support Vector Machine Classifiers as Applied to AVIRIS Data, Proc. Eighth JPL Airborne Geoscience Workshop, 8-11 February 1999, Pasadena, 1-10.
- Guo Y, Liu Y, Oerlemans A, Lao S, Wu S, Lew M S, 2016, Deep Learning for Visual Understanding: A Review, Neurocomputing, 187, 27-48.
- Hamida A B, Benoit A, Lambert P, Amar C B, 2018, 3-D Deep Learning Approach for Remote Sensing Image Classification, IEEE Transactions on Geoscience and Remote Sensing, 56, 8, 4420-4434.
- Hang R, Li Z, Liu Q, Ghamisi P, Bhattacharyya S S, 2020, Hyperspectral Image Classification with Attention Aided CNNs, arXiv preprint arXiv:2005.11977,
- He M, Li B, Chen H, 2017, Multi-scale 3D deep convolutional neural network for hyperspectral image classification, 2017 IEEE International Conference on Image Processing (ICIP), 3904-3908.
- Hinton G E, Srivastava N, Krizhevsky A, Sutskever I, Salakhutdinov R R, 2012, Improving Neural Networks by Preventing Co-adaptation of Feature Detectors, arXiv preprint arXiv:1207.0580, 1, 1-18.
- Hong D, Gao L, Yao J, Zhang B, Plaza A, Chanussot J, 2020, Graph Convolutional Networks for Hyperspectral Image Classification, IEEE Transactions on Geoscience and Remote Sensing, 1, 1-13.
- Hotelling H, 1933, Analysis of a Complex of Statistical Variables into Principal

- Components, Journal of educational psychology, 24, 6, 417.
- Hu W, Huang Y, Wei L, Zhang F, Li H, 2015, Deep Convolutional Neural Networks for Hyperspectral Image Classification, Journal of Sensors, 2015, 1, 1-12.
- Hubel D H, Wiesel T N, 1962, Receptive Fields, Binocular Interaction and Functional Architecture in the Cat's Visual Cortex, The Journal of physiology, 160, 1, 106.
- İnik Ö, Ülker E, 2017, Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, Gaziosmanpaşa Bilimsel Araştırma Dergisi, 6, 3, 85-104.
- Japkowicz N, Shah M, 2011, Evaluating Learning Algorithms: A Classification Perspective, Cambridge University Press, 406, Cambridge.
- Jordan M I, Mitchell T M, 2015, Machine Learning: Trends, Perspectives, and Prospects, Science, 349, 6245, 255-260.
- Karantzalos K, Karakizi C, Kandylakis Z, Antoniou G, 2018, HyRANK Hyperspectral Satellite Dataset I (Version v001).
- Kavzoğlu T, Çölkesen İ, 2009, A Kernel Functions Analysis for Support Vector Machines for Land Cover Classification, International Journal of Applied Earth Observation and Geoinformation, 11, 5, 352-359.
- Kavzoğlu T, Çölkesen İ, 2010, Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi, Harita Dergisi, 144, 7, 73-82.
- Kayaalp K, Süzen A, 2018, Derin Öğrenme ve Türkiye'deki Uygulamaları, 89, Adıyaman.
- Kingma D P, Ba J, 2014, Adam: A Method for Stochastic Optimization, arXiv preprint arXiv:1412.6980, 1, 1-15.
- Krizhevsky A, Sutskever I, Hinton G E, 2017, Imagenet Classification with Deep Convolutional Neural Networks, Communications of the ACM, 60, 6, 84-90.

- Landgrebe D A, 2005, Signal Theory Methods in Multispectral Remote Sensing, John Wiley & Sons, 508, Hoboken.
- LeCun Y, 1989, Generalization and Network Design Strategies, Connectionism in perspective, 19, 143-155.
- LeCun Y, Bengio Y, Hinton G, 2015, Deep Learning, nature, 521, 7553, 436-444.
- LeCun Y, Boser B, Denker J S, Henderson D, Howard R E, Hubbard W vd., 1989, Backpropagation Applied to Handwritten Zip Code Recognition, Neural computation, 1, 4, 541-551.
- LeCun Y, Bottou L, Bengio Y, Haffner P, 1998, Gradient-Based Learning Applied to Document Recognition, Proceedings of the IEEE, 86, 11, 2278-2324.
- Lee C, Landgrebe D A, 1993, Analyzing High-Dimensional Multispectral Data, IEEE Transactions on Geoscience and Remote Sensing, 31, 4, 792-800.
- Li W, Prasad S, Fowler J E, Bruce L M, 2011, Locality-Preserving Dimensionality Reduction and Classification for Hyperspectral Image Analysis, IEEE Transactions on Geoscience and Remote Sensing, 50, 4, 1185-1198.
- 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, e1264.
- Lillesand T, Kiefer R W, Chipman J, 2015, Remote Sensing and Image Interpretation, John Wiley & Sons, 719, Hoboken.
- Lindsay G, 2020, Convolutional Neural Networks as a Model of the Visual System: Past, Present, and Future, Journal of Cognitive Neuroscience, 1-15.
- Luo Y, Zou J, Yao C, Zhao X, Li T, Bai G, 2018, HSI-CNN: A Novel Convolution Neural Network for Hyperspectral Image, 2018 International Conference on Audio, Language and Image Processing (ICALIP), Beijing, 464-469.

- Makantasis K, Karantzas K, Doulamis A, Doulamis N, 2015, Deep Supervised Learning for Hyperspectral Data Classification Through Convolutional Neural Networks, 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Milan, 4959-4962.
- Mather P M, Koch M, 2011, Computer Processing of Remotely-Sensed Images: an Introduction, John Wiley & Sons, 426, West Sussex.
- Mathur A, Foody G M, 2008, Multiclass and Binary SVM Classification: Implications for Training and Classification Users, IEEE Geoscience and Remote Sensing Letters, 5, 2, 241-245.
- 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.
- Melgani F, Bruzzone L, 2004, Classification of Hyperspectral Remote Sensing Images with Support Vector Machines, IEEE Transactions on Geoscience and Remote Sensing, 42, 8, 1778-1790.
- Mosavi A, Ardabili S, Varkonyi-Koczy A R, 2019, List of Deep Learning Models, International Conference on Global Research and Education, Budapest, 202-214.
- 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.
- Mountrakis G, Im J, Ogole C, 2011, Support Vector Machines in Remote Sensing: A Review, ISPRS Journal of Photogrammetry and Remote Sensing, 66, 3, 247-259.
- Nair V, Hinton G E, 2010, Rectified Linear Units Improve Restricted Boltzmann Machines, The 27th International Conference on Machine Learning (ICML 2010), 21-24 June 2010, Haifa, Israel, 8.
- Nassif A B, Shahin I, Attili I, Azzeh M, Shaalan K, 2019, Speech Recognition Using Deep Neural Networks: A Systematic Review, IEEE Access, 7, 19143-19165.

