

**UZAKTAN ALGILAMA VERİLERİNİN
DERİN ÖĞRENME İLE SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

Mustafa Emre DÖŞ

**Danışman
Doç. Dr. Murat UYSAL**

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

Temmuz 2020

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

UZAKTAN ALGILAMA VERİLERİNİN DERİN ÖĞRENME İLE
SINIFLANDIRILMASI

Mustafa Emre DÖŞ

Danışman
Doç. Dr. Murat UYSAL

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

Temmuz 2020

TEZ ONAY SAYFASI


Mustafa Emre DÖŞ tarafından hazırlanan “UZAKTAN ALGILAMA VERİLERİNİN DERİN ÖĞRENME İLE SINIFLANDIRILMASI” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 29 / 07 / 2020 tarihinde aşağıdaki jüri tarafından **oy birliği** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **Harita Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Doç. Dr. Murat UYSAL

Başkan : Dr. Öğr. Üyesi Abdullah VARLIK
Necmettin Erbakan Üniversitesi, Mühendislik Fakültesi

Üye : Doç. Dr. Mustafa YILMAZ
Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi

Üye : Doç. Dr. Murat UYSAL
Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi



Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu’nun
..... /..... /..... tarih ve
..... sayılı kararıyla onaylanmıştır.

.....
Prof. Dr. İbrahim EROL
Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

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

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

beyan ederim.

29/07/2020


Mustafa Emre DÖŞ

ÖZET

Yüksek Lisans Tezi

UZAKTAN ALGILAMA VERİLERİNİN DERİN ÖĞRENME İLE SINIFLANDIRILMASI

Mustafa Emre DÖŞ

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Harita Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Murat UYSAL

Bu araştırmada, uzaktan algılama platformları vasıtasıyla elde edilen görüntülerden kentsel nesnelerin otomatik olarak sınıflandırılması sorunu için Derin Öğrenme ağları önerilmiş ve önerilen ağlar kendi aralarında doğruluk, zaman kullanımı ve ağ karmaşıklığı gibi konularda karşılaştırılmışlardır. Günümüzde anlamsal bölütleme için geliştirilmiş Derin Öğrenme mimarilerinin, uzaktan algılanmış görüntülerde kentsel nesnelerin otomatik sınıflandırılmasında etkili olacağı düşüncesi ile UNet, SegNet ve PSPNet gibi anlamsal bölütlemeye kendini kanıtlamış mimariler kullanılmıştır. Sınıflandırma için kullanılan görüntüler Uluslararası Fotogrametri ve Uzaktan Algılama Birliği (UFUAB) kullanıma sunduğu Vaihingen ve Potsdam verileridir. Vaihingen veri setinin eğitim ve test kısmında ücretsiz bulut sistemi olan Google Colab kullanılmış ve bu tür ağların eğitiminde maliyetin düşürülmesi için büyük bir alternatif sunulmuştur. Potsdam veri setinin eğitim ve test aşamasındaysa bir iş istasyonu kullanılmıştır. Yapılan çalışmadaki tüm kodlar Python yazılım dili kullanılarak yazılmıştır. Çalışmadan elde edilen sonuçlara bakıldığında zaman; her iki veri seti içinde genel olarak SegNet daha başarılı performans göstermiştir. UNet' ten de SegNet' e yakın sonuçlar elde edilmiştir. Ancak PSPNet diğer iki mimariye göre daha kaba görünmektedir.

2020, ix + 56 sayfa

Anahtar Kelimeler: Uzaktan Algılama, Sınıflandırma, Derin Öğrenme, Evrimsel Sinir Ağları

ABSTRACT
M.Sc. Thesis

CLASSIFICATION OF REMOTE SENSING DATA WITH DEEP LEARNING

Mustafa Emre DÖŞ

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Geomatics Engineering

Supervisor: Assoc. Prof. Murat UYSAL

In this research, Deep Learning networks were proposed for the problem of automatic classification of urban objects from images obtained through remote sensing platforms, and the proposed networks were compared among themselves on issues such as accuracy, time use and network complexity. Today, proven architectures have been used in semantic segmentation such as UNet, SegNet and PSPNet with the thought that Deep Learning architectures developed for semantic segmentation will be effective in automatic classification of urban objects in remote sensed images. The images used for classification are Vaihingen and Potsdam data made available by the International Society for Photogrammetry and Remote Sensing (ISPRS). The free cloud system, Google Colab, has been used in the training and testing part of the Vaihingen dataset, and a great alternative has been offered to reduce costs in the training of such networks. A workstation was used during the training and testing phase of the Potsdam dataset. All the codes in the study were written using the Python software language. When the results obtained from the study are examined; SegNet performed more successfully in both data sets. Results similar to SegNet were obtained from UNet. However, PSPNet appears to be more rude than the other two architectures.

2020, ix + 56 pages

Keywords: Remote Sensing, Classification, Deep Learning, Convolutional Neural Networks

TEŐEKKÜR

Bu arařtırmanın konusu, deneysel alıřmaların ynlendirilmesi, sonuların deęerlendirilmesi ve yazımı ařamasında yapmıř olduęu byk katkılarında dolay tez danıřmanım Sayın Do. Dr. Murat UYSAL, her konuda neri ve eleřtirileriyle yardımlarını grdęm hocalarıma ve arkadařlarıma teőekkr ederim. Bu arařtırma boyunca maddi ve manevi desteklerinden dolay aileme teőekkr ederim.

Mustafa Emre DŐŐ
AFYONKARAHİSAR, 2020

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER DİZİNİ.....	iv
KISALTMALAR DİZİNİ	v
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ.....	viii
1. GİRİŞ	1
2. LİTERATÜR BİLGİLERİ	3
3. DERİN ÖĞRENME	6
3.1 Evrişimsel Sinir Ağları (ESA)	9
3.1.1 Evrişim Katmanı.....	12
3.1.2 Havuzlama Katmanı	13
3.2 Anlamsal Bölütleme	14
3.2.1 Unet	14
3.2.2 SegNet	17
3.2.3 PSPNet.....	19
4. MATERYAL VE METOT.....	22
5. UYGULAMA.....	26
5.1 Vaihingen Veri Seti Sonuçları	26
5.2 Potsdam Veri Seti Sonuçları	34
6. TARTIŞMA ve SONUÇ	44
7. KAYNAKLAR.....	52
ÖZGEÇMİŞ.....	56

KISALTMALAR DİZİNİ

Kısaltmalar

DESA	Derin Evrişimsel Sinir Ağı
DESA-LR	Derin Evrişimsel Sinir Ağı – Lojistik Regrasyon
DÖ	Derin Öğrenme
DVM	Destek Vektör Makinesi
ESA	Evrişimsel Sinir Ağı
GİB	Grafik İşlem Birimi
MİB	Merkezi İşlem Birimi
MO	Maksimum Olabilirlik
MÖ	Makine Öğrenmesi
PSPNET	Piramit Sahne Ayrıştırma Ağı
RO	Rastgele Orman
TBA	Temel Bileşenler Analizi
TEA	Tamamen Evrişimli Ağ
TSA	Tekrarlayan Sinir Ağları
UFUAB	Uluslararası Fotogrametri ve Uzaktan Algılama Birliği
YOK-LR	Yığın Oto-Kodlayıcı Lojistik Regrasyon
YSA	Yapay Sinir Ağları

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 3.1 Yapay zeka, MÖ, sinir ağları ve DÖ arasındaki ilişki.	6
Şekil 3.2 Algılayıcı ve çok katmanlı sinir ağı.	7
Şekil 3.3 AlexNet ağ yapısı.	7
Şekil 3.4 Derin öğrenme ve klasik makine öğrenmesi veri boyutuna göre performansları.	8
Şekil 3.5 MÖ ile DÖ arasındaki temel fark.	9
Şekil 3.6 Kedi görme sistemi hücreleri ile ESA katmanlarının karşılaştırılması.	10
Şekil 3.7 ESA genel mimari yapısı.	11
Şekil 3.8 Bir girdinin farklı seviyelerdeki özellik haritası, a) Düşük seviye b) Orta seviye c) Yüksek seviye özellik haritası.	12
Şekil 3.9 Evrişim katmanında yapılan filtreleme işlemlerinin genel bir temsili.	13
Şekil 3.10 Evrişim ve havuzlama katmanlarının görüntü üzerindeki etkisinin ortak gösterimi.	14
Şekil 3.11 UNet mimari yapısı.	15
Şekil 3.12 HeLa hücreleri üzerinde UNet yapısı. a) Ham görüntü, b) HeLa hücrelerin farklı renklerde gösterimi, c) UNet tahmini sınıfları, d) Ağı sınır piksellerini öğrenmeye zorlamak için piksel olarak kayıp ağırlığına sahip harita.	16
Şekil 3.13 Bilinen en popüler aktivasyon fonksiyonları.	16
Şekil 3.14 SegNet ağ mimarisi.	17
Şekil 3.15 Mnist veri seti üzerinden Yığın normalleştirme fonksiyonu. a) Doğruluğu ve adım sayısı, b) Yığın normalleştirme olmadan sigmoid kullanımı, c) Yığın normalleştirme ile kullanımı.	18
Şekil 3.16 2x2 boyutundaki maksimum havuzlama çekirdek yapısı ile kod çözücü kısmında endekslerin tekrar kullanılması.	19
Şekil 3.17 ADE20K verisindeki bağlamsal tahmin sorunları. a) Girdi görüntüleri, b) Gerçek zemin görüntüleri, c) TEK çıktı tahminleri, d) PSPNet çıktı tahminleri.	20
Şekil 3.18 PSPNet mimarisi genel görünüşü.	21
Şekil 4.1 Vaihingen veri seti eğitim alanları.	22

Şekil 4.2 Vaihingen veri setinde bulunan 1.bölge için. a) Ortofoto, b) Etiketli görüntü, c) Sınır pikselleri silinmiş etiketli görüntü.....	23
Şekil 4.3 Potsdam veri seti eğitim alanları.....	23
Şekil 4.4 Potsdam veri setinde bulunan 1.bölge için. a) Ortofoto, b) Etiketli görüntü, c) Sınır pikselleri silinmiş etiketli görüntü.....	24
Şekil 5.1 UNet için Vaihingen veri seti kayıp değer grafiği.....	27
Şekil 5.2 SegNet için Vaihingen veri seti kayıp değer grafiği.....	30
Şekil 5.3 PSPNet için Vaihingen veri seti kayıp değer grafiği. a) 35 epoka kadar olan kısım, b) son 15 epokluk kısım.....	33
Şekil 5.4 UNet için Potsdam veri seti kayıp değer grafiği.....	36
Şekil 5.5 SegNet için Potsdam veri seti kayıp değer grafiği.....	39
Şekil 5.6 PSPNet için Potsdam veri seti kayıp değer grafiği.....	42
Şekil 6.1 Vaihingen veri seti için, mimarilerde karıştırılan sınıflara ait karşılaştırma. a) Ortofoto görüntü, b) Gerçek zemin görüntüsü, c) Mimari tahmin görüntüsü	45
Şekil 6.2 Vaihingen veri seti için, mimarilerde ortofotodan kaynaklı sınır karmaşası. a) Ortofoto görüntüsü, b) Gerçek zemin görüntüsü, c) Mimari tahmin görüntüsü.....	46
Şekil 6.3 Potsdam veri seti için, mimarilerde ağaç sınıfının ortofoto ile gerçek zemin görüntülerinin birbirini tam uyumlu olmamasından kaynaklı yanlış sınır tahmini. a) Ortofoto görüntü, b) Gerçek zemin görüntüsü, c) Mimari tahmin görüntüleri.....	48
Şekil 6.4 Potsdam veri seti için, ortofoto görüntülerdeki yırtılmalardan kaynaklı sınır bilgilerinin yanlış tahmin edilmesi. a) Ortofoto görüntü, b) Gerçek zemin görüntüsü, c) Mimari tahmin görüntüleri.....	49

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 5.1 UNet, Vaihingen veri setinde eğitim aşamasından sınıflara göre sonuç değerler.	26
Çizelge 5.2 UNet, Vaihingen veri setinde test aşamasından sınıflara göre sonuç değerler.	27
Çizelge 5.3 UNet, Vaihingen veri setinde eğitim aşamasından elde edilen kappa değerleri.	28
Çizelge 5.4 UNet, Vaihingen veri setinden test aşamasında elde edilen kappa değerleri.	28
Çizelge 5.5 SegNet, Vaihingen veri setinde eğitim aşamasından sınıflara göre sonuç değerler.	29
Çizelge 5.6 SegNet, Vaihingen veri setinde test aşamasından sınıflara göre sonuç değerler.	29
Çizelge 5.7 SegNet, Vaihingen veri setinde eğitim aşamasından elde edilen kappa değerleri.	31
Çizelge 5.8 SegNet, Vaihingen veri setinde test aşamasından elde edilen kappa değerleri.	31
Çizelge 5.9 PSPNet, Vaihingen veri setinde eğitim aşamasından sınıflara göre sonuç değerler.	32
Çizelge 5.10 PSPNet, Vaihingen veri setinde test aşamasından sınıflara göre sonuç değerler.	32
Çizelge 5.11 PSPNet, Vaihingen veri seti için eğitim aşamasında elde edilen kappa değerleri.	34
Çizelge 5.12 PSPNet, Vaihingen veri seti için test aşamasında elde edilen kappa değerleri.	34
Çizelge 5.13 UNet, Potsdam veri seti için eğitim aşamasında sınıflara göre sonuç değerler.	35
Çizelge 5.14 UNet, Potsdam veri seti için test aşamasında sınıflara göre sonuç değerler.	35
Çizelge 5.15 UNet, Potsdam veri seti için eğitim aşamasında elde edilen kappa değerleri.	37
Çizelge 5.16 UNet, Potsdam veri seti için test aşamasında elde edilen kappa değerleri.	37

Çizelge 5.17 SegNet, Potsdam veri seti için eğitim aşamasında sınıflara göre sonuç değerleri.....	38
Çizelge 5.18 SegNet, Potsdam veri seti için test aşamasında sınıflara göre sonuç değerleri.....	38
Çizelge 5.19 SegNet, Potsdam veri seti için eğitim aşamasında elde edilen kappa değerleri.....	40
Çizelge 5.20 SegNet, Potsdam veri seti için test aşamasında elde edilen kappa değerleri.....	40
Çizelge 5.21 PSPNet, Potsdam veri seti için eğitim aşamasında sınıflara göre sonuç değerleri.....	41
Çizelge 5.22 PSPNet, Potsdam veri seti için test aşamasında sınıflara göre sonuç değerleri.....	41
Çizelge 5.23 PSPNet, Potsdam veri seti için eğitim aşamasında elde edilen kappa değerleri.....	43
Çizelge 5.24 PSPNet, Potsdam veri seti için test aşamasında elde edilen kappa değerleri.....	43

1. GİRİŞ

Uzaktan algılama platformları, yeryüzünün ve ona ait detayların görüntü olarak algılanması, kaydedilmesi, sınıflandırılması ve yorumlanmasına olanak sağlamaktadır. İnsan gözünün ayırt edemeyeceği dalga boylarında alınan bu görüntüler veri seti yelpazesini genişletip farklı görüş imkânlarını bize sunmuştur. Bu görüntülerin sınıflandırılması ve yorumlanması gibi işlem adımlarında insan faktörü önemli rol oynamaktadır. Ancak uzaktan algılama platformlarındaki gelişmelere paralel olarak elde edilen veri setlerinin çeşitliliği ve boyutları artmıştır. Bu durumun sonucu olarak yüksek veri boyutları ve detayların yorumlanması kısmında insan yetenekleri yetersiz kalmaktadır. Bu sebepten dolayı uzaktan algılamanın en büyük avantajlarından olan maliyet ve zaman boyutunda ise istenilen seviyeye ulaşılamamaktadır. Bilgisayar teknolojisindeki gerek donanımda gerekse yazılım kısmındaki gelişmeler farklı sınıflandırma yöntemleri için zemin hazırlamıştır. Yüksek boyutlardaki görüntülerin sınıflandırılma sorununa çözüm için hali hazırda birçok yöntem kullanılmıştır. Ancak bu yöntemler insan faktörüne çok fazla bağımlı olduğu için yine insan algısı sınırları içerisinde kalmaktadır. Bu faktörden ötürü yapılan çalışmalar belirli bir seviyeye gelmiştir, ancak gelişmeler sürekli olmamıştır.