- Oommen T, Misra D, Twarakavi N K, Prakash A, Sahoo B, Bandopadhyay S, 2008, An Objective Analysis of Support Vector Machine Based Classification for Remote Sensing, *Mathematical geosciences*, 40, 4, 409-424.
- Pal M, 2005, Random Forest Classifier for Remote Sensing Classification, *International Journal of remote sensing*, 26, 1, 217-222.
- Pal M, Mather P, 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, 120-147.
- Paoletti M E, Haut J M, Roy S K, Hendrix E M, 2020, Rotation Equivariant Convolutional Neural Networks for Hyperspectral Image Classification, *IEEE Access*, 8, 179575-179591.
- Paoletti M E, Haut J M, Tao X, Miguel J P, Plaza A, 2020, A New GPU Implementation of Support Vector Machines for Fast Hyperspectral Image Classification, *Remote Sensing*, 12, 8, 1257.
- Pearson K, 1901, LIII. On Lines and Planes of Closest Fit to Systems of Points in Space, *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, 2, 11, 559-572.
- Richards J A, 2013, *Remote Sensing Digital Image Analysis*, Springer, 439, Berlin.
- Rippel O, Snoek J, Adams R P, 2015, Spectral Representations for Convolutional Neural Networks, *Advances in Neural Information Processing Systems*, Montreal, 2449-2457.
- Rodriguez-Galiano V F, Ghimire B, Rogan J, Chica-Olmo M, Rigol-Sanchez J P, 2012, An Assessment of the Effectiveness of a Random Forest Classifier for Land-Cover Classification, *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 93-

104.

Roy S K, Krishna G, Dubey S R, Chaudhuri B B, 2019, HybridSN: Exploring 3-D–2-D CNN Feature Hierarchy for Hyperspectral Image Classification, *IEEE Geoscience and Remote Sensing Letters*, 17, 2, 277-281.

Seyrek E C, Çölkesen İ, Bovkır R, Aydınoglu A Ç, 2019, The Use of Machine Learning Algorithms in Real Estate Valuation, *Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği X. Sempozyumu (TUFUAB2019)*, 25-27 Nisan 2019, Aksaray, 96-102.

Sunar F, Özkan C, Osmanoglu B, 2011, *Uzaktan Algılama*, Anadolu Üniversitesi Yayınları, 210, Eskişehir.

Vapnik V, 1995, *The Nature of Statistical Learning Theory*, Springer - Verlag, 188, New York.

Viera A J, Garrett J M, 2005, Understanding Interobserver Agreement: The Kappa Statistic, *Fam med*, 37, 5, 360-363.

Waske B, Benediktsson J A, Arnason K, Sveinsson J R, 2009, Mapping of Hyperspectral AVIRIS Data Using Machine-Learning Algorithms, *Canadian Journal of Remote Sensing*, 35, sup1, S106-S116.

Zeiler M D, 2013, *Hierarchical Convolutional Deep Learning in Computer Vision*, New York University, Department of Computer Science, PhD Thesis, 207, New York.

Zeiler M D, Fergus R, 2013, Stochastic Pooling for Regularization of Deep Convolutional Neural Networks, *arXiv preprint arXiv:1301.3557*, 1, 1-9.

Zhao W, Du S, 2016, Spectral–Spatial Feature Extraction for Hyperspectral Image Classification: A Dimension Reduction and Deep Learning Approach, *IEEE Transactions on Geoscience and Remote Sensing*, 54, 8, 4544-4554.

Zhao X, Tao R, Li W, Li H-C, Du Q, Liao W vd., 2020, Joint Classification of

Hyperspectral and LiDAR Data Using Hierarchical Random Walk and Deep CNN Architecture, *IEEE Transactions on Geoscience and Remote Sensing*, 58, 10, 7355-7370.

Zinkevich M, Weimer M, Li L, Smola A J, 2010, Parallelized Stochastic Gradient Descent, *Advances in Neural Information Processing Systems 23: 24th Annual Conference on Neural Information Processing Systems 2010*, 6-9 December 2010, Vancouver, Canada, 2595-2603.



İnternet Kaynakları

- 1- https://www.usgs.gov/centers/eros/science/usgs-eros-archive-earth-observing-one-eo-1-hyperion?qt-science_center_objects=0#qt-science_center_objects/, 31/12/2020.
- 2- http://www.ehu.eus/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes/, 31/12/2020.
- 3- <https://webapps.itc.utwente.nl/sensor/default.aspx?view=allensors/>, 18/11/2020.
- 4- https://www.usgs.gov/centers/eros/science/usgs-eros-archive-earth-observing-one-eo-1-hyperion?qt-science_center_objects=0#qt-science_center_objects, 11/11/2020.
- 5- https://hyperspectral.ee.uh.edu/?page_id=459, 12/11/2020.
- 6- https://upload.wikimedia.org/wikipedia/commons/7/72/SVM_margin.png, 10/11/2020.
- 7- <https://github.com/KonstantinosF/Classification-of-Hyperspectral-Image>, 07/07/2020.

ÖZGEÇMİŞ

Adı Soyadı : Eren Can SEYREK
Doğum Yeri ve Tarihi : Vezirköprü/SAMSUN, 14/04/1995
Yabancı Dili : İngilizce
İletişim (Telefon / e-posta) : +90 (545) 613 99 79 / erencanseyre@gmail.com

Eğitim Durumu

Lise : Vezirköprü Anadolu Lisesi (2009–2013)
Lisans : Karadeniz Teknik Üniversitesi, Harita Mühendisliği
Bölümü, (2013–2018)
Yüksek Lisans : Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü,
Harita Mühendisliği ABD, (2019–2021)
Çalıştığı Kurum ve Yıl : Afyon Kocatepe Üniversitesi (2019–Devam Ediyor)

Yayınlar ve Bildiriler:

Salihoğlu T, Seyrek E C, Kaymakçıoğlu M, 2020, Alternatives to Solar Power Plant Location Through GIS and AHP: Case of Karaman, Turkey, Kent Akademisi Dergisi, 13, 4, 651-667.
Salihoğlu T, Seyrek E C, Kaymakçıoğlu M, 2019, Using GIS for the Solar Power Plant Location: Case Of Karaman, Turkey, International Symposium on Applied Geoinformatics, 07-09 November 2019, Istanbul.
Seyrek E C, Çölkesen İ, Aydınoğlu A Ç, 2019, Taşınmaz Değer Haritaları Üretimi Amacıyla Coğrafi Analiz Aracı Geliştirilmesi, GTÜ Fen Bilimleri Enstitüsü Lisansüstü Araştırmalar Sempozyumu ve Tanıtım Günleri, 17 Haziran 2019, Kocaeli, 28.

Seyrek E C, Çölkesen İ, Bovkır R, Aydınoglu A Ç, 2019, The Use of Machine Learning Algorithms in Real Estate Valuation, Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliđi X. Sempozyumu (TUFUAB2019), 25-27 Nisan 2019, Aksaray, 96-102.