Son yapılan çalışmalar ile Yapay Sinir Ağları (YSA) ve bilgisayar görüşü gibi yaklaşımlar çok ilgi görmektedir. Bu yaklaşımın temelinde olan Derin Öğrenme ağları (DÖ) gibi yapılar ise farklı disiplinlerdeki bilim dallarında bulunan sorunlara cevap olarak tercih edilmeye başlanmıştır. DÖ' nün geçmişi eskiye dayanmaktadır, ancak bilgisayar teknolojisindeki eksiklikler nedeniyle geçmişte yapılan çalışmalar sığ kalmışlardır. Günümüzde bilgisayar teknolojisindeki gelişmeler sayesinde bu yapılara ilgi tekrar artmaktadır. DÖ yapıları kullanıcıya bağlı kalmadan kendini geliştirebilen bir yapıdır. Bir insanın tüm yaşamı boyu öğrenmesi gibi bu yapılarda sabit değerlere bağlı kalmadan kendini geliştirip daha iyi sonuçlar alınmasında destek olmaktadır.

DÖ' nün genellikle görüntülerin sınıflandırılması görevlerinde kullanılan Evrimsel Sinir Ağları (ESA) mimarisinde son on yılda çok önemli gelişmeler görülmüştür. ESA yapısında sunulan görüntülerde bulunan objelerin tespiti veya görüntülerdeki tüm

piksellerin bir sınıfa atanması olan anlamsal bölütleme görevlerinde kullanılmaktadır. Anlamsal bölütleme mimarileri uzaktan algılama verilerinin sınıflandırılmasında iyi bir alternatif olabilirler.

Uzaktan algılama görüntülerindeki objelerin otomatik olarak sınıflandırılması, araştırmacıların üzerinde durduğu güncel bir sorundur. Bu çalışmada, bu soruna alternatif bir çözüm olarak DÖ yapılarının performansı değerlendirilmiştir. Değerlendirme yapılırken DÖ' nün anlamsal bölütleme için kullanılan ESA mimarisine sahip UNet, SegNet ve PSPNet ağıları kullanılmıştır. Anlamsal bölütleme ile görüntüdeki tüm piksellerin tanımlanan herhangi bir sınıfa atanması ile görüntü otomatik olarak sınıflandırılmış olur. Bu yüzden anlamsal bölütlemeye sahip mimariler tercih edilmiştir. Veri seti olarak Uluslararası Fotogrametri ve Uzaktan Algılama Birliği (UFUAB)' in uzaktan algılama görüntülerinin, otomatik sınıflandırılması çalışmalarında kaynak olarak sunduğu Vaihingen ve Potsdam veri setleri kullanılmıştır.

2. LİTERATÜR BİLGİLERİ

Uzaktan algılama platformlarından elde edilen görüntüler, içerisinde farklı objelere ait detaylar barındırır. Bu detayların karmaşıklığını gidermek için, kullanıcılar görüntülerin sınıflandırılması ile şehir planlama, tarım alanlarının takibi, mühendislik çalışmaları vb. gibi birçok alanda altlık olarak kullanılmaktadır. Araştırmacılar uzaktan algılama görüntülerinin sınıflandırma işlemini otomatik olarak, yüksek doğruluk ve kısa zamanda sonuç elde etmek için zaman içinde farklı yöntemler denemişlerdir.

Pal ve Mather (2006), klasik makine öğrenmesi yapısı Destek Vektör Makineleri (DVM) ile Maksimum Olabilirlik (MO) ve Yapay Sinir Ağlarını (YSA) karşılaştırmışlardır. Sonuçlar, DVM'lerin MO ve YSA sınıflandırıcısından daha yüksek bir sınıflandırma doğruluğu elde ettiğini ve DVM'nin küçük eğitim veri kümeleri ve yüksek boyutlu verilerle kullanılabilmesini göstermektedir. DVM'nin bir dezavantajı olarak, YSA sınıflandırıcısı gibi etkili kullanımının kullanıcı tanımlı birkaç parametrenin değerlerine bağlı olması olduğu belirtilmiştir. Bu dezavantajdan ve büyük veri kümeleri için etkinliği az olan DVM'ler günümüz sorunlarına cevap verememektedir.

Chen vd. (2014), hiperspektral görüntüler için Yığın Oto-Kodlayıcı Lojistik Regrasyon (YOK-LR) mimarisini önermişlerdir. Bu çalışmada ilk olarak Temel Bileşenler Analizi (TBA) ile boyut küçültme yapılmış, daha sonra veriler düzleştirilip derin özellikler elde etmek için oto-kodlayıcılara katmanlar halinde verilmiştir. YOK-LR mimarisinden elde edilen sonuç ürünler DVM yapısı ile karşılaştırılmış ve daha yüksek genel doğruluk elde edilmiştir. YOK-LR yapısının dezavantajı olarak eğitim süresinin uzun olmasıdır. Ancak telafi olarak DVM'ye göre test süresi daha azdır.

Castelluccio vd. (2015), uzaktan algılama görüntüleri için ESA mimarisini önermişlerdir. Bu çalışmaya göre bir ESA yapısını sıfırdan eğitmek yerine GoogleNet ve CaffeNet gibi önceden eğitilmiş ağları uzaktan algılama verilerine uygun hale getirip kullanmak sonuç ürünlerde önemli bir fark yaratmaktadır.

Yue vd. (2015), hiperspektral görüntüler için hem spektral hem de uzamsal özellikler kullanılarak Derin Evrişimsel Sinir Ağı (DESA) ve lojistik regrasyon (LR) melezi bir mimari önermişlerdir (DESA-LR). DESA-LR yapısı ilk defa hiperspektral görüntüler için kullanılmıştır. Önerilen teknik iki aşamadan oluşur. İlk olarak, spektral ve uzamsal özellik harita oluşturma algoritması sunulmuştur. İkinci olarak DESA-LR yapısı ile üst düzey özellikler elde edilir. Önerilen yöntem DVM yapısı ile karşılaştırılmıştır. Sonuç ürünlerde DESA-LR yapısı ile %95,18 genel doğruluk değeri elde edilmiştir. Bir kez daha DÖ yapılarının üstünlüğü ortaya koyulmuştur.

Volpi ve Tuia (2016), kodlayıcı-kod çözücü yapıları ESA mimarisini 9 cm ve 5 cm çözünürlüğündeki Vaihingen ve Potsdam verisine uygulamışlardır. Üç farklı ESA yapısı ile karşılaştırma yapılmış ve sonuç olarak kodlayıcı-kod çözücü ESA yapısında %88,85 genel doğruluk ile en iyi sonuç elde edilmiştir.

Kussul vd. (2017), Landsat-8 ve Sentinel-1A uydu görüntülerinde mahsul izleme ve değerlendirme çalışması için DÖ kullanılmıştır. Bu çalışmada tek tarihli görüntüler üzerinden ESA, DVM ve Rastgele Orman (RO) mimarileri karşılaştırılmıştır. DVM için büyük veri uygulamaları ve geniş alan sınıflandırma problemleri için uygun olmadığı, RO sınıflandırıcısını besleyecek birden fazla özellik tanımlanması gerekliliği ortaya koyulmuştur. Önerilen ESA yapısı ile %94,6'lık genel doğruluk elde edilmiş ve klasik makine öğrenmesi yöntemlerinden üstünlüğü gösterilmiştir.

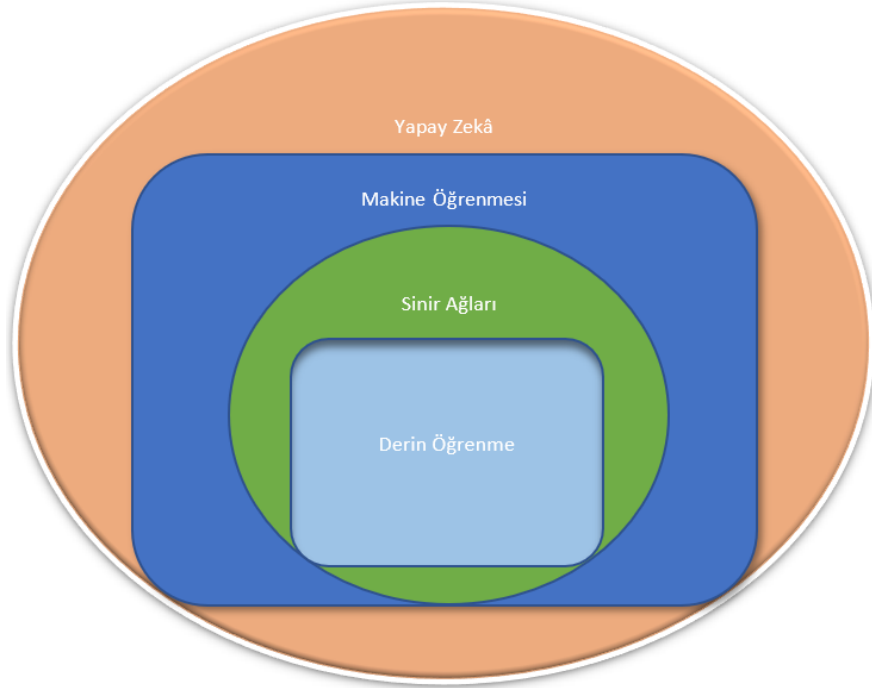
Venkatesan ve Prabu (2019), hiperspektral görüntüler üzerinde Tekrarlayan Sinir Ağları (TSA) modeli ile ESA yapısını karşılaştırmışlardır. Hiperspektral pikselleri bilgi dizisi olarak analiz edebilen ve ağ akıl yürütmesi yoluyla ek bilgi kategorilerini tanımlayabilen tek model TSA olduğu söylenmiştir. TSA ile ESA mimarisinden daha sonuçlar elde edildiği belirtilmiştir.

Ancak incelenen çalışmalarda, önerilen DÖ'nin anlamsal bölümlenmede eksik kaldıkları düşünülmüştür. Anlamsal bölümlenme konusu son zamanlarda DÖ yapısının ESA mimarisi ile üstesinden gelinmeye çalışılan alanıdır. Yapılacak çalışmada uzaktan algılanmış görüntüler üzerinde anlamsal bölümlenme ile görüntüde bulunan detayların

tekel ve birbirleri arasındaki ilişkiler farklı ESA yapıları ile incelenerek anlamlandırılıp sınıflandırılmayı çalışılacaktır.

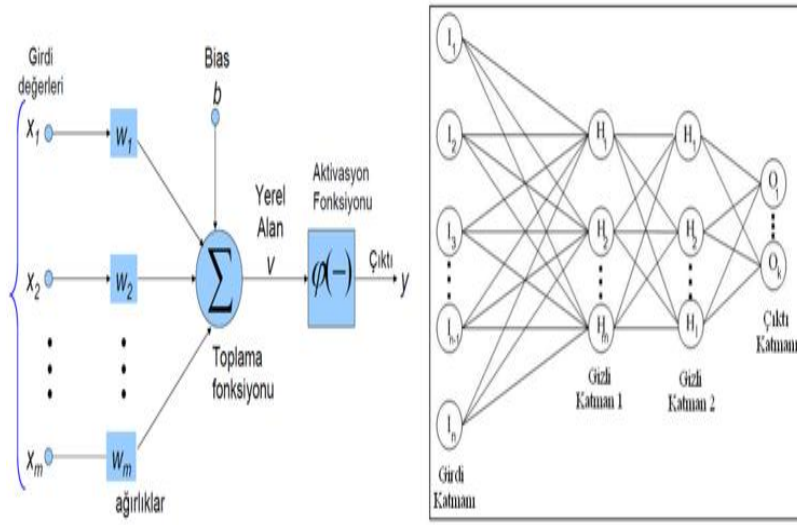
3. DERİN ÖĞRENME

Sinir ağıları, MÖ nün bir alt alanıdır ve DÖ ortaya çıkaran bu alt alandır. Şekil 3.1' den görüleceği üzere MÖ ve DÖ birbirinden farklı alanlar değil aksine iç içedir.




Şekil 3.1 Yapay zekâ, MÖ, sinir ağıları ve DÖ arasındaki ilişki.

DÖ yapıları yeni bir yaklaşım gibi görünse de tarihi daha eskiye dayanmaktadır. McCulloch ve Pitts (1943), sinir aktivitesinin ya hep ya hiç karakteri nedeniyle, sinirsel olaylar ve bunlar arasındaki ilişkileri önermeli mantık yoluyla ele alınabileceğini söylemiştir. Rosenblatt (1958), bir sinir hücrelerini matematiksel olarak Şekil 3.2' den görüleceği üzere modellemiş ve buna "Algılayıcı" ismini vermiştir. Ancak bu zamandan sonra sinir ağı çalışmaları uzun bir süre duraklamaya girmiştir. Bunun sebebi Minsky ve ark. (1969), algılayıcıların bilimsel bir değerinin olmadığı ve doğrusal olmayan problemlerin üstesinde gelemeyeceğini söylemiş ve örnek olarak XOR probleminin algılayıcılar ile çözülüyor oluşunu göstermişlerdir. Rumelhart ve ark. (1986), çok katmanlı sinir ağ yapısını önermiş ve doğrusal olmayan problemlerde çözüm önerisi getirmişlerdir.




Şekil 3.2 Algılayıcı ve çok katmanlı sinir ağı.

LeCun ve ark. (1998), geri yayımlı ESA mimarisi olan LeNet yapısı ile el yazısı ve post kutuları üzerindeki yazıları okuma konusunda başarılı sonuçlar elde ettiler. Görüntü tanıma probleminde devrim niteliğinde olan bu çalışma yeterli donanımsal ve yazılımsal gelişmeler olmadığı için uzun bir süre klasik makine öğrenme tekniklerinin gölgesinde kaldı. Krizhevsky ve ark. (2012), Büyük Ölçekli Görsel Tanıma Yarışmasında yine bir ESA mimarisi olan AlexNet ile %16,4 hata oranı ile birinci olmuştur. Bu gelişmeden sonra DÖ yapılarına ilgi tekrar artmış ve birçok çalışma yapılmıştır. Şekil 3.3' de AlexNet ağ yapısının ikili ağ yapısı temsil edilmiştir.



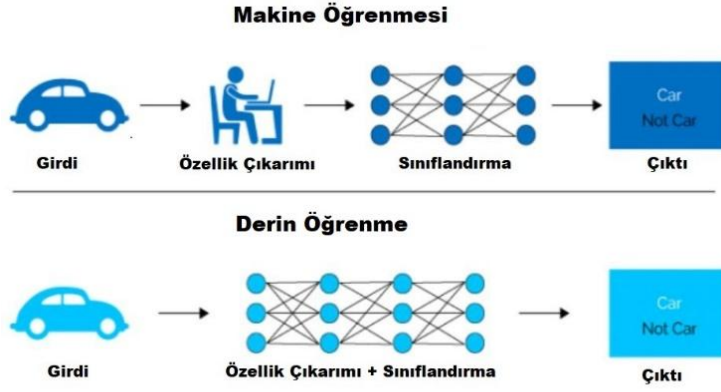
Şekil 3.3 AlexNet ağ yapısı.

Son zamanlarda uzaktan algılama teknolojisindeki gelişmeler sayesinde veri elde etme yöntemlerinin çeşitliliği ve veri setlerinin boyutları sebebiyle klasik MÖ yapıları istenilen sonuçları verememektedirler. DÖ son zamanlarda yapılan çalışmalarda büyük veri setlerinin boyutu ve karmaşıklığı ile başa çıkabileceğini kanıtlamıştır (Ding vd. 2016, Ishii vd. 2015).



Şekil 3.4 Derin öğrenme ve klasik makine öğrenmesi veri boyutuna göre performansları.

MÖ yapıları, yapay zekâ temeline dayalı olarak çalışmaktadır. MÖ algoritmalarında, ağın eğitileceği eğitim verileri hazırlanırken ilgili görüntüye dair özelliklerin kullanıcı tarafından hazırlanması gerekmektedir. Bu yüzden, kullanıcıya bağımlı bir özellik öğretimi işlemi mevcuttur. DÖ yapıları MÖ' nün bir alt yapısı olmasına rağmen, Şekil 3.5' de temsil edildiği şekilde klasik MÖ tekniklerinden farklı olarak kullanıcı bazlı olarak seçilen özelliklerin ağa sunulması kısmı tamamen elenmiştir. Ağa sunulan etiketli veri setleri üzerinden özellik haritalarının tam otomatik olarak belirlenmesi sağlanmıştır. Bu fark sayesinde DÖ yapıları klasik MÖ tekniklerine göre çok daha avantajlı bir konuma geçmektedir ve bu sayede popülerliği gün geçtikçe artmaktadır (Eitel vd. 2015).




Şekil 3.5 MÖ ile DÖ arasındaki temel fark.

Günümüzde DÖ mimarileri ile yol çıkarımı (Mnih ve Hinton 2012), bina çıkarımı (Yang vd. 2018) ve tarım arazilerinin izlenmesi (Zhong vd. 2018) gibi birçok görevde kullanılmış ve tatmin edici sonuçlar elde edilmiştir.

3.1 Evrimsel Sinir Ağları (ESA)

YSA yapılarında bulunan yapay sinir hücreleri nasıl insan sinir hücrelerinden esinlenilmişse, ESA mimari yapısı da hayvanlarda bulunan görme sisteminden esinlenilmiştir. Hubel ve Wiesel (1962), 20.yüzyıl ortalarında kedilerin görme merkezinde iki ana hücre tespit etti. İlk tip basit olan hücreler, belirli uzamsal konumlara yerleştirildiğinde açık veya koyu çubuklara yanıt verir. Her hücre çubuğun açısı bu tercih edilen yönlendirmeler (bir yönelim ayar eğrisi yaratarak) değişikçe yanıtı düşerek, en çok ateş ettiği çubuğun yönüne sahiptir. İkinci tip olan karmaşık hücreler, daha az katı tepki profiline sahiptir. Ancak yakınlardaki birkaç farklı konumdaki bir çubuğa olduğu kadar güçlü tepki verirler. Hubel ve Wiesel bu karmaşık hücrelerin hepsi aynı tercih edilen konumlara sahip birkaç basit hücreden girdi aldıkları sonucuna varmıştır. Şekil 3.6' da ki karşılaştırma gibi buradan ESA mimarilerinde bulunan evrişim ve havuzlama katmanları kedilerdeki hücre tipine benzemektedir

(Lindsay 2020).




Şekil 3.6 Kedi görme sistemi hücreleri ile ESA katmanlarının karşılaştırılması.

Bu ağ yapısı ilk olarak Fukuşima tarafından 1987’ de ortaya atılmıştır (Fukushima 1987). O zamanda var olan bilgisayarlar bu ağ yapısını hesaplamakta yeterli olmadığı için popüler olarak kullanılmamıştır. 1998 yılında LeCun gradyan tabanlı bir ESA mimarisi ile el yazısı okumada başarılı sonuçlar elde etmişlerdir (LeCun vd. 1998). Bu tarihten sonra yine bir unutulma sürecine giren ESA mimarileri, hesaplamada bilgisayarın Merkezi İşlem Birimleri (MİB) yerine, Grafik İşlem Birimlerinin (GİB) kullanılması ile büyük gelişmeler göstermiştir.

Günümüzde ESA mimarilerinin tekrar gündeme gelip popüler olmasında AlexNet’ in ImageNet yarışmasındaki başarısının payı büyüktür. İlerleyen yıllarda ESA mimarileri kendilerini kanıtlamak için bu yarışmada boy göstermiştir. Mevcut mimarilerde popüler olan VGGNet (Simonyan ve Zisserman 2015) 2014 yılında ImageNet yarışmasında genel kategoride %11,7 hata oranı ile ikinci olmuştur. Yine aynı yıl ana kategoride %6,7’ lik hata oranı ile GoogLeNet (Szegedy vd. 2015) birinci olmuştur. Diğer mimarilerden farklı olarak GoogLeNet’ de tam bağlantılı katmanlar kullanılmamış ve 22 evrişim katmanından oluşturulmuştur. 2015 yılında ResNet (He vd. 2016) derinliği daha da arttırarak 152 katmanlı bir mimari önerdi. Bu sayede %3,7’ lik hata oranı ile

tüm kategorilerde birinci olmuşlardır. O zamana kadar teoride çok katmanlı yapılar daha iyi sonuç vermeleri beklenirken, aslında pratikte öyle olmamaktadır. ResNet mimarisi bu sorunun derin mimarilerin optimizasyonun zor olduğunu, bu yüzden bu sorunun optimizasyon sorunu olduğunu öne sürerek kalıntı blok yapısını önerdiler. ResNet mimarisi ile elde edilen sonuçlar insan hassasiyetinin bile üzerindedir.


ESA tipik olarak seyrek etkileşimlere sahiptir. Bu, çekirdeği girişten daha küçük yaparak gerçekleştirilir. Örneğin bir görüntüyü işlerken, giriş görüntüsünde binlerce veya milyonlarca piksel olabilir. Ancak yalnızca onlarca veya yüzlerce pikseli kaplayan çekirdekli kenarlar gibi küçük, anlamlı özellikler tespit edebiliriz. Bu hem daha az bellek gereksinimi sağlar ve istatistiksel verimliliği artırır (Goodfellow vd. 2015). Şekil 3.7’ de basit bir ESA mimarisi gösterilmiştir.



Şekil 3.7 ESA genel mimari yapısı.

Şekil 3.7’ den de görüleceği üzere ESA mimarisi özellik öğrenimi ve sınıflandırma olmak üzere iki ana yapıdan oluşur. Ağın özellik çıkarımı kısmında düşük ve orta düzeyinde evrişimli katmanlar ve havuzlama katmanları olmak iki tür katman vardır. Üst düzey özellikler, alt düzey katmanlardan yayılan özelliklerden türetilir. Özellikler en yüksek katmana veya düzeye ilerledikçe, özelliklerin boyutları sırasıyla evrişimli ve havuzlama işlemleri için çekirdeğin boyutuna bağlı olarak azalır. Ancak sınıflandırma doğruluğunu sağlamak için girdi görüntülerinin daha iyi özellik haritalarının sayısı genellikle artmıştır. ESA’ nın son katmanının çıkışı, sınıflandırma katmanı adı verilen tam bağlantılı bir ağın girişi olarak kullanılır (Alom vd. 2018). Şekil 3.8’ de evrişim

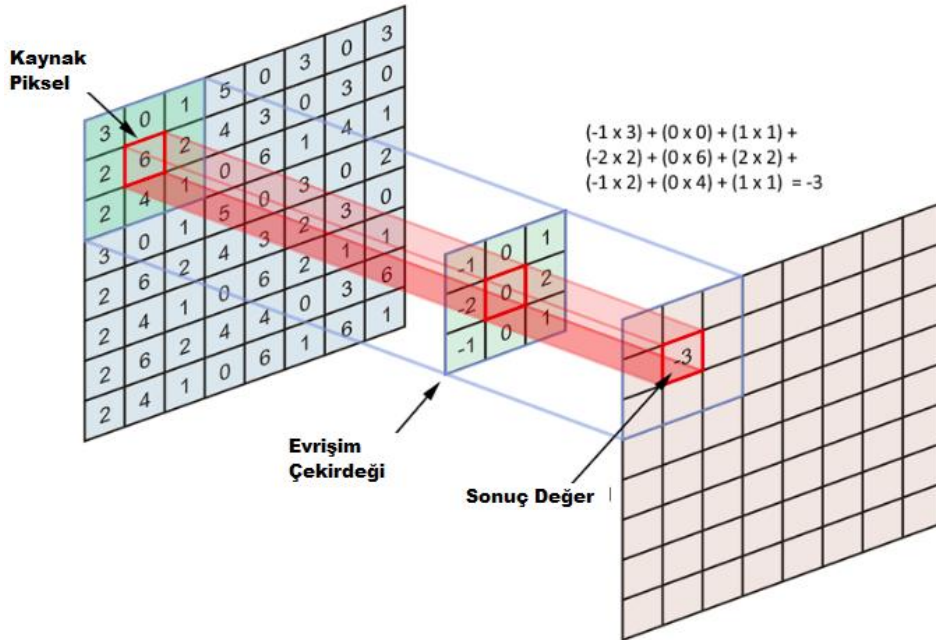
katmanlarında öğrenilen özelliklerin seviyeleri temsil edilmiştir.



Şekil 3.8 Bir girdinin farklı seviyelerdeki özellik haritası, a) Düşük seviye b) Orta seviye c) Yüksek seviye özellik haritası.

3.1.1 Evrişim Katmanı


Evrişimsel katmandaki ilk katman, girdinin evrilmesidir. Bir görüntünün giriş boyutunu $32 \times 32 \times 3$ olduğunu varsayalım. Bu evrişimli katmanları ifade etmenin en iyi yolu görüntünün sol üst köşesinde parlayan bir el feneri hayal etmektir. El feneri 5×5 bir alanı kaplamaktadır, şimdi bunlar giriş görüntüleri üzerinde kayacaktır. DÖ' de bu fenerlere çekirdek (genel olarak filtre) denir ve parladığı alana alıcı alanlar denir. Çekirdeğin giriş ile aynı olması gerekir, böylece boyutlar $5 \times 5 \times 3$ olur. Çekirdeğin ilk konumu sol üst köşede olabilir. Çekirdek, giriş görüntülerinin etrafındaki kıvrımın üzerinden kayarak, çekirdekteki değerleri görüntünün Şekil 3.9' da gösterildiği gibi orijinal girdisiyle çarpar. Bu çarpmaların hepsi toplanır ve tek bir sayı elde edilir (Pandya vd. 2019). Bu işlem diğer görüntüler için tekrar edilir ve bu işlemlerin yapıldığı kısma evrişim katmanı ismi verilir.



Şekil 3.9 Evrişim katmanında yapılan filtreleme işlemlerinin genel bir temsili.

3.1.2 Havuzlama Katmanı

Bir havuzlama katmanı genellikle birbirini izleyen iki evrişim katmanı arasına dahil edilir. Havuzlama katmanı, temsili aşağı örnekleyerek parametrelerin sayısını ve hesaplamayı azaltır. Ağın bu katmanında öğrenilen bir parametre yoktur. Giriş verisinin kanal sayısını sabit tutarak yükseklik ve genişlik bilgisini azaltır. Ancak Hinton' un kapsül teorisine (Sabour vd. 2017) göre verideki önemli bazı bilgilerin kaybolmasına sebep olduğu için başarımdan ödün vermektedir. Günümüz de en popüler kullanılan yöntem ise maksimum havuzlama yöntemidir (Zhou ve Chellappa 1988). Bu yöntemde göre seçilen havuzlama çekirdek boyutu giriş verisindeki kapladığı bölgede bulunan en yüksek değeri çıktı olarak vermektedir. Şekil 3.10' da evrişim ve havuzlama katmanının görüntüden öğrenilen özelliklerin nasıl alt katmanlara iletildiği gösterilmektedir.




Şekil 3.10 Evrişim ve havuzlama katmanlarının görüntü üzerindeki etkisinin ortak gösterimi.

3.2 Anlamsal Bölütleme

Anlamsal bölütleme, ağa sunulan görüntüdeki tüm piksellerin bir sınıfa atanması görevi olarak tanımlanabilir. Bu görev için günümüzde birçok ağ yapısı önerilmiştir. Bunlardan göze çarpanlar UNet (Ronneberger vd. 2015), SegNet (Badrinarayanan vd. 2016) ve Piramit Sahne Ayrıştırma Ağı (PSPNet) (Zhao vd. 2017) gibi yapılar elde ettikleri başarılı sonuçlar ile bu araştırmanın konusu olmuştur. Anlamsal bölütleme sadece hedefin kategorisini, boyutunu ve miktarını değil, aynı zamanda doğru sınır ve pozisyonu da üretebilir. Bu nedenle, uzaktan algılama için uygundur.


3.2.1 Unet

UNet yapısının şekli u harfine benzediği için böyle isimlendirilmiştir. Mimari, bağlamı yakalamak için evrişimsel ve havuzlama (alt örnekleme) katmanları ile derin özellikleri öğrenip buna paralel simetrik bir genişleme yolundan oluşur. UNet ilk olarak 2015 yılında Uluslararası Biyomedikal Görüntüleme Sempozyumu' da önerilmiştir. Böyle bir ağın çok az görüntülerden eğitilebildiğini ve sinirsel yapıların elektron mikroskopik yığınlarda bölütlemesi için önceki en iyi yöntemden (Cirean vd. 2012) daha iyi performans göstermektedir. Bu sempozyumdaki hücre izleme görevi kategorisini büyük bir farkla kazanmıştır (Ronneberger vd. 2015).



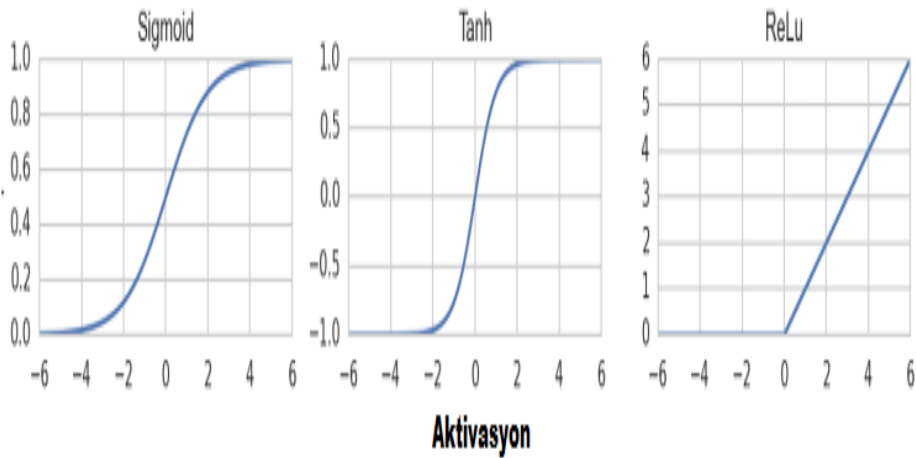
Şekil 3.11 UNet mimari yapısı.