Seyrek E C, Çölkesen İ, Bovkır R, Aydınoglu A Ç, 2018, Açık Kaynaklı Coğrafi Veri Analiz Araçlarının İncelenmesi ve Uygulanabilirliđi, V. Uluslararası Fen, Mühendislik ve Mimarlık Bilimlerinde Akademik Çalışmalar Sempozyumu, 16-17 Kasım 2018



EKLER

Ek 1 Dioni 30% veri seti için DVM modelinin hata matrisi.

Sın.No	1	2	3	4	5	7	9	10	11	12	13	14
1	762	5	17	0	59	0	1	23	16	0	0	0
2	8	121	0	0	0	0	0	4	10	0	0	0
3	16	1	385	0	24	0	0	0	4	0	0	0
4	0	0	0	82	23	0	0	0	0	0	0	0
5	59	0	12	13	1148	0	1	3	2	0	0	0
7	0	0	0	0	0	250	3	0	0	0	0	0
9	1	0	0	0	3	0	3309	211	0	0	0	0
10	12	0	2	0	3	0	126	4301	18	0	0	0
11	17	0	0	0	2	0	1	39	1167	2	0	0
12	1	0	0	0	0	0	0	0	8	335	0	0
13	0	0	0	0	0	0	0	0	0	0	1128	0
14	0	1	1	0	0	0	0	2	0	0	2	273

Ek 2 Dioni 30% veri seti için RO modelinin hata matrisi.

Sın.No	1	2	3	4	5	7	9	10	11	12	13	14
1	689	5	13	0	80	0	0	55	41	0	0	0
2	15	113	0	0	0	0	0	3	12	0	0	0
3	15	1	389	0	17	0	0	3	5	0	0	0
4	0	0	0	78	25	0	1	1	0	0	0	0
5	24	0	15	8	1164	0	3	23	1	0	0	0
7	0	0	0	0	0	253	0	0	0	0	0	0
9	0	0	0	0	5	0	3240	279	0	0	0	0
10	0	0	0	0	6	0	109	4338	9	0	0	0
11	6	0	1	0	0	0	2	85	1128	6	0	0
12	0	0	0	0	0	0	0	0	13	331	0	0
13	0	0	0	0	0	0	0	0	0	0	1128	0
14	0	0	0	0	0	0	0	0	0	0	2	277

Ek 3 Dioni 30% veri seti için 2B ESA modelinin hata matrisi.

Sın.No	1	2	3	4	5	7	9	10	11	12	13	14
1	827	0	10	0	12	0	0	33	0	1	0	0
2	0	137	0	0	0	0	0	5	1	0	0	0
3	5	0	414	0	8	0	0	0	3	0	0	0
4	3	0	0	90	11	0	0	0	1	0	0	0
5	10	0	2	5	1221	0	0	0	0	0	0	0
7	0	0	0	0	0	253	0	0	0	0	0	0
9	0	0	0	0	0	0	3472	52	0	0	0	0
10	0	0	4	0	0	0	61	4395	2	0	0	0
11	0	0	1	0	0	0	0	8	1219	0	0	0
12	0	0	0	0	0	0	0	0	2	342	0	0
13	0	0	0	0	0	0	0	0	0	0	1128	0
14	0	0	0	0	0	0	0	0	0	0	0	279

Ek 4 Dioni 30% veri seti için 3B+2B ESA modelinin hata matrisi.

Sın.No	1	2	3	4	5	7	9	10	11	12	13	14
1	838	0	14	0	10	2	0	18	0	1	0	0
2	0	143	0	0	0	0	0	0	0	0	0	0
3	0	0	420	0	3	0	0	6	1	0	0	0
4	1	0	0	83	21	0	0	0	0	0	0	0
5	5	0	3	2	1228	0	0	0	0	0	0	0
7	0	0	0	0	0	253	0	0	0	0	0	0
9	0	0	0	0	3	0	3499	22	0	0	0	0
10	1	0	3	0	0	0	71	4386	1	0	0	0
11	4	1	1	0	0	0	0	1	1221	0	0	0
12	1	0	0	0	0	0	0	0	0	343	0	0
13	0	0	0	0	0	0	0	0	0	0	1128	0
14	0	0	0	0	0	0	0	0	0	0	0	279

Ek 5 Dioni 50% veri seti için DVM modelinin hata matrisi.

Sın.No	1	2	3	4	5	7	9	10	11	12	13	14
1	560	1	13	0	34	0	0	10	13	0	0	0
2	2	93	0	0	0	0	0	3	4	0	0	0
3	9	0	278	0	18	0	0	0	2	0	0	0
4	1	0	0	67	7	0	0	0	0	0	0	0
5	26	0	4	6	845	0	0	1	2	0	0	0
7	0	0	0	0	0	180	1	0	0	0	0	0
9	0	0	0	0	1	0	2389	127	0	0	0	0
10	5	0	0	0	1	0	81	3096	4	0	0	0
11	9	0	0	0	0	0	1	21	846	0	0	0
12	0	0	0	0	0	0	0	0	1	245	0	0
13	0	0	0	0	0	0	0	0	0	0	806	0
14	0	0	0	0	0	0	0	0	0	0	0	199

Ek 6 Dioni 50% veri seti için RO modelinin hata matrisi.

Sın.No	1	2	3	4	5	7	9	10	11	12	13	14
1	510	4	4	0	54	0	0	30	29	0	0	0
2	6	87	0	0	0	0	0	3	6	0	0	0
3	16	0	271	0	16	0	0	2	2	0	0	0
4	0	0	0	60	14	0	1	0	0	0	0	0
5	19	0	4	6	841	0	3	11	0	0	0	0
7	0	0	0	0	0	181	0	0	0	0	0	0
9	0	0	0	0	0	0	2354	163	0	0	0	0
10	0	0	0	0	4	0	83	3095	5	0	0	0
11	4	0	1	0	0	0	1	53	817	1	0	0
12	0	0	0	0	0	0	0	0	9	237	0	0
13	0	0	0	0	0	0	0	0	0	0	806	0
14	0	0	0	0	0	0	0	0	0	0	1	198

Ek 7 Dioni 50% veri seti için 2B ESA modelinin hata matrisi.

Sın.No	1	2	3	4	5	7	9	10	11	12	13	14
1	617	0	1	0	8	1	0	3	1	0	0	0
2	0	101	0	0	0	0	0	0	1	0	0	0
3	3	0	299	0	3	0	0	2	0	0	0	0
4	0	0	0	65	10	0	0	0	0	0	0	0
5	1	0	3	1	879	0	0	0	0	0	0	0
7	0	0	0	0	0	181	0	0	0	0	0	0
9	0	0	0	0	0	0	2501	16	0	0	0	0
10	1	0	0	0	0	0	25	3160	1	0	0	0
11	0	0	1	0	0	0	0	0	876	0	0	0
12	0	0	0	0	0	0	0	0	1	245	0	0
13	0	0	0	0	0	0	0	0	0	0	806	0
14	0	0	0	0	0	0	0	0	0	0	0	199

Ek 8 Dioni 50% veri seti için 3B+2B ESA modelinin hata matrisi.