UNet' in genel ağ mimarisi Şekil 3.11' de gösterilmektedir. Bir daralma yolundan (sol taraf) ve genişleme yolundan (sağ taraf) oluşur. Daralma yolu, evrişimsel bir ağın tipik mimarisini izler. Her biri aktivasyon fonksiyonu olarak kullanılan rektifiye edilmiş doğrusal bir birim (ReLU) ve aşağı örnekleme için adım 2 ile 2x2 maksimum havuzlama işleminden sonra iki 3x3 evrişimsel çekirdeğin tekrar tekrar uygulanmasından oluşur. Her alt örnekleme adımında, özellik kanallarının sayısı ikiye katlanır. Genişleme yolundaki her adım, özellik haritasının yukarı örneklemesinden sonra, özellik kanallarının sayısını yarıya indiren 2x2 evrişimden, daralma yolunda karşılık gelen kırpılmış özellik eşlemesiyle birleştirme ve iki 3x3' ten oluşur. Evrişimleri, her bir ReLU izler. Her evrişimde sınır piksellerinin kaybolması nedeniyle kırpma gerekmektedir. Son katmanda, her bir 64 bileşenli özellik vektörünü istenen sayıda sınıfa eşlemek için 1x1 evrişim kullanılır. Toplamda ağın 23 evrişimli katmanı vardır.



Şekil 3.12 HeLa hücreleri üzerinde UNet yapısı. a) Ham görüntü, b) HeLa hücrelerin farklı renklerde gösterimi, c) UNet tahmini sınıfları, d) Ağrı sınır piksellerini öğrenmeye zorlamak için piksel olarak kayıp ağırlığına sahip harita.


Burada ismi geçen aktivasyon fonksiyonu yapıları modele doğrusal olmama özelliği katmaktadır. Çünkü DÖ doğrusal olmayan yapıya sahip problemlerin çözümünde diğer yöntemlere göre daha etkili olduğu için (örneğin XOR problemi), DÖ çözülmeye çalışılan problemler genelde doğrusal olmayan problemlerdir. Evrişim çekirdeği ile girdi görüntüsündeki karşılık gelen kısımda yapılan işlem sonrası elde edilen değerler doğrusal olmama haline dönüştürülmesi aktivasyon fonksiyonları ile yapılmaktadır. Bu aktivasyon fonksiyonlarından bazıları Şekil 3.13’ de fonksiyon grafikleri verilen Sigmoid, Tanh ve ReLU’ dur.



Şekil 3.13 Bilinen en popüler aktivasyon fonksiyonları.


3.2.2 SegNet

SegNet' in genel ağ yapısı Şekil 3.13' te gösterildiği gibi, bir kodlayıcı ağına (sol taraf) ve buna karşılık gelen bir kod çözücü ağına (sağ taraf), ardından son piksel olarak bir sınıflandırma katmanına sahiptir. Kodlayıcı ağın mimarisi topolojik olarak VGG16 ağındaki 13 evrişimli katmanla aynıdır (Simonyan ve Zisserman 2014). Kod çözücü ağda dolayısıyla 13 evrişim katmanı vardır. Kod çözücü ağda, düşük çözünürlüklü kodlayıcı özellik eşleşmelerini piksel olarak sınıflandırmak için tam giriş çözünürlüğü özellik eşleşmeleriyle eşlemektir.



Şekil 3.14 SegNet ağ mimarisi.

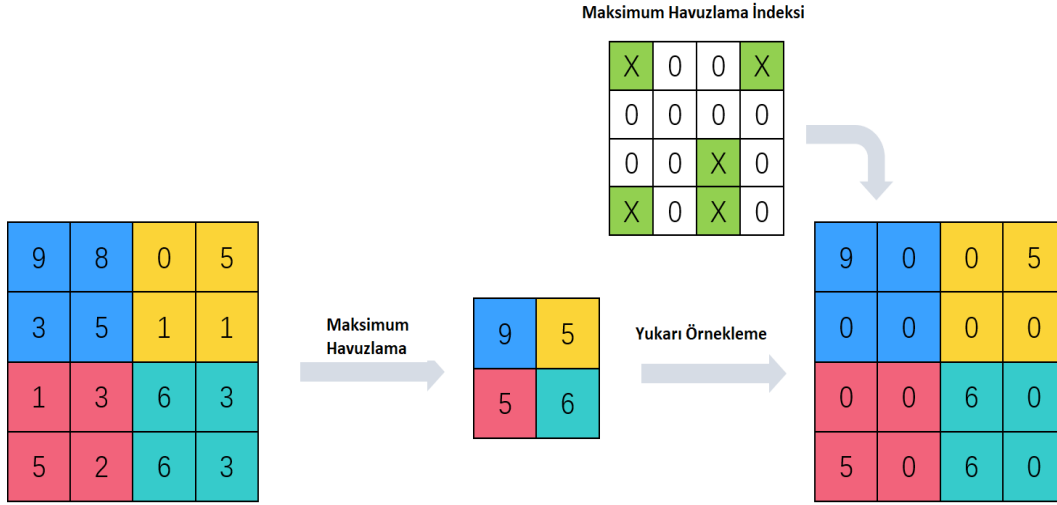
Kodlayıcı ağdaki her evrişim katmanında, özellik haritaları üretmek için bir filtre dizisi uygulanır. Bunlarda daha sonra normalizasyon katmanına sokulur ve çıktı değerleri ReLU katmanına gönderilir. Burada kullanılan normalizasyon fonksiyonu yığın normalleştirme (Ioffe ve Szegedy 2015) fonksiyonudur. Yığın normalleştirme fonksiyonu DÖ da herhangi bir katmana sıfırına ortalanmış ve 1 ile 0 arasında değerlere sahip verileri vermemizi sağlayan bir fonksiyondur. Şekil 3.15' de yığın normalleştirme fonksiyonu ile katmanlar arasındaki hata değerlerinin daha dengeli olduğu görülmektedir.



Şekil 3.15 Mnist veri seti üzerinden Yığın normalleştirme fonksiyonu. a) Doğruluğu ve adım sayısı, b) Yığın normalleştirme olmadan sigmoid kullanımı, c) Yığın normalleştirme ile kullanımı.

Yığın normalleştirme ve ReLU adımından sonra, 2×2 ' lik ve adım sayısı 2 olan maksimum havuzlama yapılır ve elde edilen çıktı 2 faktörü ile alt örneklendir. Kodlayıcı kısmında yapılan her alt örnekleme ile giderek azalan (özellikle sınır bilgileri) görüntü gösterimi, sınır tanımlamanın çok önemli olduğu bölümlere ayırma için iyi değildir. Bu nedenle alt örnekleme yapılmadan önce sınır bilgilerini yakalamak ve kodlayıcı özellik haritalarında saklamak gerekir. Çıkarım sırasında tüm kodlayıcı özellik eşlemeleri saklanabilir. Ancak pratikte böyle olmamaktadır. SegNet mimarisi bu soruna daha kolay bir çözüm sunmakta; yalnızca kodlayıcı kısımda yapılan alt örnekleme maksimum havuzlama indekslerinin yani, havuzlama penceresindeki maksimum özellik değerinin konumlarının her kodlayıcı özellik haritası için hafızaya alınmasını içerir. Prensipte olarak bu her 2×2 havuz penceresini 2 bit kullanılarak yapılabilir.

SegNet' in en dikkat çeken farkı, kod çözücü kısmında yukarı örnekleme için karşılık gelen kodlayıcı kısmındaki maksimum havuzlama katmanında hesaplanan havuzlama indekslerini kullanır. Şekil 3.16' da bu indekslerin kod çözücü ağda nasıl kullanıldığı temsil gösterilmiştir. Maksimum havuzlama indekslerinin yeniden kullanılmasının bazı faydaları vardır. Bunlardan birincisi sınır tanımlamayı geliştirir, ikincisi uçtan uca eğitimi mümkün kılan parametre sayısını azaltır.



Şekil 3.16 2x2 boyutundaki maksimum havuzlama çekirdek yapısı ile kod çözücü kısmında endekslerin tekrar kullanılması.


Kod çözücü ağındaki uygun kod çözücü, karşılık gelen kodlayıcı özellik haritalarından hafızaya alınan maksimum havuzlama indekslerini kullanarak giriş özellik haritalarını örneklendirir. Bu adımda seyrek özellik haritaları oluşturulur. Bu özellik haritaları daha sonra yoğun özellik haritaları üretmek için eğitilebilir bir kod çözücü filtre dizisi ile evrişim uygulanır. Daha sonra bu haritaların her birine yığın normalleştirme uygulanır. En son kod çözücünün çıkışındaki yüksek boyutlu özellik temsili, eğitilebilir bir softmax sınıflandırıcı katmanı ile beslenir. Kullanılan softmax katmanı her pikseli bağımsız olarak sınıflandırır.

SegNet mimari yapısı VGG16' nın ilk 13 katmanı ile aynıdır. Burada farklı olan 3 katman VGG16' nın son üç basamağında yer alan tam bağlantılı katmanlardır. En derinde olan kodlayıcı çıktısında yüksek çözünürlüklü özellik haritalarını korumak için bu 3 katman çıkarılmıştır. Bu aynı zamanda SegNet kodlayıcı ağındaki parametre sayısını 134 milyondan 14,7 milyona düşürerek önemli ölçüde azaltmıştır.

3.2.3 PSPNet

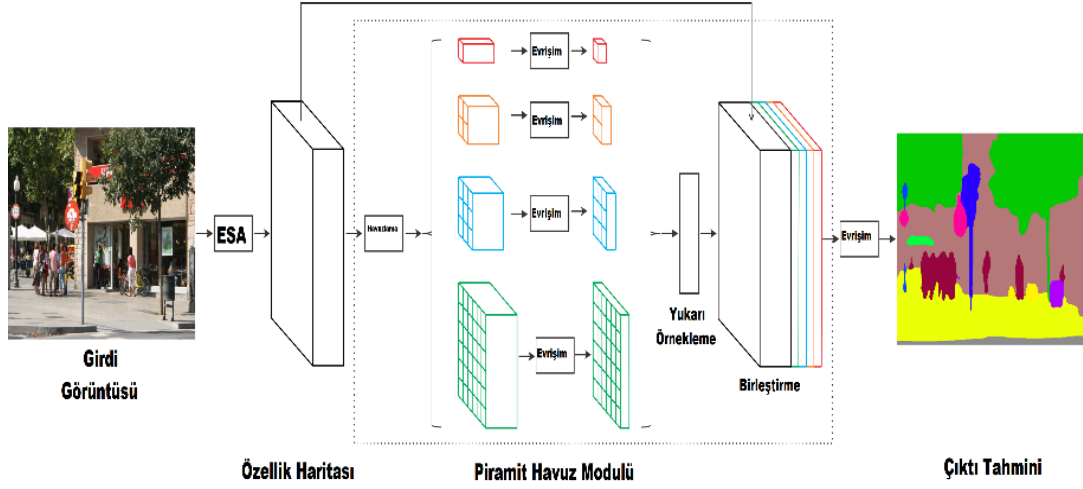
Anlamsal bölütleme her eleman için etiketi, konumu ve şekli tahmin eder. Anlamsal bölütleme zorluğu sahne ve etiket çeşitliliği ile yakından ilişkilidir. Bu zorluğun

üstesinden gelebilmek için Zhao ve ark. (2017)' de PSPNet' i önermişlerdir. Gelişmiş anlamsal bölütleme yapıları Tamamen Evrişimli Ağ (TEA)' a dayanmaktadır (Long vd. 2015). Ancak bu yapıların eksikliği olarak, görüntülerdeki bağlamsal ilgilerin TEK tabanlı yapılarda uygun bir strateji olmadığı görülmüş. Bağlamsal ilgiler için uygun strateji olmamasından kasıt ise, Şekil 3.17' ta görülen araba ve teknenin aynı sınıfa atanması gibi hatalardır. Bu hatalar nesnenin benzer görünümünden kaynaklanmaktadır. Ancak, sahnenin bir nehrin yakınındaki kayıkhanesi olarak tanımlanması için bağlam bilgisinin öğrenilmesi gerekir.



Şekil 3.17 ADE20K verisindeki bağlamsal tahmin sorunları. a) Girdi görüntüleri, b) Gerçek zemin görüntüleri, c) TEA çıktı tahminleri, d) PSPNet çıktı tahminleri.

Şekil 3.18' de PSPNet' in genel bir mimari görüntüsü verilmektedir. Girdi görüntüsü keyfi boyutlarda verilmekte, ancak derin bir sinir ağında alıcı alanının boyutu kabaca bağlam bilgisini ne kadar kullandığımızı gösterir bu neden ötürü girdi görüntüsü boyutuna dikkat edilmelidir.




Şekil 3.18 PSPNet mimarisi genel görünüşü.

PSPNet ilk girdi görüntüsü üzerinde kullanıcının tercihi göre bir ESA mimarisi ile özellik haritalarını çıkarır. Seçilen ESA mimarisi ile üretilen özellik haritalarında bir havuzlama katmanı ile farklı boyutlardaki alt örneklemeler elde edilir. Şekil 3.17’ de kırmızıyla vurgulanan en kaba seviye, tek bir kutu çıkışı üretmek için küresel bir havuzlamadır. PSPNet ismini bu piramit gibi olan yapısından alır. Aşağıya doğru piramit seviyesi, özellik haritasını farklı alt bölgelere ayırır ve farklı konumlar içi birleştirir. Bağlam özelliğinin ağırlığını korumak için, piramidin seviye boyutu N ise, bağlam temsilinin boyutunu orijinalin $1/N$ ’ sine düşürmek için piramit seviyesinden sonra 1×1 evrişim katmanı uygulanır. Boyut özellik eşleşmeleri, bilinear enterpolasyon yoluyla orijinal özellik eşleşmesiyle aynı boyut özelliğine sahip olur. Son olarak, farklı özellik seviyeleri son piramit havuzlama küresel özelliği olarak birleştirilir. Burada kullanılan havuzlama çekirdek boyutları ise sırasıyla 1×1 , 2×2 , 3×3 , 6×6 ’ olarak seçilmiştir. PSPNet mimarisinde en son özellik haritası boyutu, giriş görüntüsünün $1/8$ ’ i kadardır.


4. MATERYAL VE METOT

Bu çalışmada, UFUAB' in uzaktan algılama verilerinin sınıflandırılması için arařtırmacıların kullanımına sunduđu Vaihingen ve Potsdam veri setleri kullanılmıřtır. Kullanılan veri setleri üç bantlı ve bant kombinasyonu ise yakın kızılötesi, kırmızı ve yeřil bantlar olarak sunulmuřtur. Toplam bina (mavi), zemin (beyaz), bitki örtüsü (turkuaz), ađaç(yeřil), araba(sarı) ve karıřıklık(kırmızı) olmak üzere 6 sınıf vardır. Bu sınıflar arasındaki belirsiz sınır tanımlarının deđerlendirme üzerindeki etkisini azaltmak için üç piksel yarıçaplı dairesel bir disk tarafından silinen etiketli görüntülerde (řekil 4.2) eklenmiřtir. Vaihingen ve Potsdam veri setlerinde, UNet, SegNet ve PSPNet mimarileri kullanılarak sınıflandırma yapılacaktır. Bu sınıflandırma işleminde Python yazılım dili kullanılmıřtır.

Vaihingen veri seti, 9 cm yer örnekleme aralıđına sahip farklı piksel boyutunda, řekil 4.1' de gösterilen bölgelere ayrılmıř toplam 33 ortofoto görüntüsü içermektedir. Bu ortofotolardan sadece 16 tanesi etiketli görüntülerden oluşur. Diđerleri bađımsız deđerlendirme yapılabilmesi için kullanılır.



řekil 4.1 Vaihingen veri seti eđitim alanları.




Şekil 4.2 Vaihingen veri setinde bulunan 1.bölge için. a) Ortofoto, b) Etiketli görüntü, c) Sınır pikselleri görüntü.

Bu çalışmada, bir diğer veri seti olan Potsdam veri seti, 5 cm yer örnekleme aralığına sahip 6000x6000 piksel boyutunda, Şekil 4.3’ de gösterilen bölgelere ayrılmış toplam 38 ortofoto görüntüden oluşmaktadır. Bu ortofotolardan 24 tanesi etiketli görüntülerdendir. Yine aynı şekilde sınır pikselleri silinmiş etiketli görüntülerde (Şekil 4.4) Potsdam eğitim veri setinde bulunmaktadır.



Şekil 4.3 Potsdam veri seti eğitim alanları.



Şekil 4.4 Potsdam veri setinde bulunan 1.bölge için. a) Ortofoto, b) Etiketli görüntü, c) Sınır pikselleri silinmiş etiketli görüntü.

Vaihingen veri setinde, eğitim ve test aşamasında Google Colab kullanılmıştır. Google Colab kullanıcılara genel olarak derin öğrenme çalışmaları için 12 saat boyunca ücretsiz GİB desteği sağlayan bir internet platformudur. İçerisinde farklı birçok GİB kullanılabilir. Çalışmaya uygunluğu açısından 16 GB GİB olan Tesla P100-PCIe kullanılmıştır. Google Colab kullanılarak yapılan bu çalışma sayesinde, uzaktan algılama verilerinin sınıflandırılması görevindeki yüksek maliyetli donanım gereksinimlerine alternatif olabileceği gösterilmiştir. Potsdam veri setinde, eğitim ve test aşamasında 8 GB Asus GeForce 2070 süper GİB ile Intel Xeon MİB' e sahip bir iş istasyonu kullanılmıştır.

Her iki veri seti için 12 görüntü eğitim ve 4 görüntü test için olmak üzere toplam 16 görüntü kullanılmıştır. Eğitim aşamasında kullanılan görüntüler 256x256 pencerele bölünerek 10000 tane yama görüntü üzerinden yapılmıştır. Test aşamasında, eğitim aşamasından elde edilen son ağırlık değerleriyle 4 ortofoto görüntünün tamamı tahmin edilmeye çalışılmıştır. Kullanılan mimarilerde sıfırdan eğitim yerine daha önceden eğitilmiş ağırlıklar kullanılması önerilmiştir (Castelluccio vd. 2015). Bu sebepten dolayı UNet ve SegNet için VGG19 ağırlıkları kodlayıcı ve kod çözücü ağ yapılarına uygun bulunduğu için seçilmiş, diğer ikisinden farklı bir mimariye sahip PSPNet için performans ve parametre sayısı olarak en uygun olan ResNet-50 (Bianco vd. 2018)

ağırlık değerleri seçilmiştir.

İlk olarak Vaihingen veri seti üzerinden, UNet, SegNet ve PSPNet mimarileri kullanılarak Google Colab' da bir eğitim yapılmıştır. Kullanılan mimariler arasında tam bir kıyaslama yapılabilmesi için ağlarda kullanılan hiper parametrelerin (Balaprakash vd. 2018) değerleri aynı değerler seçilmiştir. Hiper parametrelerden yığın değeri 10, epok sayısı 50, öğrenme oranı 0.01 (Kavzoğlu, 2001) olarak seçilmiş ve ağırlık optimizasyonu için SGD (Ruder, 2017) optimizasyon algoritması kullanılmıştır. Eğitim bittikten sonra elde edilen son ağırlık değerleri kaydedilmiş ve bu ağırlık değerleri ile daha kaba bir değerlendirme olan test aşaması gerçekleştirilmiştir.

Aynı şekilde Potsdam veri seti içinde yine UNet, SegNet ve PSPNet mimarilerinde bir eğitim gerçekleştirilmiş ve elde edilen son ağırlık değerleri ile eğitim aşamasından daha kaba bir test aşaması yapılmıştır. Potsdam veri seti Vaihingen veri setine göre boyut ve detay olarak daha büyük bir veri setidir. Bu yüzden eğitim ve test aşamasında kullanılan GIB' in optimizasyonu için uygun hiper parametreler kullanılmıştır. Yığın değeri 10, epok sayısı 50, öğrenme oranı 0.01 ve yine ağırlık optimizasyonu için SGD optimizasyon algoritması kullanılmıştır.

Bu çalışmada UNet, SegNet ve PSPNet mimarileri her iki veri seti içinde sınıflandırma doğruluğu, zaman kullanımı, hafıza kullanımı ve ağların karmaşıklıkları olarak karşılaştırılacaklardır. Sınıflandırma doğrulukları; elde edilen sonuç ürünlerdeki sınıfların ne kadar doğru tespit edildiği, hata matrisinden elde edilen kappa değerleri ve kayıp değer grafiği üzerinden değerlendirilecektir.

5. UYGULAMA

Yapılan sınıflandırma çalışmasında Vaihingen veri seti ve Potsdam veri seti için eğitim ve test kısımları ayrı ayrı çalışılmış ve elde edilen sonuçlar yine ayrı şekilde sunulmuştur.

5.1 Vaihingen Veri Seti Sonuçları

İlk olarak UNet üzerinden eğitim ve test aşaması gerçekleştirilmiş ve bu adımlar sırasıyla 7,5 saat ve 11 dakikalık bir süre almıştır. Elde edilen sonuçlar eğitim için Çizelge 5.1 ve test için Çizelge 5.2’ de sınıflara göre son değerleri sunulmuştur. Görüntüde bir sınıfa ait değer yoksa boş geçilmiş veya olmayan bir sınıf atanmış ise 0,00 değeri verilmiştir.

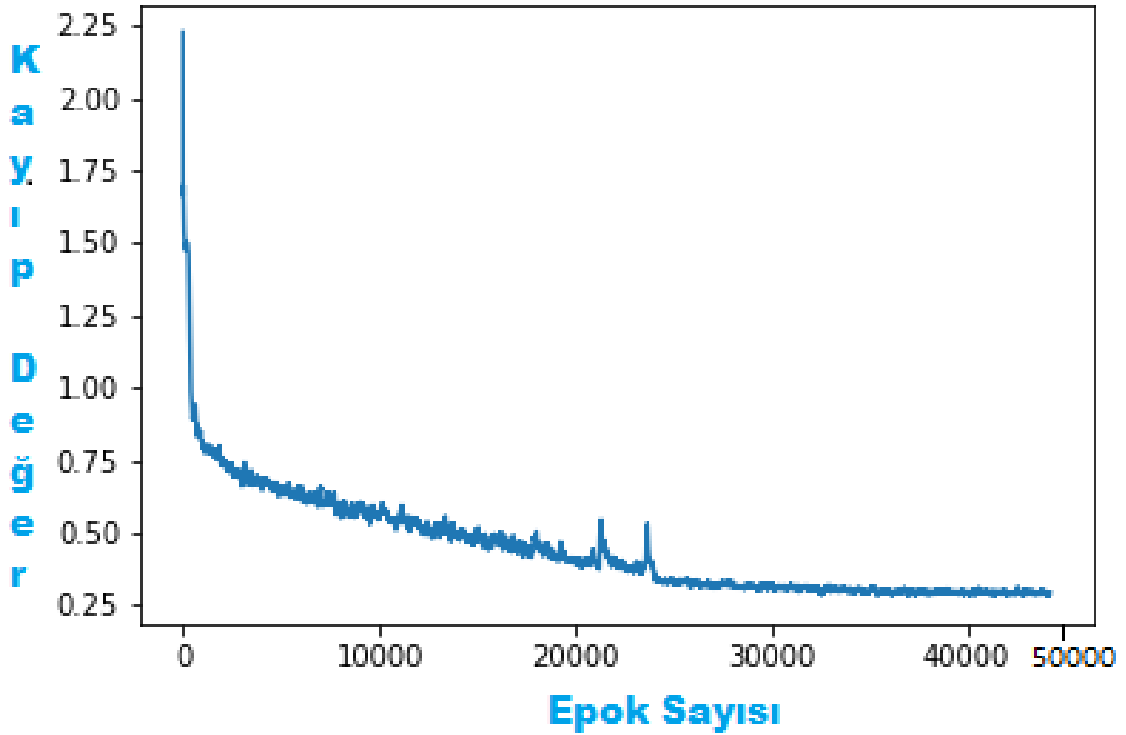
Çizelge 5.1 UNet, Vaihingen veri setinde eğitim aşamasından sınıflara göre sonuç değerler.

Görüntü	Zemin	Bina	Bitki Örtüsü	Ağaç	Araç	Karışıklık
1	91,73	95,19	78,12	88,72	74,99	0,00
3	92,33	94,74	79,74	87,26	79,33	-
23	90,69	94,94	79,74	89,23	77,20	0,00
26	90,29	94,49	79,12	90,51	72,42	93,17
7	93,08	95,30	74,87	91,73	64,64	-
11	90,84	94,28	74,36	92,79	73,87	-
13	84,11	95,10	81,61	86,68	78,34	0,00
28	89,75	94,32	76,73	80,14	71,23	0,00
17	89,09	97,78	92,50	89,51	56,84	-
32	96,10	96,93	77,44	90,04	67,00	0,00
34	93,25	96,19	85,19	90,43	79,55	-
37	93,43	95,84	92,22	84,04	51,86	-

Çizelge 5.2 UNet, Vaihingen veri setinde test aşamasından sınıflara göre sonuç değerler.

Görüntü	Zemin	Bina	Bitki Örtüsü	Ağaç	Araç	Karışıklık
5	90,35	95,48	62,81	85,49	59,74	-
21	83,99	93,21	77,32	88,78	82,82	-
15	88,56	93,44	64,48	91,20	65,46	0,00
30	87,50	92,80	77,42	89,82	71,86	-

Çizelge 5.1 ve Çizelge 5.2 incelendiği zaman genel olarak bina sınıfının yüksek doğrulukta tahmin edildiği, bitki örtüsü ve araç sınıfının diğerlerine göre daha düşük tahmin edildiği görülmektedir. UNet için eğitim aşamasındaki kayıp değer grafiği Şekil 5.1’ de sunulmuştur.



Şekil 5.1 UNet için Vaihingen veri seti kayıp değer grafiği.

Önceden eğitilmiş ağırlıklar ile başlamanın avantajıyla grafikte hızlı bir düşüş görülmekte ve kayıp değer grafiğinin alt bölümüne paralel olmaya başladığı zaman aslında kullanılan mimarinin optimum seviye geldiğini söyleyebiliriz.

UNet için eğitim ve test kısmında elde edilen hata matrisinden hesaplanan kapa değerleri ise Çizelge 5.3 ve Çizelge 5.4' de sunulmuştur.

Çizelge 5.3 UNet, Vaihingen veri setinde eğitim aşamasından elde edilen kapa değerleri.

Görüntü	Kappa
1	86,82
3	86,38
23	85,70
26	87,20
7	87,39
11	86,27
13	85,44
28	85,05
17	88,55
32	89,34
34	88,37
37	89,10

Çizelge 5.4 UNet, Vaihingen veri setinden test aşamasında elde edilen kapa değerleri.

Görüntü	Kappa
5	84,77
21	83,70
15	83,12
30	82,79

SegNet ile Vaihingen veri seti üzerinden yapılan eğitim ve test aşaması sırasıyla 6 saat ve 9 dakika sürmüştür. Elde edilen sonuçlar eğitim için Çizelge 5.5 ve test için Çizelge 5.6' da sınıflara göre son değerleri sunulmuştur. Görüntüde bir sınıfa ait değer yoksa boş geçilmiş veya olmayan bir sınıf atanmış ise 0,00 değeri verilmiştir.


Çizelge 5.5 SegNet, Vaihingen veri setinde eğitim aşamasından sınıflara göre sonuç değerler.

Görüntü	Zemin	Bina	Bitki Örtüsü	Ağaç	Araç	Karışıklık
1	98,25	98,84	96,68	97,59	91,26	-
3	98,24	98,74	95,43	96,08	95,74	-
23	97,64	99,01	95,87	97,15	97,70	97,32
26	98,14	98,84	95,69	97,14	93,40	99,22
7	98,36	99,04	95,29	97,96	91,72	-
11	98,27	98,87	95,48	97,51	94,74	-
13	97,35	99,30	96,10	96,01	91,44	-
28	98,03	98,90	95,82	96,99	93,11	99,10
17	98,30	99,32	98,55	97,40	95,78	-
32	99,30	99,55	96,34	97,84	94,68	98,32
34	98,92	99,48	97,26	97,64	95,79	-
37	98,50	99,02	98,47	96,35	90,71	-

Çizelge 5.6 SegNet, Vaihingen veri setinde test aşamasından sınıflara göre sonuç değerler.

Görüntü	Zemin	Bina	Bitki Örtüsü	Ağaç	Araç	Karışıklık
5	93,08	96,73	71,53	86,54	73,89	0,00
21	93,15	96,04	75,79	92,28	83,56	0,00
15	86,34	95,29	79,11	88,02	93,11	0,00
30	90,26	94,00	81,88	89,35	84,28	0,00

Çizelge 5.5 incelendiği zaman genel olarak sınıfların yüksek doğrulukta tahmin edildiği görülmektedir. Çizelge 5.6’ da ise bina sınıfının diğer sınıflara göre daha yüksek tahmin edildiği, diğer sınıfların eğitim aşamasına göre test sonuçlarının kısmen düştüğü görülmektedir. SegNet için eğitim aşamasındaki kayıp değer grafiği Şekil 5.2’ de sunulmuştur.



Şekil 5.2 SegNet için Vaihingen veri seti kayıp değer grafiği.

Şekil 5.2’ de kayıp değerlerin önceden eğitilmiş ağırlıklar ile hızlı bir şekilde düşmüştür. Eğitimin ortalarına doğru SegNet ağı optimize olmaya başladığı ve son epokta tam grafiğin alt kısmına paralel olduğu görülmektedir.

SegNet için eğitim ve test kısmında elde edilen hata matrisinden hesaplanan kappa değerleri ise Çizelge 5.7 ve Çizelge 5.8’ de sunulmuştur.

Çizelge 5.7 SegNet, Vaihingen veri setinde eğitim aşamasından elde edilen kappa değerleri.

Görüntü	Kappa
1	97,30
3	96,90
23	96,79
26	96,96
7	97,01
11	96,99
13	96,79
28	96,75
17	96,83
32	96,99
34	97,04
37	97,09

Çizelge 5.8 SegNet, Vaihingen veri setinde test aşamasından elde edilen kappa değerleri.