Sın.No	1	2	3	4	5	7	9	10	11	12	13	14
1	598	0	0	0	20	0	2	8	3	0	0	0
2	3	55	0	0	0	0	0	9	35	0	0	0
3	1	0	302	0	2	0	0	0	2	0	0	0
4	0	0	0	32	42	1	0	0	0	0	0	0
5	5	0	1	0	877	0	0	1	0	0	0	0
7	0	0	0	0	0	181	0	0	0	0	0	0
9	0	0	0	0	0	0	2511	6	0	0	0	0
10	0	0	3	0	0	0	56	3124	4	0	0	0
11	0	0	0	0	0	0	0	0	877	0	0	0
12	0	0	0	0	0	0	0	0	4	242	0	0
13	0	0	0	0	0	0	0	0	0	0	806	0
14	0	0	0	0	0	0	0	0	0	0	0	199

Ek 9 Dioni 70% veri seti için DVM modelinin hata matrisi.

Sın.No	1	2	3	4	5	7	9	10	11	12	13	14
1	335	1	10	0	20	0	0	7	6	0	0	0
2	1	58	0	0	0	0	0	2	0	0	0	0
3	4	0	166	0	12	0	0	0	2	0	0	0
4	1	0	0	40	4	0	0	0	0	0	0	0
5	12	0	4	3	511	0	0	0	1	0	0	0
7	0	0	0	0	0	108	0	0	0	0	0	0
9	0	0	0	0	1	0	1433	76	1	0	0	0
10	1	0	2	0	0	0	49	1855	5	0	0	0
11	4	0	0	0	0	0	1	7	514	0	0	0
12	0	0	0	0	0	0	0	0	0	148	0	0
13	0	0	0	0	0	0	0	0	0	0	484	0
14	0	0	0	0	0	0	0	0	0	0	1	118

Ek 10 Dioni 70% veri seti için RO modelinin hata matrisi.

Sın.No	1	2	3	4	5	7	9	10	11	12	13	14
1	317	0	3	0	30	0	0	17	12	0	0	0
2	6	52	0	0	0	0	0	2	1	0	0	0
3	6	0	165	0	9	0	0	2	2	0	0	0
4	0	0	0	34	10	0	1	0	0	0	0	0
5	14	0	3	4	504	0	0	6	0	0	0	0
7	0	0	0	0	0	108	0	0	0	0	0	0
9	0	0	0	0	1	0	1419	91	0	0	0	0
10	0	0	1	0	1	0	38	1868	4	0	0	0
11	4	0	0	0	0	0	0	26	495	1	0	0
12	0	0	0	0	0	0	0	0	3	145	0	0
13	0	0	0	0	0	0	0	0	0	0	484	0
14	0	0	0	0	0	0	0	0	0	0	1	118

Ek 11 Dioni 70% veri seti için 2B ESA modelinin hata matrisi.

Sın.No	1	2	3	4	5	7	9	10	11	12	13	14
1	377	0	0	0	1	0	0	1	0	0	0	0
2	0	60	0	0	0	0	0	1	0	0	0	0
3	1	0	181	0	2	0	0	0	0	0	0	0
4	0	0	0	40	4	0	0	1	0	0	0	0
5	0	0	2	0	529	0	0	0	0	0	0	0
7	0	0	0	0	0	108	0	0	0	0	0	0
9	0	0	0	0	0	0	1505	6	0	0	0	0
10	0	0	0	0	0	0	14	1897	1	0	0	0
11	0	0	0	0	0	0	0	0	526	0	0	0
12	0	0	0	0	0	0	0	0	1	147	0	0
13	0	0	0	0	0	0	0	0	0	0	484	0
14	0	0	0	0	0	0	0	0	0	0	0	119

Ek 12 Dioni 70% veri seti için 3B+2B ESA modelinin hata matrisi.

Sın.No	1	2	3	4	5	7	9	10	11	12	13	14
1	374	0	1	0	4	0	0	0	0	0	0	0
2	0	61	0	0	0	0	0	0	0	0	0	0
3	1	0	179	0	3	0	0	1	0	0	0	0
4	0	0	0	39	6	0	0	0	0	0	0	0
5	0	0	1	0	529	0	0	1	0	0	0	0
7	0	0	0	0	0	108	0	0	0	0	0	0
9	0	0	0	0	0	0	1508	3	0	0	0	0
10	0	0	0	0	0	0	9	1903	0	0	0	0
11	0	0	0	0	0	0	0	1	525	0	0	0
12	0	0	0	0	0	0	0	0	0	148	0	0
13	0	0	0	0	0	0	0	0	0	0	484	0
14	0	0	0	0	0	0	0	0	0	0	0	119

Ek 13 Loukia 30% veri seti için SVM modelinin hata matrisi.

Sın.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	153	0	16	0	20	0	0	0	3	8	1	1	0	0
2	0	33	0	0	0	0	0	0	0	7	3	4	0	0
3	8	0	345	0	5	0	0	0	1	19	0	1	0	0
4	3	0	0	32	12	0	0	0	3	5	0	0	0	0
5	9	0	20	4	908	0	0	2	27	10	1	0	0	0
6	0	0	0	0	1	90	0	13	50	2	0	0	0	0
7	0	0	0	0	0	0	247	40	61	2	0	0	0	0
8	0	0	0	0	4	17	21	505	204	0	0	0	0	0
9	2	0	1	1	8	13	26	130	2293	181	0	0	0	0
10	0	0	6	0	7	0	0	2	242	1685	18	2	0	0
11	0	0	0	0	0	0	0	0	0	34	244	5	0	0
12	2	0	0	0	0	0	0	1	1	11	11	315	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	975	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	316

Ek 14 Loukia 30% veri seti için RO modelinin hata matrisi.

Sın.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	129	0	23	0	39	0	0	0	0	8	0	3	0	0
2	0	40	0	0	0	0	0	0	0	0	1	6	0	0
3	5	0	333	0	6	0	0	0	0	31	2	2	0	0
4	0	0	0	26	27	0	0	0	1	1	0	0	0	0
5	6	0	7	1	885	0	0	1	44	37	0	0	0	0
6	0	0	0	0	3	85	0	25	43	0	0	0	0	0
7	0	0	0	0	0	0	224	41	83	2	0	0	0	0
8	0	0	0	0	0	7	12	496	236	0	0	0	0	0
9	0	0	0	0	7	2	20	109	2317	200	0	0	0	0
10	1	0	1	0	7	0	0	0	225	1725	2	1	0	0
11	0	0	2	0	0	0	0	0	0	73	189	19	0	0
12	2	0	0	0	0	0	0	0	8	14	9	308	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	975	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	316

Ek 15 Loukia 30% veri seti için 2B ESA modelinin hata matrisi.

Sın.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	174	0	7	1	20	0	0	0	0	0	0	0	0	0
2	0	46	0	0	0	0	0	0	0	0	1	0	0	0
3	3	0	363	0	8	0	0	0	0	5	0	0	0	0
4	1	0	0	38	11	0	4	0	1	0	0	0	0	0
5	6	0	18	6	939	0	0	2	7	3	0	0	0	0
6	0	0	1	4	3	105	0	12	31	0	0	0	0	0
7	1	0	0	0	4	0	274	41	28	2	0	0	0	0
8	0	0	0	0	1	3	12	670	65	0	0	0	0	0
9	1	0	0	0	2	6	9	36	2457	144	0	0	0	0
10	0	0	3	0	0	0	1	0	165	1784	7	2	0	0
11	0	0	2	0	0	0	0	0	0	14	267	0	0	0
12	2	0	0	0	0	0	0	0	6	0	8	325	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	975	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	316

Ek 16 Loukia 30% veri seti için 3B+2B ESA modelinin hata matrisi.

Sın.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	182	0	3	0	12	0	0	0	0	5	0	0	0	0
2	0	47	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	347	0	8	0	0	0	1	20	0	3	0	0
4	2	0	0	46	7	0	0	0	0	0	0	0	0	0
5	8	0	2	5	949	0	1	4	7	3	1	1	0	0
6	0	0	0	0	1	121	1	8	25	0	0	0	0	0
7	0	0	0	0	8	0	287	23	28	4	0	0	0	0
8	0	0	0	0	3	2	1	706	39	0	0	0	0	0
9	1	0	0	0	1	7	4	42	2490	107	3	0	0	0
10	0	0	0	0	1	0	1	0	138	1812	10	0	0	0
11	0	0	0	0	0	0	0	0	0	8	275	0	0	0
12	0	0	0	0	0	0	0	2	0	7	2	330	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	975	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	316

Ek 17 Loukia 50% veri seti için DVM modelinin hata matrisi.

Sın.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	117	0	7	0	14	1	0	0	2	2	0	1	0	0
2	0	28	0	0	0	0	0	0	0	2	2	1	0	0
3	5	0	256	0	4	0	0	0	2	4	0	0	0	0
4	2	0	0	26	11	0	0	0	0	0	0	0	0	0
5	9	0	5	1	674	0	0	1	9	2	0	0	0	0
6	0	0	0	0	1	81	0	6	23	0	0	0	0	0
7	0	0	0	0	0	0	190	23	35	2	0	0	0	0
8	0	0	0	0	3	8	9	395	120	1	0	0	0	0
9	1	0	0	0	8	11	17	96	1636	128	0	0	0	0
10	1	0	2	0	7	0	0	0	164	1214	11	3	0	0
11	0	0	0	0	0	0	0	0	0	20	180	2	0	0
12	1	0	0	0	0	0	0	1	1	6	3	232	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	697	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	225

Ek 18 Loukia 50% veri seti için RO modelinin hata matrisi.

Sın.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	94	0	14	0	32	0	0	0	0	1	0	3	0	0
2	0	29	0	0	0	0	0	0	0	0	2	2	0	0
3	3	0	244	0	4	0	0	0	0	17	2	1	0	0
4	0	0	0	18	20	0	0	0	0	1	0	0	0	0
5	4	0	1	1	650	0	0	1	30	14	0	0	0	0
6	0	0	0	0	1	71	0	11	28	0	0	0	0	0
7	0	0	0	0	0	0	173	26	49	2	0	0	0	0
8	0	0	0	0	1	6	11	354	164	0	0	0	0	0
9	0	0	0	0	6	4	15	64	1696	112	0	0	0	0
10	0	0	2	0	7	0	0	0	161	1230	2	0	0	0
11	0	1	3	0	0	0	0	0	0	39	151	8	0	0
12	1	0	0	0	0	0	0	0	9	7	7	220	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	697	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	225

Ek 19 Loukia 50% veri seti için 2B ESA modelinin hata matrisi.

Sın.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	126	0	3	0	15	0	0	0	0	0	0	0	0	0
2	0	32	0	0	0	0	0	0	0	0	1	0	0	0
3	0	0	261	0	5	0	0	0	1	4	0	0	0	0
4	1	0	0	27	11	0	0	0	0	0	0	0	0	0
5	1	0	9	2	680	0	1	1	6	1	0	0	0	0
6	0	0	0	0	0	93	0	3	15	0	0	0	0	0
7	0	0	0	0	1	0	216	13	17	3	0	0	0	0
8	0	0	0	0	0	0	1	499	36	0	0	0	0	0
9	0	0	0	0	0	6	2	25	1794	69	0	1	0	0
10	0	0	2	0	0	0	1	0	67	1331	1	0	0	0
11	0	0	2	0	0	0	0	0	0	5	195	0	0	0
12	0	0	0	0	0	0	0	1	0	3	6	234	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	697	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	225

Ek 20 Loukia 50% veri seti için 3B+2B ESA modelinin hata matrisi.

Sın.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	133	0	2	0	8	0	1	0	0	0	0	0	0	0
2	0	33	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	264	2	1	0	0	0	1	2	0	1	0	0
4	0	0	0	31	8	0	0	0	0	0	0	0	0	0
5	3	0	3	2	690	0	0	1	1	1	0	0	0	0
6	0	0	0	0	0	102	0	2	7	0	0	0	0	0
7	0	0	0	0	2	0	233	5	9	1	0	0	0	0
8	0	0	0	0	0	0	8	513	14	1	0	0	0	0
9	0	0	0	0	1	3	6	6	1841	40	0	0	0	0
10	0	0	0	0	1	0	3	3	59	1328	7	1	0	0
11	0	0	0	0	0	0	0	0	0	0	200	2	0	0
12	0	0	0	0	0	0	0	0	3	0	0	241	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	697	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	225

Ek 21 Loukia 70% veri seti için DVM modelinin hata matrisi.

Sın.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	76	0	3	0	6	0	0	0	1	0	0	0	0	0
2	0	19	0	0	0	0	0	0	0	0	0	1	0	0
3	1	0	155	0	4	0	0	0	0	3	0	0	0	0
4	0	0	0	18	6	0	0	0	0	0	0	0	0	0
5	2	0	3	0	410	0	1	3	0	1	0	0	0	0
6	0	0	0	0	0	53	0	2	12	0	0	0	0	0
7	0	0	0	0	0	0	121	11	17	1	0	0	0	0
8	0	0	0	0	0	3	5	257	57	0	0	0	0	0
9	0	0	0	0	4	5	14	56	982	77	0	0	0	0
10	0	0	0	0	3	0	3	1	96	732	5	1	0	0
11	0	0	0	0	0	0	0	0	0	7	114	0	0	0
12	1	0	0	0	0	0	0	0	0	2	0	143	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	418	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	135

Ek 22 Loukia 70% veri seti için RO modelinin hata matrisi.

Sın.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	60	0	7	0	14	0	0	0	0	3	0	2	0	0
2	0	19	0	0	0	0	0	0	0	0	0	1	0	0
3	4	0	143	0	3	0	0	0	0	11	1	1	0	0
4	0	0	0	13	10	0	0	0	0	1	0	0	0	0
5	3	0	1	0	398	0	0	1	12	5	0	0	0	0
6	0	0	0	0	0	41	0	6	20	0	0	0	0	0
7	0	0	0	0	0	0	104	14	31	1	0	0	0	0
8	0	0	0	0	0	2	6	231	83	0	0	0	0	0
9	0	0	0	0	5	3	8	31	1015	76	0	0	0	0
10	0	0	1	0	4	0	0	0	104	732	0	0	0	0
11	0	0	1	0	0	0	0	0	0	20	100	0	0	0
12	1	0	0	0	0	0	0	0	1	2	1	141	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	418	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	135

Ek 23 Loukia 70% veri seti için 2B ESA modelinin hata matrisi.