Görüntü	Kappa
5	85,75
21	88,71
15	95,98
30	97,59

Son olarak PSPNet ile Vaihingen veri seti üzerinden yapılan eğitim ve test aşaması sırasıyla 12 saat ve 15 dakika sürmüştür. Elde edilen sonuçlar eğitim için Çizelge 5.9 ve test için Çizelge 5.10’ da sınıflara göre son değerleri sunulmuştur. Görüntüde bir sınıfa ait değer yoksa boş geçilmiş veya olmayan bir sınıf atanmış ise 0,00 değeri verilmiştir.

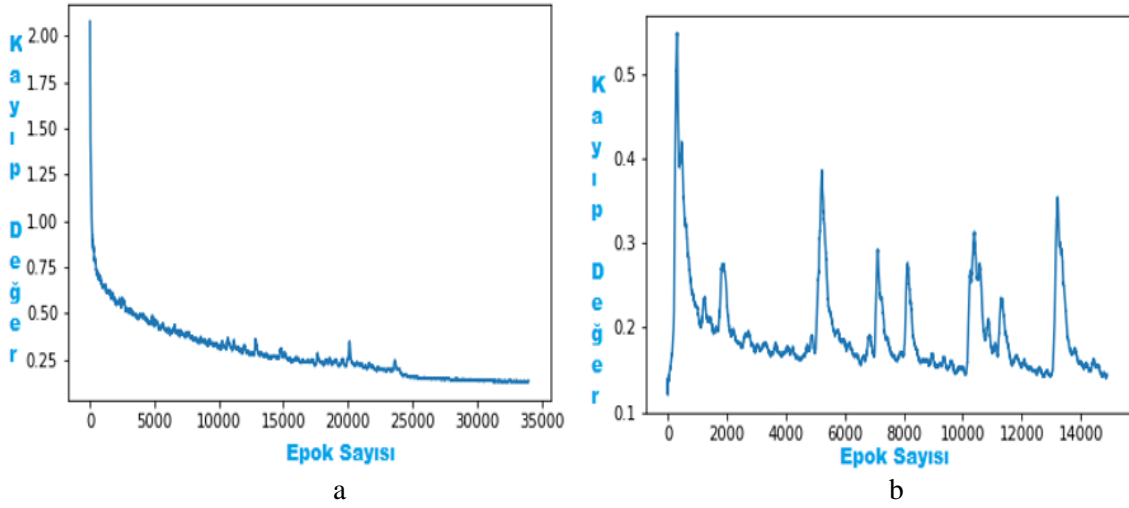
Çizelge 5.9 PSPNet, Vaihingen veri setinde eğitim aşamasından sınıflara göre sonuç değerler.

Görüntü	Zemin	Bina	Bitki Örtüsü	Ağaç	Araç	Karışıklık
1	87,88	93,30	73,12	88,62	64,84	0,00
3	89,34	91,83	80,18	86,89	69,36	-
23	85,44	92,89	75,41	88,48	66,84	57,87
26	86,62	91,90	74,63	93,30	58,50	94,47
7	89,36	94,27	72,36	90,12	62,85	-
11	90,03	94,24	77,60	91,74	57,81	-
13	85,28	95,93	83,39	86,18	58,99	-
28	84,25	92,16	80,56	83,06	62,45	0,00
17	88,91	96,84	92,55	87,68	45,48	-
32	93,68	91,52	80,40	90,39	67,52	58,77
34	89,02	92,02	82,63	85,04	74,01	-
37	91,41	94,73	90,09	71,74	54,28	-

Çizelge 5.10 PSPNet, Vaihingen veri setinde test aşamasından sınıflara göre sonuç değerler.

Görüntü	Zemin	Bina	Bitki Örtüsü	Ağaç	Araç	Karışıklık
5	87,38	93,81	54,38	84,58	44,88	-
21	86,11	90,04	64,06	90,74	57,06	0,00
15	76,53	93,04	71,35	87,86	72,22	0,00
30	87,41	92,82	75,87	87,37	52,82	0,00

Çizelge 5.9 incelendiği zaman zemin ve bina sınıflarının diğer sınıflara yüksek doğrulukta tahmin edildiği, ancak araç ve karışıklık sınıflarının düşük tahmin edildiği görülmektedir. Çizelge 5.10’ da ise yine zemin ve bina sınıfının diğer sınıflara göre daha yüksek tahmin edildiği, ağaç sınıfının ise eğitim kısmına göre daha yüksek tahmin edildiği görülmektedir. Yine Çizelge 5.10 incelendiği zaman karışıklık sınıfı olmamasına rağmen görüntülerde karışıklık sınıfına atama yapıldığı bu yüzden değerlerin 0,00 geldiği tespit edilmiştir. PSPNet için eğitim aşamasındaki kayıp değer grafiği Şekil 5.3’ de sunulmuştur.



Şekil 5.3 PSPNet için Vaihingen veri seti kayıp değer grafiği. a) 35 epoka kadar olan kısım, b) son 15 epokluk kısım

PSPNet’ de eğitim süresi uzun sürdüğü için Google Colad’ da bağlantı kısıtlamasına denk gelmektedir. Bu yüzden eğitim iki aşamalı olarak, ilk 35 epok eğitim yapılmış daha sonra kayıt edilen ağırlık değerleri ile son 15 epokluk eğitim gerçekleştirilmiştir. Şekil 5.3 (b)’ de büyük dalgalanmalar olarak görülmesinin sebebiyse kayıp değerinin 0,5 ile 0,1 arasında değişkenlik göstermesidir.

PSPNet için eğitim ve test kısmında elde edilen hata matrisinden hesaplanan kappa değerleri ise Çizelge 5.11 ve Çizelge 5.12’ de sunulmuştur.

Çizelge 5.11 PSPNet, Vaihingen veri seti için eğitim aşamasında elde edilen kappa değerleri.

Görüntü	Kappa
1	82,98
3	83,31
23	81,70
26	82,72
7	83,07
11	83,46
13	83,43
28	83,15
17	83,58
32	83,97
34	83,98
37	84,13

Çizelge 5.12 PSPNet, Vaihingen veri seti için test aşamasında elde edilen kappa değerleri.

Görüntü	Kappa
5	85,72
21	85,39
15	84,86
30	84,67

5.2 Potsdam Veri Seti Sonuçları

Potsdam veri seti içinde ilk olarak UNet üzerinden eğitim ve test aşaması gerçekleştirilmiş ve bu adımlar sırasıyla 8,5 saat ve 1,5 saatlik bir süre almıştır. Elde edilen sonuçlar eğitim için Çizelge 5.13 ve test için Çizelge 5.14’ de sınıflara göre son değerleri sunulmuştur. Görüntüde bir sınıfa ait değer yoksa boş geçilmiş veya olmayan bir sınıf atanmış ise 0,00 değeri verilmiştir.


Çizelge 5.13 UNet, Potsdam veri seti için eğitim aşamasında sınıflara göre sonuç değerler.

Görüntü	Zemin	Bina	Bitki Örtüsü	Ağaç	Araç	Karışıklık
2_10	78,44	85,71	76,90	53,35	70,90	68,49
2_11	86,76	87,49	77,93	70,12	81,94	68,12
2_12	84,10	86,26	81,46	65,51	77,95	67,18
3_10	86,72	89,96	78,70	74,13	85,42	75,45
3_11	88,50	91,75	83,93	73,85	79,74	77,01
3_12	85,54	88,16	80,91	70,74	79,72	67,69
4_10	84,74	88,27	80,23	70,91	79,29	64,12
4_11	84,26	88,83	80,05	71,48	80,20	62,53
4_12	85,00	89,09	80,53	71,50	81,51	60,60
5_10	83,51	85,73	75,20	72,77	82,10	22,24
5_11	85,00	89,24	79,91	71,86	82,36	56,55
5_12	85,12	89,82	79,56	71,76	82,58	55,18

Çizelge 5.14 UNet, Potsdam veri seti için test aşamasında sınıflara göre sonuç değerler.

Görüntü	Zemin	Bina	Bitki Örtüsü	Ağaç	Araç	Karışıklık
6_7	50,76	74,44	70,52	58,21	59,64	07,83
6_8	82,27	88,02	78,01	76,86	72,67	37,59
6_9	84,17	89,96	78,93	71,94	82,45	52,34
6_10	87,55	87,67	65,11	72,27	83,57	27,35

Çizelge 5.13 ve Çizelge 5.14 incelendiği zaman genel olarak bina sınıfının yüksek doğrulukta tahmin edildiği, karışıklık sınıfının diğerlerine göre çok daha düşük tahmin edildiği görülmektedir. UNet için eğitim aşamasındaki kayıp değer grafiği Şekil 5.4' de sunulmuştur.



Şekil 5.4 UNet için Potsdam veri seti kayıp değer grafiği.

Şekil 5.4 incelendiğinde kayıp değerinin hızlı bir şekilde düştüğü ve belirli bir aralıkta kalarak optimum seviye ulaştığı görülmektedir. UNet için eğitim ve test kısmında elde edilen hata matrisinden hesaplanan kapa değerleri ise Çizelge 5.15 ve Çizelge 5.16’ da sunulmuştur.

Çizelge 5.15 UNet, Potsdam veri seti için eğitim aşamasında elde edilen kappa değerleri.

Görüntü	Kappa
2_10	67,27
2_11	71,31
2_12	74,20
3_10	75,31
3_11	79,60
3_12	75,48
4_10	73,79
4_11	75,87
4_12	81,33
5_10	74,79
5_11	78,45
5_12	77,67

Çizelge 5.16 UNet, Potsdam veri seti için test aşamasında elde edilen kappa değerleri.

Görüntü	Kappa
6_7	75,06
6_8	75,00
6_9	74,27
6_10	74,34

SegNet ile Potsdam veri seti üzerinden yapılan eğitim ve test aşaması sırasıyla 7,5 saat ve 1,5 saat sürmüştür. Elde edilen sonuçlar eğitim için Çizelge 5.17 ve test için Çizelge 5.18’ de sınıflara göre son değerleri sunulmuştur. Görüntüde bir sınıfa ait değer yoksa boş geçilmiş veya olmayan bir sınıf atanmış ise 0,00 değeri verilmiştir.

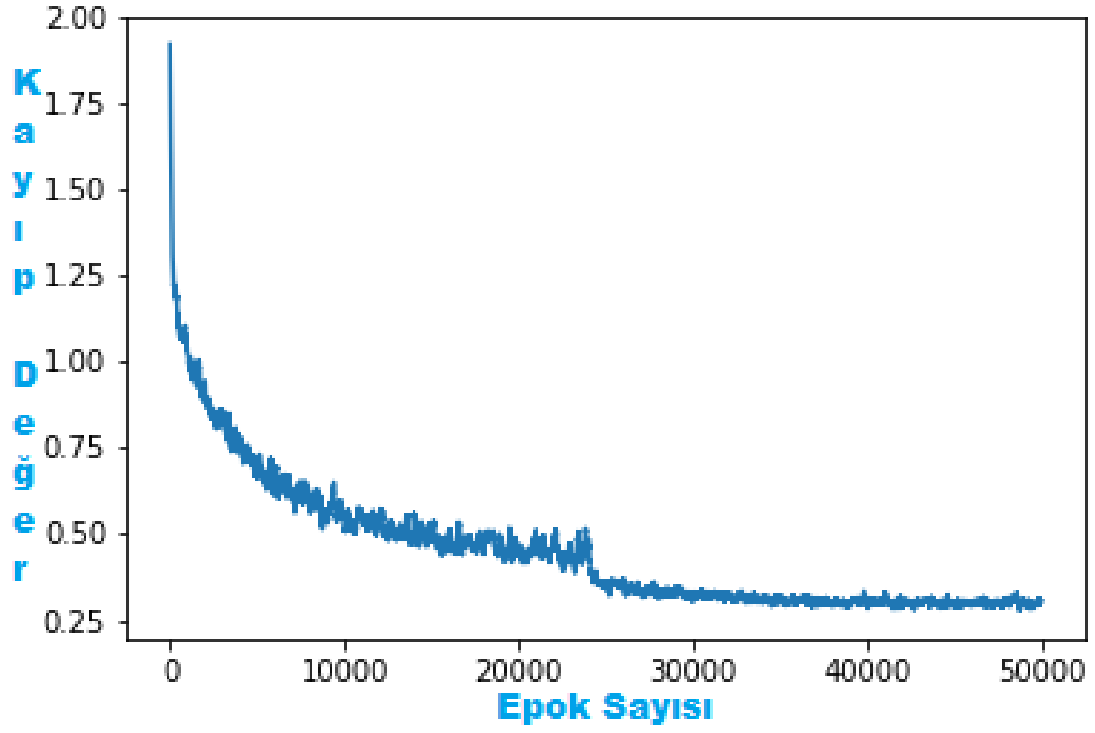
Çizelge 5.17 SegNet, Potsdam veri seti için eğitim aşamasında sınıflara göre sonuç değerler.

Görüntü	Zemin	Bina	Bitki Örtüsü	Ağaç	Araç	Karışıklık
2_10	93,72	97,38	91,66	81,07	89,68	83,64
2_11	94,37	95,85	89,38	84,57	95,43	88,18
2_12	94,47	96,97	93,80	83,17	93,93	40,78
3_10	94,08	96,78	91,60	85,40	93,78	84,52
3_11	95,61	98,20	92,94	88,69	94,70	89,08
3_12	94,25	97,09	91,38	86,95	94,11	83,27
4_10	93,81	97,00	90,95	86,74	94,00	81,57
4_11	93,35	97,03	90,65	86,90	94,36	80,03
4_12	93,74	97,27	90,81	86,89	94,87	78,86
5_10	93,72	97,20	90,54	86,96	94,86	77,85
5_11	93,94	97,84	85,68	88,86	95,69	39,07
5_12	93,49	97,51	81,09	84,20	94,86	36,05

Çizelge 5.18 SegNet, Potsdam veri seti için test aşamasında sınıflara göre sonuç değerler.

Görüntü	Zemin	Bina	Bitki Örtüsü	Ağaç	Araç	Karışıklık
6_7	93,61	97,73	90,01	87,07	95,99	74,28
6_8	93,47	97,72	89,81	87,09	95,88	74,10
6_9	92,99	97,48	89,51	87,10	95,87	74,14
6_10	92,97	97,36	89,21	87,15	95,74	72,12

Çizelge 5.17 incelendiği zaman genel olarak sınıfların yüksek doğrulukta tahmin edildiği görülmektedir. Çizelge 5.6' da ise bina ve zemin sınıfının diğer sınıflara göre daha yüksek tahmin edildiği, diğer sınıfların eğitim aşamasına göre test sonuçlarının kısmen düştüğü görülmektedir. SegNet için eğitim aşamasındaki kayıp değer grafiği Şekil 5.5' de sunulmuştur.



Şekil 5.5 SegNet için Potsdam veri seti kayıp değer grafiği.

Şekil 5.5 incelendiğinde kayıp değer hızla düşüyor ve belirli bir aralıkta kalarak optimum seviye ulaştığı görülmektedir. SegNet için eğitim ve test kısmında elde edilen hata matrisinden hesaplanan kapa değerleri ise Çizelge 5.19 ve Çizelge 5.20’ da sunulmuştur.

Çizelge 5.19 SegNet, Potsdam veri seti için eğitim aşamasında elde edilen kappa değerleri.