Sın.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	84	0	0	0	2	0	0	0	0	0	0	0	0	0
2	0	20	0	0	0	0	0	0	0	0	0	0	0	0
3	1	0	159	0	1	0	0	0	1	1	0	0	0	0
4	0	0	0	19	5	0	0	0	0	0	0	0	0	0
5	1	0	2	0	413	1	0	1	1	1	0	0	0	0
6	0	0	0	0	0	62	0	0	5	0	0	0	0	0
7	0	0	0	0	1	0	137	6	5	1	0	0	0	0
8	0	0	0	0	0	0	1	312	9	0	0	0	0	0
9	0	0	0	0	0	5	0	8	1092	32	1	0	0	0
10	0	0	0	0	0	0	2	0	39	800	0	0	0	0
11	0	0	0	0	0	0	0	0	0	2	119	0	0	0
12	1	0	0	0	0	0	0	0	0	0	0	145	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	418	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	135

Ek 24 Loukia 70% veri seti için 3B+2B ESA modelinin hata matrisi.

Sın.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	82	0	2	0	0	0	0	0	0	0	0	2	0	0
2	0	20	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	162	0	1	0	0	0	0	0	0	0	0	0
4	0	0	1	19	4	0	0	0	0	0	0	0	0	0
5	1	0	1	0	416	0	1	0	0	1	0	0	0	0
6	0	0	0	0	0	62	0	0	5	0	0	0	0	0
7	0	0	0	0	1	0	136	3	9	1	0	0	0	0
8	0	0	0	0	0	0	0	312	9	1	0	0	0	0
9	0	0	1	0	1	3	0	3	1101	28	1	0	0	0
10	0	0	1	0	0	0	2	0	20	818	0	0	0	0
11	0	0	1	0	0	0	0	0	0	1	119	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	146	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	418	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	135

Ek 25 DFC13 30% veri seti için DVM modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	960	1	0	1	0	0	0	0	0	0	0	0	0	0	0
2	9	1009	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	556	0	0	0	0	0	0	0	0	0	0	0	0
4	6	1	0	878	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	905	0	0	0	1	0	0	0	3	0	0
6	0	0	0	0	0	236	1	0	0	0	0	0	0	0	0
7	0	0	0	2	0	0	1004	0	2	1	13	8	3	0	0
8	0	0	0	0	0	0	6	924	4	0	0	0	14	0	0
9	0	1	0	1	0	0	0	7	1059	8	1	8	3	0	0
10	0	0	0	0	0	0	2	2	17	960	9	2	5	0	0
11	0	0	0	0	1	0	15	2	11	18	1047	2	0	0	0
12	0	0	0	0	0	0	3	8	14	3	0	958	14	0	0
13	1	0	0	0	2	0	11	24	8	8	7	37	343	3	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	357	0
15	0	0	0	0	0	0	1	0	0	0	0	0	7	0	551

Ek 26 DFC13 30% veri seti için RO modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	960	1	0	1	0	0	0	0	0	0	0	0	0	0	0
2	10	1006	0	2	0	0	0	0	0	0	0	0	0	0	0
3	0	0	553	0	0	0	1	0	0	1	0	0	0	1	0
4	6	7	0	871	0	0	0	0	0	0	1	0	0	0	0
5	0	0	0	0	901	0	0	0	2	2	2	1	1	0	0
6	0	0	0	0	0	236	1	0	0	0	0	0	0	0	0
7	0	1	0	0	1	0	1009	0	1	1	13	7	0	0	0
8	0	0	0	0	1	0	6	915	11	1	0	5	7	2	0
9	0	3	0	0	11	0	0	0	1021	22	14	15	2	0	0
10	0	0	0	0	0	0	0	0	17	943	14	17	6	0	0
11	2	0	0	0	3	0	25	1	13	4	1042	4	2	0	0
12	0	0	0	0	0	0	5	0	25	10	6	943	11	0	0
13	0	0	0	0	3	0	18	15	10	13	8	57	316	4	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	357	0
15	0	0	0	0	0	0	3	3	0	0	0	0	1	4	548

Ek 27 DFC13 30% veri seti için 2B ESA modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	962	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	5	1013	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	556	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	885	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	909	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	237	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	1031	0	0	0	0	0	2	0	0
8	0	0	0	0	0	0	3	939	6	0	0	0	0	0	0
9	0	1	0	0	1	0	0	0	1078	8	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	997	0	0	0	0	0
11	0	0	0	0	0	0	6	0	0	0	1088	0	2	0	0
12	0	0	0	0	0	0	2	0	0	0	0	998	0	0	0
13	0	0	0	0	0	0	5	0	0	2	1	7	426	3	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	357	0
15	0	0	0	0	0	0	1	0	0	0	0	0	0	0	558

Ek 28 DFC13 30% veri seti için 3B+2B ESA modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	962	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	4	1014	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	556	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	885	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	909	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	237	0	0	0	0	0	0	0	0	0
7	0	0	0	1	0	0	1021	0	1	2	0	6	2	0	0
8	0	0	0	0	0	0	0	948	0	0	0	0	0	0	0
9	0	1	0	1	0	0	0	0	1083	0	0	3	0	0	0
10	0	0	0	0	0	0	0	0	0	997	0	0	0	0	0
11	0	0	0	0	0	0	1	0	0	0	1095	0	0	0	0
12	0	0	0	0	0	0	4	0	0	0	0	996	0	0	0
13	0	0	0	3	0	0	4	0	2	1	0	0	431	3	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	356	1
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	559

Ek 29 DFC13 50% veri seti için DVM modelinin hata matrisi.

Sın.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	686	1	0	0	0	0	0	0	0	0	0	0	0	0	0
2	7	720	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	397	0	0	0	0	0	0	0	0	0	0	0	0
4	2	1	0	629	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	645	0	0	1	1	0	1	0	1	0	0
6	0	0	0	0	0	169	1	0	0	0	0	0	0	0	0
7	0	0	0	2	0	0	724	0	0	1	6	4	1	0	0
8	0	0	0	0	0	0	4	660	5	0	0	0	8	0	0
9	0	1	0	0	0	0	0	2	761	3	0	8	2	0	0
10	0	0	0	0	0	0	0	1	3	701	4	0	3	0	0
11	0	0	0	0	0	0	2	0	4	6	768	2	1	0	0
12	0	0	0	0	0	0	3	5	5	3	1	695	3	0	0
13	0	0	0	0	1	0	8	12	5	5	5	29	250	2	0
14	0	0	0	0	0	0	0	0	0	0	0	0	1	254	0
15	0	0	0	0	0	0	0	0	0	0	0	0	1	0	398

Ek 30 DFC13 50% veri seti için RO modelinin hata matrisi.