Görüntü	Kappa
2_10	82,98
2_11	83,31
2_12	81,70
3_10	82,72
3_11	83,07
3_12	83,46
4_10	83,43
4_11	83,15
4_12	83,58
5_10	83,97
5_11	83,98
5_12	84,13

Çizelge 5.20 SegNet, Potsdam veri seti için test aşamasında elde edilen kappa değerleri.

Görüntü	Kappa
6_7	89,20
6_8	89,06
6_9	88,73
6_10	88,57

Son olarak PSPNet ile Potsdam veri seti üzerinden yapılan eğitim ve test aşaması sırasıyla 17 saat ve 2 saat sürmüştür. Elde edilen sonuçlar eğitim için Çizelge 5.21 ve test için Çizelge 5.22 sınıflara göre son değerleri sunulmuştur. Görüntüde bir sınıfa ait değer yoksa boş geçilmiş veya olmayan bir sınıf atanmış ise 0,00 değeri verilmiştir.


Çizelge 5.21 PSPNet, Potsdam veri seti için eğitim aşamasında sınıflara göre sonuç değerler.

Görüntü	Zemin	Bina	Bitki Örtüsü	Ağaç	Araç	Karışıklık
2_10	87,12	75,58	85,11	70,79	66,43	79,25
2_11	93,89	94,62	88,49	83,24	92,40	87,38
2_12	90,58	86,38	88,40	79,46	79,06	80,99
3_10	90,39	84,46	87,41	81,83	79,62	79,68
3_11	90,00	79,47	86,00	82,25	78,54	78,48
3_12	89,33	77,58	83,98	82,69	77,69	75,53
4_10	88,23	77,17	82,41	81,70	75,61	73,44
4_11	87,29	76,77	80,93	81,46	74,50	71,31
4_12	88,17	79,05	80,76	81,44	76,87	69,33
5_10	87,94	78,97	80,12	81,53	76,60	67,82
5_11	87,52	78,26	78,38	81,07	75,76	65,20
5_12	86,75	77,43	76,09	80,47	74,34	62,81

Çizelge 5.22 PSPNet, Potsdam veri seti için test aşamasında sınıflara göre sonuç değerler.

Görüntü	Zemin	Bina	Bitki Örtüsü	Ağaç	Araç	Karışıklık
6_7	78,96	66,40	70,52	77,27	70,96	56,54
6_8	78,39	66,01	70,05	77,25	69,97	55,65
6_9	78,80	67,52	70,28	77,72	71,79	56,72
6_10	79,85	68,38	69,65	77,76	72,90	56,06

Çizelge 5.21 ve Çizelge 5.22' ye bakıldığında genel olarak sınıfların istenen seviyede doğru tahmin yapılamadığı görülmektedir. PSPNet için eğitim aşamasındaki kayıp değer grafiği Şekil 5.6' da gösterilmiştir.



Şekil 5.6 PSPNet için Potsdam veri seti kayıp değeri grafiği.

Şekil 5.6 incelendiğinde diğer mimarilerden farklı olarak iki katı epok sayısı görülmekte, bunun sebebiyse PSPNet' in GİB kullanımını diğer mimarilere göre fazla olduğundan dolayı yığın değeri 10 yerine 5 seçilmiştir. Yine belirli bir aralıkta PSPNet ağı optimize olmuştur. PSPNet için eğitim ve test kısmında elde edilen hata matrisinden hesaplanan kappa değerleri ise Çizelge 5.23 ve Çizelge 5.24' te sunulmuştur.

Çizelge 5.23 PSPNet, Potsdam veri seti için eğitim aşamasında elde edilen kappa değerleri.

Görüntü	Kappa
2_10	75,18
2_11	80,66
2_12	81,23
3_10	80,91
3_11	79,35
3_12	77,88
4_10	76,22
4_11	75,01
4_12	75,80
5_10	75,45
5_11	74,26
5_12	72,65

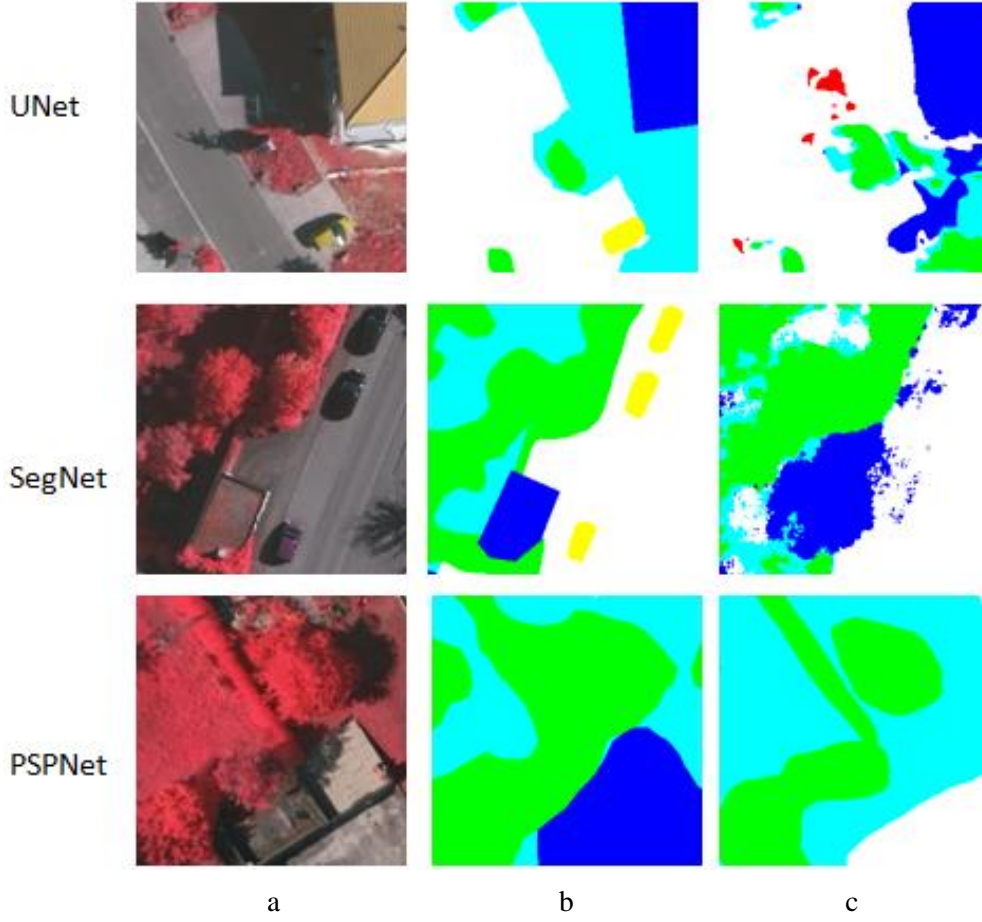
Çizelge 5.24 PSPNet, Potsdam veri seti için test aşamasında elde edilen kappa değerleri.

Görüntü	Kappa
6_7	62,90
6_8	62,38
6_9	63,35
6_10	63,82

6. TARTIŞMA ve SONUÇ


Önceki bölümlerde, uygulanmanın hangi veriler üzerinden, hangi mimariler kullanılarak nasıl yapılacağıyla alakalı bilgiler verilmiştir. Daha sonra Vaihingen ve Potsdam veri setleri için ayrı ayrı UNet, SegNet ve PSPNet mimarileri üzerinden sınıflandırma yapılmış, eğitim ve test aşamalarına dair elde edilen sonuçlar sunulmuştur. Her iki veri setinde zemin, bina, bitki örtüsü, ağaç, araç ve karışıklık olmak üzere toplam 6 sınıf bulunmaktadır.

Vaihingen veri seti için eğitim kısmında sınıflar arası en yüksek doğruluk değerine SegNet ile ulaşıldığı ve sınıflar arası doğruluğun homojen dağıldığını Çizelge 5.5 görmekteyiz. UNet ve PSPNet ise Çizelge 5.1 ile Çizelge 5.9 incelendiği zaman bina ve zemin sınıflarında yüksek bir doğruluk elde edilmiş ancak diğer sınıflarda beklenen doğruluğa ulaşamamıştır. Kayıp değer grafikleri UNet için Şekil 5.1, SegNet için Şekil 5.2 ve PSPNet için Şekil 5.3 incelendiği zaman SegNet' in daha hızlı optimize olduğu ve kayıp değerini diğer mimarilere göre daha hızlı düşürdüğü görülmektedir. Kayıp değer grafiklerindeki dalgalanmalar dikkate alındığında üç mimari içinde bazı durumlar dikkat çekmiştir. Bunlardan birincisi Şekil 6.1' de gösterilen zemin ile bina veya bitki örtüsü ile ağaç sınıfı ayrımı tam öğrenilmemiş olmasıdır.



Şekil 6.1 Vaihingen veri seti için, mimarilerde karıştırılan sınıflara ait karşılaştırma. a) Ortofoto görüntü, b) Gerçek zemin görüntüsü, c) Mimari tahmin görüntüsü.

İkinci durum olarak, Şekil 6.2’ de karşılaştırıldığı gibi veri setindeki ortofotolarda yırtılmalardan kaynaklı bina ve araç köşe bilgilerinin tam olarak tahmin edilememesidir.



Şekil 6.2 Vaihingen veri seti için, mimarilerde ortofotodan kaynaklı sınır karmaşası. a) Ortofoto görüntüsü, b) Gerçek zemin görüntüsü, c) Mimari tahmin görüntüsü.

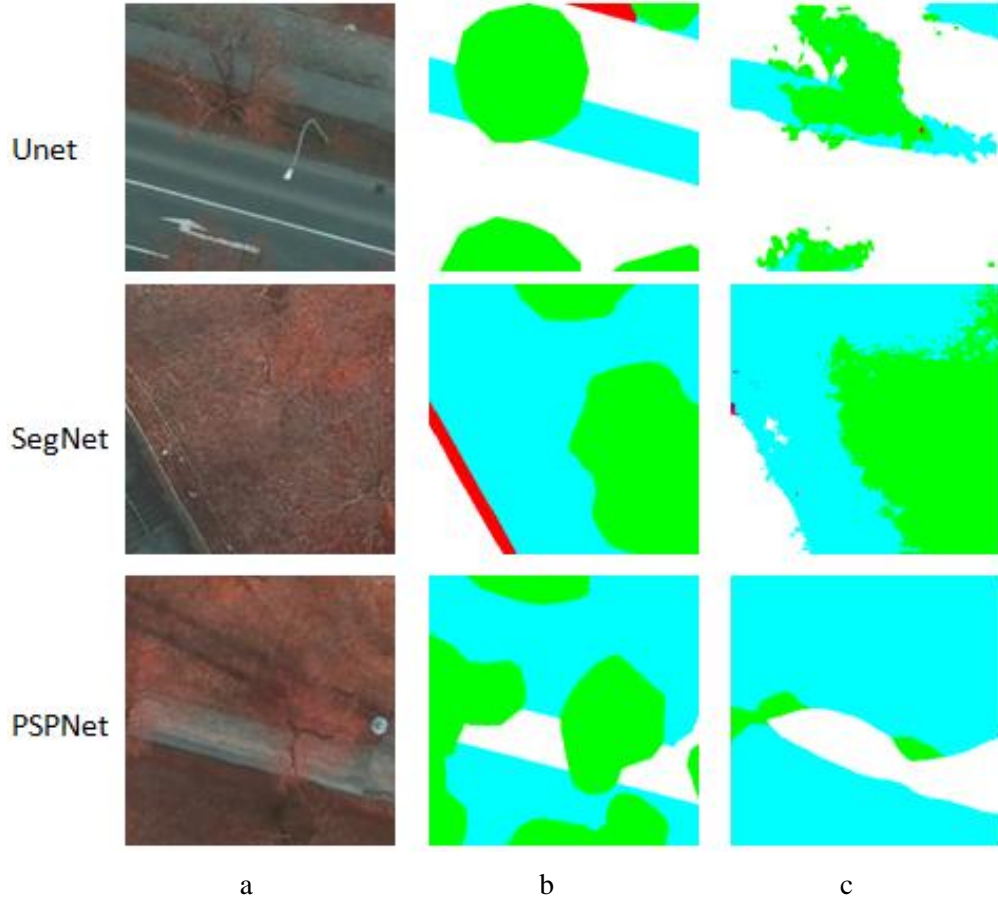
Vaihingen veri seti için yapılan sınıflandırmaların genel doğruluk açısından ne kadar uyumlu olduğunun tespiti, hata matrisleri üzerinden hesaplanan kappa değerleri ile ölçülmüştür. Kappa değer tabloları UNet için Çizelge 5.3, SegNet için Çizelge 5.7, PSPNet için Çizelge 5.11’ de incelendiğinde yine SegNet’ in diğer mimarilere göre bariz üstünlüğü görülmektedir. SegNet ile %95 üzeri tahminler gerçekleştirilmiş ve yaptığı sınıflandırmanın uyumluluğu görülmektedir. Diğer iki mimarinin kappa değerleri arasında çok büyük farklar olmamasına rağmen UNet daha iyi bir performans göstermiştir. Daha hızlı olan test aşamasında UNet için Çizelge 5.2, SegNet için Çizelge 5.6 ve PSPNet için Çizelge 5.10’ da sunulduğu üzere, SegNet daha iyi bir performans göstermiştir. Ancak her üç mimaride bitki örtüsü ve araç sınıfında önemli derecede doğruluğun düştüğü tespit edilmiştir.

Zaman kullanımı açısından bakıldığı zaman SegNet ve UNet birbirine yakın bir süre


kullanımına sahip ancak PSPNet diğer iki mimariye göre iki katı bir zaman kullanmıştır. SegNet sadece maksimum havuzlama katmanındaki endeks değerlerini saklarken, UNet de tüm alt örnek değerleri saklanır. Bu durum hem hafıza kullanımında hem de zaman kullanımında SegNet' i, UNet' in bir adım önüne geçmesini sağlıyor. PSPNet' değse ResNet-50 ile köşe bilgilerinin elde edilip saklanması ve daha sonra farklı değerlerdeki havuzlama katmanlarından görüntülerin alınıp tekrar birleştirilmesi gibi karmaşık ve yoğun hafıza kullanımı gerektiren işlemler bulunduğu için hem zaman açısından hem de hafıza kullanımı açısından en kaba mimari olarak göze çarpıyor.

Potsdam veri seti, hem boyut hem de detay olarak Vaihingen veri setinden daha büyüktür. Bu açıdan bakıldığında kullanılan üç mimaride, Vaihingen veri setine göre doğruluk, zaman kullanımı ve hafıza kullanımı gibi konularda zorlanmışlardır. Vaihingen veri setinde elde edilen sonuçlardaki yüksek doğruluk kısmen düşmüş, ancak yine de tatmin edici seviyededir.