Sın.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	687	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	12	715	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	395	0	0	0	1	0	0	0	0	0	0	1	0
4	5	5	0	621	0	0	1	0	0	0	0	0	0	0	0
5	0	0	0	0	644	0	0	0	1	2	2	0	0	0	0
6	0	0	0	0	0	169	1	0	0	0	0	0	0	0	0
7	0	1	0	0	0	0	725	0	0	1	7	4	0	0	0
8	0	0	0	0	1	0	4	654	7	1	1	4	4	1	0
9	0	1	0	0	2	0	0	0	744	10	7	12	1	0	0
10	0	0	0	0	0	0	0	0	8	682	7	10	5	0	0
11	2	0	0	0	0	0	12	0	5	4	755	4	1	0	0
12	0	0	0	0	0	0	1	0	17	6	2	684	5	0	0
13	0	0	0	0	3	0	10	10	7	6	7	36	234	3	1
14	0	0	0	0	0	0	0	0	0	0	0	0	0	255	0
15	0	0	0	0	0	0	3	3	0	0	0	0	0	2	391

Ek 31 DFC13 50% veri seti için 2B ESA modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	687	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	5	722	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	397	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	632	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	649	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	170	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	738	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	677	0	0	0	0	0	0	0
9	0	1	0	0	0	0	0	0	773	3	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	712	0	0	0	0	0
11	0	0	0	0	0	0	2	0	0	0	781	0	0	0	0
12	0	0	0	0	0	0	0	0	2	0	0	713	0	0	0
13	0	0	0	0	0	0	1	0	0	1	0	2	311	2	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	255	0
15	0	0	0	0	0	0	1	0	0	0	0	0	0	0	398

Ek 32 DFC13 50% veri seti için 3B+2B modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	687	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	1	726	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	397	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	632	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	649	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	170	0	0	0	0	0	0	0	0	0
7	0	0	0	3	0	0	734	0	0	0	0	0	1	0	0
8	0	0	0	0	0	0	0	677	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0	0	776	0	0	1	0	0	0
10	0	0	0	0	0	0	0	0	0	712	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	783	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	1	714	0	0	0
13	0	0	0	0	0	0	0	0	1	0	0	0	314	2	0
14	0	0	0	0	0	0	0	0	0	0	0	0	2	253	0
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	399

Ek 33 DFC13 70% veri seti için DVM modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	412	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	3	433	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	239	0	0	0	0	0	0	0	0	0	0	0	0
4	0	1	0	378	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	387	0	0	1	0	0	0	0	1	0	0
6	0	0	0	0	0	101	1	0	0	0	0	0	0	0	0
7	0	0	0	1	0	0	437	0	0	1	3	1	0	0	0
8	0	0	0	0	2	0	4	390	2	1	0	0	7	0	0
9	0	1	0	0	0	0	0	0	460	1	0	3	1	0	0
10	0	0	0	0	0	0	0	0	1	421	1	0	4	0	0
11	0	0	0	0	0	0	0	0	1	0	469	0	0	0	0
12	0	0	0	0	0	0	1	4	3	2	0	418	1	0	0
13	0	0	0	0	0	0	6	8	4	3	3	14	152	1	0
14	0	0	0	0	0	0	0	0	0	0	0	0	1	152	0
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	239

Ek 34 DFC13 70% veri seti için RO modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	412	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	6	430	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	238	0	0	0	1	0	0	0	0	0	0	0	0
4	1	3	0	375	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	388	0	0	0	1	0	0	0	0	0	0
6	0	0	0	0	0	101	1	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	439	0	0	1	3	0	0	0	0
8	0	0	0	0	1	0	5	389	4	1	0	1	5	0	0
9	0	2	0	0	1	0	0	0	444	4	9	5	1	0	0
10	0	0	0	0	0	0	0	0	2	414	3	3	5	0	0
11	1	0	0	0	0	0	6	0	0	2	459	2	0	0	0
12	0	0	0	0	0	0	1	0	8	4	1	410	5	0	0
13	0	0	0	0	0	0	5	6	3	4	4	22	145	1	1
14	0	0	0	0	0	0	0	0	0	0	0	0	0	153	0
15	0	0	0	0	0	0	1	1	0	0	0	0	0	0	237

Ek 35 DFC13 70% veri seti için 2B ESA modelinin hata matrisi.

C	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	412	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	2	434	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	239	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	379	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	389	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	102	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	443	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	406	0	0	0	0	0	0	0
9	0	1	0	0	0	0	0	0	465	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	427	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	470	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	429	0	0	0
13	0	0	0	0	0	0	0	0	0	3	0	0	187	1	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	153	0
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	239

Ek 36 DFC13 70% veri seti için 3B+2B ESA modelinin hata matrisi.

Sın.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	412	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	436	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	239	0	0	0	0	0	0	0	0	0	0	0	0
4	0	1	0	378	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	389	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	102	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	443	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	406	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0	0	466	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	426	1	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	470	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	428	1	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	190	1	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	153	0
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	239

Ek 37 Salinas Scene 30% veri seti için DVM modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	1406	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	2606	0	0	1	1	0	0	0	0	0	0	0	0	0	0
3	0	0	1369	0	11	0	0	0	0	3	0	0	0	0	0	0
4	0	0	0	966	10	0	0	0	0	0	0	0	0	0	0	0
5	0	0	17	6	1851	0	0	0	0	1	0	0	0	0	0	0
6	0	0	0	0	1	2770	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	1	0	2504	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	7157	0	18	0	0	0	0	715	0
9	0	0	0	0	0	0	0	0	4342	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	7	23	2243	13	5	0	0	1	3
11	0	0	1	0	0	0	0	0	0	9	738	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	1	1348	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	639	2	0	0
14	0	0	0	0	0	0	0	0	0	4	0	0	1	744	0	0
15	0	0	0	0	2	0	0	1087	0	1	0	0	0	0	3998	0
16	0	0	0	0	0	0	0	0	0	1	0	0	0	1	0	1263

Ek 38 Salinas Scene 30% veri seti için RO modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	1406	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	2605	0	0	0	0	0	1	0	0	0	0	0	0	1	1
3	0	0	1380	0	3	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	972	4	0	0	0	0	0	0	0	0	0	0	0
5	0	0	12	7	1854	1	0	0	0	0	0	1	0	0	0	0
6	0	0	2	0	0	2769	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	1	0	2499	4	0	0	0	0	0	0	1	0
8	0	0	0	0	0	0	0	7307	1	14	5	0	0	0	563	0
9	0	0	0	0	0	0	0	4	4333	4	0	0	0	1	0	0
10	0	0	20	0	0	1	0	5	23	2213	13	9	0	6	3	2
11	0	0	3	0	0	0	0	0	9	5	726	5	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	1349	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	636	5	0	0
14	0	0	0	0	0	0	0	2	0	2	0	0	6	738	1	0
15	0	0	0	0	0	0	0	1331	0	0	0	0	0	0	3757	0
16	0	0	0	0	0	0	0	1	0	4	0	0	0	0	3	1257

Ek 39 Salinas Scene 30% veri seti için 2B ESA modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	1406	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	2608	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	1383	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	974	2	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	1875	0	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	2771	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	2505	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	7851	0	3	0	0	0	0	36	0
9	0	0	0	0	0	0	0	0	4342	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	1	2294	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	747	1	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	1349	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	641	0	0	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	749	0	0
15	0	0	0	0	0	0	0	92	0	0	0	0	0	0	4996	0
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1265

Ek 40 Salinas Scene 30% veri seti için 3B+2B ESA modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	1406	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	2608	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	1383	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	939	34	0	0	0	0	0	3	0	0	0	0	0
5	0	0	1	0	1874	0	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	2771	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	2505	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	7839	0	7	0	0	0	0	44	0
9	0	0	0	0	0	0	0	0	4342	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	2295	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	1	747	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	1349	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	641	0	0	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	749	0	0
15	0	0	0	0	0	0	0	151	0	0	0	0	0	0	4937	0
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1265

Ek 41 Salinas Scene 50% veri seti için DVM modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	1004	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	1863	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	983	0	3	0	0	0	0	2	0	0	0	0	0	0
4	0	0	0	692	5	0	0	0	0	0	0	0	0	0	0	0
5	0	0	4	3	1331	0	0	0	0	1	0	0	0	0	0	0
6	0	0	0	0	1	1979	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	1	0	1789	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	5158	0	11	0	0	0	0	467	0
9	0	0	0	0	0	0	0	0	3101	1	0	0	0	0	0	0
10	0	0	0	0	0	0	0	2	15	1615	3	1	0	2	0	1
11	0	0	1	0	0	0	0	0	0	3	530	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	963	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	457	1	0	0
14	0	0	0	0	0	0	0	0	0	2	0	0	0	533	0	0
15	0	0	0	0	0	0	0	782	0	0	0	0	0	0	2852	0
16	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	902

Ek 42 Salinas Scene 50% veri seti için RO modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	1004	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	1862	0	0	0	0	0	0	0	0	0	0	0	0	1	0
3	0	0	987	0	1	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	690	7	0	0	0	0	0	0	0	0	0	0	0
5	0	0	4	4	1329	0	0	1	0	0	1	0	0	0	0	0
6	0	0	1	0	0	1979	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	2	0	1788	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	5238	1	9	1	0	0	0	387	0
9	0	0	0	0	0	0	0	0	3101	1	0	0	0	0	0	0
10	0	0	1	0	0	0	0	4	15	1604	4	4	0	4	1	2
11	0	0	1	0	0	0	0	0	4	1	524	4	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	963	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	455	3	0	0
14	0	0	0	0	0	0	0	1	0	2	0	0	4	528	0	0
15	0	0	0	0	0	0	0	809	0	0	0	0	0	0	2825	0
16	0	0	0	0	0	0	0	0	0	1	0	0	0	0	2	900

Ek 43 Salinas Scene 50% veri seti için 2B ESA modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	1004	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	1863	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	988	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	696	1	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	1339	0	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	1980	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	1790	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	5622	0	1	0	0	0	0	13	0
9	0	0	0	0	0	0	0	0	3102	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	1639	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	534	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	963	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	458	0	0	0
14	0	0	0	0	0	0	0	0	0	1	0	0	0	534	0	0
15	0	0	0	0	0	0	0	5	0	0	0	0	0	0	3629	0
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	903

Ek 44 Salinas Scene 50% veri seti için 3B+2B ESA modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	1004	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	1863	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	988	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	694	3	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	1339	0	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	1980	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	1790	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	5620	0	1	0	0	0	0	15	0
9	0	0	0	0	0	0	0	0	3102	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	1639	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	534	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	963	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	458	0	0	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	535	0	0
15	0	0	0	0	0	0	0	16	0	0	0	0	0	0	3618	0
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	903

Ek 45 Salinas Scene 70% veri seti için DVM modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	603	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	1118	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	591	0	1	0	0	0	0	1	0	0	0	0	0	0
4	0	0	0	414	4	0	0	0	0	0	0	0	0	0	0	0
5	0	0	3	1	798	0	0	0	0	1	0	0	0	0	0	0
6	0	0	0	0	0	1188	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	1	0	1073	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	3080	0	7	1	0	0	0	293	0
9	0	0	0	0	0	0	0	0	1860	1	0	0	0	0	0	0
10	0	0	1	0	0	0	0	0	8	971	2	0	0	1	0	0
11	0	0	0	0	0	0	0	0	0	1	319	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	578	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	275	0	0	0
14	0	0	0	0	0	0	0	0	0	2	0	0	0	319	0	0
15	0	0	0	0	2	0	0	389	0	0	0	0	0	0	1790	0
16	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1	540

Ek 46 Salinas Scene 70% veri seti için RO modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	603	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	1118	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	592	0	1	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	416	2	0	0	0	0	0	0	0	0	0	0	0
5	0	0	1	3	797	0	0	1	0	0	1	0	0	0	0	0
6	0	0	1	0	0	1187	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	1	0	1073	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	3176	1	5	0	0	0	0	199	0
9	0	0	0	0	0	0	0	0	1861	0	0	0	0	0	0	0
10	0	0	1	0	0	1	0	2	8	968	1	1	0	1	0	0
11	0	0	0	0	1	0	0	0	3	3	313	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	578	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	274	1	0	0
14	0	0	0	0	0	0	0	0	0	2	0	0	2	317	0	0
15	0	0	0	0	0	0	0	436	0	0	0	0	0	0	1745	0
16	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1	540

Ek 47 Salinas Scene 70% veri seti için 2B ESA modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	603	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	1118	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	593	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	418	0	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	803	0	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	1188	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	1074	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	3381	0	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0	0	1861	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	983	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	320	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	578	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	275	0	0	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	321	0	0
15	0	0	0	0	0	0	0	3	0	0	0	0	0	0	2178	0
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	542

Ek 48 Salinas Scene 70% veri seti için 3B+2B ESA modelinin hata matrisi.

Sm.No	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	603	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	0	1118	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	0	0	593	0	0	0	0	0	0	0	0	0	0	0	0	0
4	0	0	0	418	0	0	0	0	0	0	0	0	0	0	0	0
5	0	0	0	0	803	0	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	1188	0	0	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	1074	0	0	0	0	0	0	0	0	0
8	0	0	0	0	0	0	0	3378	0	0	0	0	0	0	0	3
9	0	0	0	0	0	0	0	0	1861	0	0	0	0	0	0	0
10	0	0	0	0	0	0	0	0	0	983	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	320	0	0	0	0	0
12	0	0	0	0	0	0	0	0	0	0	0	578	0	0	0	0
13	0	0	0	0	0	0	0	0	0	0	0	0	275	0	0	0
14	0	0	0	0	0	0	0	0	0	0	0	0	0	321	0	0
15	0	0	0	0	0	0	0	6	0	0	0	0	0	0	2175	0
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	542