Eğitim aşamasında yine ilk olarak sınıflar arası doğruluklara bakacak olursak, Çizelge 5.21' de incelendiğinde SegNet ile en yüksek sınıf doğruluklarına ulaşıldığı ve homojen olan tahminler yapıldığı görülmektedir. UNet için Çizelge 5.13 ile PSPNet için Çizelge 5.21 karşılaştırıldığında, sınıflar arası doğruluklar her ikisinin de birbirine üstünlük kurduğu sınıfların olduğu ancak ikisinin de SegNet' in gerisinde kaldığı görülmektedir. Her üç mimaride de ağaç sınıfının diğer sınıflara göre düşük tahmin edildiği görülmüştür. Bunun sebebi olarak Şekil 6.3' te sunulan ağaç sınıfında olan detayların, gerçek zemin görüntülerinin, ortofotolarda tam karşılığının olmaması (ağaçların geniş yapraklı olmaması) olarak göze çarpmıştır. Kayıp değer grafikleri UNet için Şekil 5.4, SegNet için Şekil 5.5 ve PSPNet için Şekil 5.6' ya bakıldığı zaman, üç mimarinin de ortalama aynı kısım optimum seviyeye ulaşarak aynı değer aralıklarına geldiği görülmektedir. Kayıp değer grafiğindeki dalgalanmalar göze çarpmaktadır. Bu dalgalanmalara sebep olarak Şekil 6.3' de sunulan bitki örtüsü ile ağaç sınıfının karıştırılması verilebilir, bir diğer sebep ise Vaihingen veri setinde de olan ortofoto görüntülerdeki yırtılmalara bağlı sınır değerlerinin doğru tahmin edilememesidir (Şekil 6.4).



Şekil 6.3 Potsdam veri seti için, mimarilerde ağaç sınıfının ortofoto ile gerçek zemin görüntülerinin birbirini tam uyumlu olmamasından kaynaklı yanlış sınır tahmini. a) Ortofoto görüntü, b) Gerçek zemin görüntüsü, c) Mimari tahmin görüntüleri.



Şekil 6.4 Potsdam veri seti için, ortofoto görüntülerdeki yırtılmalardan kaynaklı sınır bilgilerinin yanlış tahmin edilmesi. a) Ortofoto görüntü, b) Gerçek zemin görüntüsü, c) Mimari tahmin görüntüleri.

Potsdam veri seti için yapılan sınıflandırmanın genel doğruluk açısından ne kadar uyumlu olduğunun tespiti, hata matrisi üzerinden elde edilen kappa değeri ile ölçülmüştür. Kappa değer tabloları UNet için Çizelge 5.15, SegNet için Çizelge 5.19 ve PSPNet için Çizelge 5.23 incelendiğinde, en uyumlu sınıflandırmanın SegNet ile yapıldığı görülmektedir. SegNet için test kısmında elde edilen kappa değerleri Çizelge 5.20 incelendiğinde, beklenenin aksine bir yükseliş görülmekte ve bunun sebebi olarak yama görüntülerden ziyade geniş çerçeveli tahminlerin iyi sonuçlar vermesi düşünülebilir. UNet ve PSPNet için sonuçlar incelendiğinden ortalama bir uyum görülmekte, bunun sebebi olarak bitki örtüsü ile ağaç veya bina ile zemin sınıfları arasında tam bir belirgin çizginin olmaması ve karışıklık sınıfının zemin sınıfı ile karıştırılması gibi nedenler göze çarpmaktadır.

Zaman ve hafıza kullanımı gibi kıstaslar göz önünde bulundurulduğunda PSPNet daha çok süre harcamış ve yüksek bellek kullanımı nedeniyle yığın değeri yarıya düşürülmüştür. SegNet ve UNet ise birbirlerine yakın değerler ile süre ve bellek harcamış, ancak SegNet bu konuda en iyi sonucu vermiştir.

SegNet için aynı veri seti ile yapılan çalışmalar incelendiğinde; Audebert vd. (2017) Vaihingen veri setindeki zemin için %91, bina için %94.5, bitki örtüsü için %84.2, ağaç için %89.3 ve araç için %85.7 ve Potsdam veri setindeki zemin için %92.4 bina için %95.8, bitki örtüsü için %86.7, ağaç için %87.4 ve araç için %95.1 sonuçları sunulmuştur. Bu çalışmada SegNet kullanılarak yapılan uygulamada; Vaihingen için Çizelge 5.5 incelendiği zaman, sınıflar arasında ortalama %95'lik doğruluk elde edildiği ve Potsdam için Çizelge 5.17' incelendiğin zaman, sınıflar arası ortalama %90'lık bir doğruluk elde edildiği görülmektedir. Audebert vd. (2017), farklı olarak bu çalışmada VGG16 yerine VGG19 mimarisi tercih edilmiş ve sonuçların daha iyi olduğu görülmüştür.

Li vd. (2020) yaptığı çalışma incelendiği zaman UNet ve SegNet mimarileri ayrı ayrı Vaihingen ve Potsdam veri setleri için kullanılmış ancak iki mimari içinde sınıflar arası ortalama %65'lik doğruluk elde edilmiştir. Bu çalışmada UNet kullanılarak yapılan uygulamada; Vaihingen için Çizelge 5.1 incelendiğin zaman sınıflar arası ortalama %85'lik ve Potsdam için Çizelge 5.13 incelendiği zaman, sınıflar arasında ortalama %82'lik doğruluk elde edildiği görülmektedir. Sonuçların bu kadar farklı olmasının sebebiyse Li vd. (2020)' nin kullanılan yama görüntü boyutlarının büyüklüğünden kaynaklı olduğu düşünülmektedir.

Mou vd. (2019), PSPNet kullanarak Vaihingen veri seti için yaptıkları çalışma incelendiğinde, elde edilen sonuçlar genel olarak aynı olmasına rağmen farklı olarak özellik çıkarımı için VGG16 mimarisi kullanılmıştır. Bu çalışmada PSPNet de özellik çıkarımı için ResNet-50 yapısı denenmiştir.

Bu çalışmada, Vaihingen ve Potsdam veri seti üzerinden uzaktan algılama verilerinin anlamsal bölütleme ile otomatik olarak sınıflandırılması için ESA yapısına sahip UNet,

SegNet ve PSPNet mimarileri ile uygulamalar yapılmıştır. Elde edilen sonuçlar göz önünde bulundurulduğunda, SegNet ağ yapısı ile en yüksek sınıf içi doğruluk ve genel sınıflandırmada yüksek bir uyum sağlanmıştır. UNet ve PSPNet ağ yapılarının uzaktan algılama verilerinin sınıflandırılması konusunda ortalama değerlerde kalmışlardır. DÖ en büyük dezavantajları yeteri kadar ve genel bir etiketli veri setine sahip olunamaması olarak görülmüş, bu yüzden her koşula uygun bir ağ yapısına sahip olmanın zorluğuna tekrar dikkat çekilmiştir. DÖ yeni olmasa da yeniden keşfedilmiş ve potansiyeli yüksek yapılardır, bu yüzden bu alanda yapılan çalışmaların arttırılıp uzaktan algılama verilerine uyumu açısından yeni fikirlere ve çalışmalara ihtiyacı vardır.

7. KAYNAKLAR

- Alom Z, Taha T, Yakopic C, Westberg S, Sidike P, Nasrin S, Esesn B, Awwal A, Asari V, 2018, The History Began from AlexNet: A Comprehensive Survey on Deep Learning Approaches, ArXiv, Article number, 1803.01164.
- Audebert N, Le Saux B, Lefèvre S, 2017, Beyond RGB: Very High Resolution Urban Remote Sensing with Multimodal Deep Networks, ArXiv, Article number, 1711.08681.
- Badrinarayanan V, Kendall A, Cipolla R, 2017, SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation, IEEE Transactions on Pattern Analysis and Machine Intelligence, 39, 2481-2495.
- Balaprakash P, Salim M, Uram T, Vishwanath V, Wild S, 2018, DeepHyper: Asynchronous Hyperparameter Search for Deep Neural Networks, IEEE 25th International Conference on High Performance Computing (HiPC), 17-20 December 2018, Bengaluru.
- Bianco S, Cadene R, Celona L, Napolitano, P, 2018, Benchmark Analysis of Representative Deep Neural Network Architecture, IEEE Access, 6, 64270-64277.
- Castelluccio M, Poggi G, Sansone C, Verdoliva L, 2015, Land Use Classification in Remote Sensing Images by Convolutional Neural Networks, ArXiv, Article number, 1508.00092.
- Chen Y, Lin Z, Zhao X, Wang G, 2014, Deep Learning-Based Classification of Hyperspectral Data, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 7, 2094-2107.
- Cireşan D, Giusti A, Gambardella L, Schmidhuber J, 2012, Deep Neural Networks Segment Neuronal Membranes in Electron Microscopy Images, Proceedings of the 25th International Conference on Neural Information Processing Systems, 2, 2843-2851.
- Ding J, Chen B, Liu H, Huang M, 2016, Convolutional Neural Network with Data Augmentation for Sar Target Recognition, IEEE Geoscience and Remote Sensing

- Letters, 13, 364-368.
- Eitel A, Springenberg J T, Spinello L, Riedmiller M, Burgard W, 2015, Multimodal Deep Learning for Robust Rgb-d Object Recognition, ArXiv, Article number, 1507.06821.
- Fukushima K, 1987, Neocognitron: A Hierarchical Neural Network Capable of Visual Pattern Recognition, Neural Networks, 1, 119-130.
- Goodfellow I, Shlens J, Szegedy C, 2015, Explaining and Harnessing Adversarial Examples, ArXiv, Article number, 1412.6572.
- He K, Zhang X, Ren S, Sun J, 2016, Deep Residual Learning for Images Recognition, IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 27-30 June 2016, Las Vegas.
- Hubel H D, Wiesel T N, 1962, Receptive Fields Binocular Interaction and Functional Architecture in the Cats Visual Cortex. The Journal of Physiology, 160, 106-154.
- Ioffe S, Szegedy C, 2015, Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, ArXiv, Article number, 1502.03167.
- Ishii T, Nakamura R, Nakada H, Mochizuki Y, Ishikawa, H, 2015, Surface Object Recognition with CNN and SVM in Landsat 8 Images, 14th IAPR International Conference on Machine Vision Applications (MVA), 18-22 May 2015, Tokyo.
- Kavzoğlu T, 2001, An Investigation of The Design and Use of Feed-Forward Artificial Neural Networks in The Classification of Remotely Sensed Image, University of Nottingham, PhD thesis, 325p.
- Krizhevsky A, Sutskever I, Hinton G E, 2012, Imagenet Classification with Deep Convolutional Neural Networks, Advances in Neural Information Processing Systems, 3-8 December 2012, Nevada.
- Kussul N, Lavreniuk M, Skakun S, Shelestov A, 2017, Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data, IEEE Geoscience and Remote Sensing Letters, 14, 778-782.
- LeCun Y, Bottou L, Bengio Y, Haffner P, 1998, Gradient-Based Learning Applied to Document Recognition, Proceedings of the IEEE, 86, 2278-2324.

- Li H, Qiu K, Chen L, Mei X, Hong L, Tao C, 2020, SCAttNet: Semantic Segmentation Network with Spatial and Channel Attention Mechanism for High-Resolution Remote Sensing Images, *IEEE Geoscience and Remote Sensing Letters*, 1, 1-5.
- Lindsay G W, 2020, Convolutional Neural Networks as a Model of The Visual System: Past, Present and Future, *Journal of Cognitive Neuroscience*, ArXiv, Article number, 2001.07092.
- Long J, Shelhamer E, Darrell T, 2015, Fully Convolutional Networks for Semantic Segmentation, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 7-12 June 2015, Boston.
- McCulloch W S, Pitts W, 1943, A Logical Calculus of The Ideas Immanent in Nervous Activity, *Bulletin of Mathematical Biophysics*, 5, 115-133.
- Mnih V, Hinton G, 2012, Learning to Label Aerial Images from Noisy Data, *Proceedings of the 29th International Conference on International Conference on Machine Learning*, June 2012, pages 203-210.
- Mou L, Hua Y, Zhu X X, 2019, A Relation-Augmented Fully Convolutional Network for Semantic Segmentation, *Conference on Computer Vision and Pattern Recognition (CVPR)*, 15-20 June 2019, Long Beach, CA, USA.
- Pal M, Mather P M, 2005, Support Vector Machines for Classification in Remote Sensing, *International Journal of Remote Sensing*, 26(5), 1007-1011.
- Pandya M, Shah P, Jardosh S, 2019, Medical Image Diagnosis for Disease Detection: A Deep Learning Approach, *U-Healthcare Monitoring Systems*, 1, 37-60.
- Ronneberger O, Fischer P, Brox T, 2015, U-Net: Convolutional Networks for Biomedical Image Segmentation, *Medical Image Computing and Computer-Assisted Intervention*, 5-9 October 2015, Munich.
- Rosenblatt F, 1958, The Perceptron: A Probabilistic Model for Information Storage and Organization in The Brain, *Psychological Review*, 65, 386-408.
- Ruder S, 2016, An Overview of Gradient Descent Optimization Algorithms, ArXiv, Article number, 1609.04747.
- Rumelhart E D, Hinton G E, Williams R J, 1986, Learning Representations by Back-

propagating Errors. *Nature*, 323, 533-536.

Sabour S, Frosst N, Hinton G E, 2017, Dynamic Routing Between Capsules, *ArXiv*, Article number, 1710.09829.

Simonyan A, Zisserman A, 2015, Very Deep Convolutional Networks for Large-Scale Image Recognition. *ArXiv*, Article number, 1409.1556.

Sze V, Chen Y, Yang T, Emer J, 2017, Efficient Processing of Deep Neural Networks: A Tutorial and Survey, *ArXiv*, Article number, 1703.09039.

Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, Erhan D, Vanhoucke V, Rabinovich A, 2015, Going Deeper with Convolutions, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 7-12 June 2015, Boston.

Venkatesan R, Prabu S, 2019, Hyperspectral Image Features Classification Using Deep Learning Recurrent Neural Networks, *Journal of Medical Systems*, 43, Article number, 216(2019).

Volpi M, Tuia D, 2016, Dense Semantic Labeling of Sub-Decimeter Resolution Images with Convolutional Neural Networks. *ArXiv*, Article number, 1608.00775.

Yang H L, Yuan J, Lunga D, Laverdiere M, Rose A, Bhaduri B, 2018, Building Extraction at Scale Using Convolutional Neural Network: Mapping of The United States, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11, 2600-2614.

Yue J, Zhao W, Mao S, Liu H, 2015, Spectral-Spatial Classification of Hyperspectral Images Using Deep Convolutional Neural Networks, *Remote Sensing Letters*, 6, 468-477.

Zhao H, Shi J, Qi X, Wang X, Jia J, 2017, Pyramid Scene Parsing Network, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 21-26 July 2017, Honolulu.

Zhong L, Hu L, Zhou H, 2018, Deep Learning Based Multi-Temporal Crop Classification, *Remote Sensing of Environment*, 221, 430-443.

Zhou Y T, Chellappa R, 1988, Computation of Optical Flow Using A Neural Network, *IEEE International Conference on Neural Networks*, 24-27 July 1988, San Diego.

ÖZGEÇMİŞ

Adı Soyadı : Mustafa Emre DÖŞ
Doğum Yeri ve Tarihi : Şahinbey 01.12.1993
Yabancı Dili : İngilizce
İletişim (Telefon/e-posta) : 5319905931 / mustafaemredos@gmail.com

Eğitim Durumu (Kurum ve Yıl)

Lise : Emine Konukoğlu Anadolu Lisesi, (2008-2012)
Lisans : Afyon Kocatepe Üniversitesi, Harita Mühendisliği Bölümü, (2013-2017)
Yüksek Lisans : Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalı, (2017-2020)

Çalıştığı Kurum/Kurumlar ve Yıl : Gaziantep Büyükşehir Belediyesi (2017- Devam ediyor)

Yayımları (SCI ve diğer) :

Döş M E, Uysal M, 2019, Uzaktan Algılama Verilerinin Derin Öğrenme ile Sınıflandırılması, Türkiye Uzaktan Algılama Dergisi, 1, 28-34.