**T.C.**

**YILDIZ TEKNİK ÜNİVERSİTESİ**

**FEN BİLİMLERİ ENSTİTÜSÜ**

# ARAZİ KULLANIM HARİTALARININ ÜRETİLMESİ AMACIYLA ORTOFOTOLARIN DERİN ÖĞRENME YÖNTEMLERİ KULLANILARAK SINIFLANDIRILMASI

**Berfin Pelin GÜNER**

YÜKSEK LİSANS TEZİ

Harita Mühendisliği Anabilim Dalı

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Programı

Danışman

Doç. Dr. Alper ŞEN

Şubat, 2025

**T.C.**

**YILDIZ TEKNİK ÜNİVERSİTESİ**

**FEN BİLİMLERİ ENSTİTÜSÜ**

# TEZ BAŞLIĞI

Berfin Pelin GÜNER tarafından hazırlanan tez çalışması 03.02.2025 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalı, Uzaktan Algılama ve CBS Programı **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Doç. Dr. Alper ŞEN
Yıldız Teknik Üniversitesi
Danışman

**Jüri Üyeleri**

Doç. Dr. Alper ŞEN, Danışman

Yıldız Teknik Üniversitesi _____

Doç. Dr. Tolga BAKIRMAN Üye

Yıldız Teknik Üniversitesi _____

Doç. Dr. Caner GÜNEY Üye

İstanbul Teknik Üniversitesi _____

Danışmanım Doç. Dr. Alper ŞEN sorumluluğunda tarafımca hazırlanan "Arazi Kullanım Haritalarının Üretilmesi Amacıyla Ortofotoların Derin Öğrenme Yöntemleri Kullanılarak Sınıflandırılması" başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Berfin Pelin GÜNER

İmza

# TEŞEKKÜR

Lisans ve Yüksek Lisans eğitimim boyunca çalışmalarımda yanımda olan ve yol gösteren danışman hocam Doç Dr. Alper ŞEN'e,

Yüksek Lisans sürecimde bilgi ve tecrübesini benimle paylaşan ve destekleyen Arş. Gör. Onur Can BAYRAK'a,

Eğitimim süresince manevi desteğini hissettiğim İller Bankası Mekânsal Planlama Dairesi Başkanlığı'ndaki çalışma arkadaşlarıma ve

Hayatım boyunca maddi manevi desteği ile her zaman yanımda olan aileme teşekkürlerimi sunarım.

Berfin Pelin GÜNER

# İÇİNDEKİLER

**SİMGE LİSTESİ** **vii**

**KISALTMA LİSTESİ** **viii**

**ŞEKİL LİSTESİ** **x**

**TABLO LİSTESİ** **xi**

**ÖZET** **xii**

**ABSTRACT** **xiv**

**1 GİRİŞ** **1**

1.1 Literatür Araştırması ..... 2
1.2 Tezin Amacı ..... 6
1.3 Hipotez ..... 6

**2 ARAZİ KULLANIM HARİTALARININ ÜRETİLMESİNDE CBS VE DERİN ÖĞRENME** **7**

2.1 CBS ..... 7
2.2 Arazi Kullanımı ..... 7

**3 YAPAY ZEKÂ-MAKİNE ÖĞRENMESİ-DERİN ÖĞRENME** **10**

3.1 Yapay Zekâ ..... 10
3.2 Makine Öğrenmesi ..... 10
3.3 Derin Öğrenme ..... 11
3.3.1 Aktivasyon Katmanı 14
3.3.2 Evrişim Katmanı 16
3.3.3 Hiperparametreler 18
3.3.4 Derin Öğrenme Ağları 19

3.3.5 Değerlendirme Metrikleri 22

**4 UYGULAMA 26**

4.1 Veri Seti ..... 26

4.2 Yöntem ..... 27

4.2.1 Ön İşleme 28

4.2.2 Eğitim 28

4.3 Bulgular ..... 29

4.3.1 Modeller Arası Karşılaştırma 31

4.3.2 Sınıflandırılmış Görüntülerin Karşılaştırılması 32

4.4 Değerlendirme ..... 36

4.3.3 Derin Öğrenme ile Arazi Kullanım Haritalarının Üretilmesi 38

**5 SONUÇ 46**

**KAYNAKÇA 48**

**TEZDEN ÜRETİLMİŞ YAYINLAR 51**

# SİMGE LİSTESİ

| | |
|---|---|
| $\beta$ | Momentum |
| $\alpha$ | Öğrenme Hızı |

# KISALTMA LİSTESİ

| | |
|---|---|
| ASPP | Atrous Spatial Pyramid Pooling, |
| CAII | Convolutional Attention Information Interaction |
| CBAM | Çok Başlıklı Dikkat Mekanizması |
| CBS | Coğrafi Bilgi Sistemleri |
| CNN | Evrişimsel Sinir Ağları |
| ÇKA | Çok Katmanlı Algılayıcı |
| DSN | Derin Sinir Ağları |
| DVM | Destek Vektör Makinaları |
| FCN | Fully Convolutional Networks |
| FHAM | Filtrelenmiş Hibrit Dikkat Mekanizması modülü |
| FN | Yanlış Negatif |
| FP | Yanlış Pozitif |
| FWIOU | Frequency Weighted Intersection over Union |
| GEE | Google Earth Engine |
| YÖA | Yer Örneklem Aralığı |
| IHA | İnsansız Hava Aracı |
| İBA | İleri Beslemeli Ağ |
| IoU | Kesişim-Birleşim Oranı |
| MIOU | Mean Intersection over Union |
| MPA | Mean Pixel Accuracy |
| MSF | Multi-Scale Fusion |
| OA | Overall Accuracy |
| RCA | Residual Channel Attention |
| RELU | Rectified Linear Unit |
| RESNET | Deep Residual Network |

| | |
|---|---|
| RMSE | Karesel Ortalama Hata |
| RNN | Recurrent Neural Networks |
| SIG | Semantic Information Guidance |
| SK | Selective Kernel |
| SVM | Support Vector Machines |
| TN | Doğru Negatif |
| TP | Doğru Pozitif |
| VIT | Vision Transformers |
| YSA | Yapay Sinir Ağları |

# ŞEKİL LİSTESİ

**Şekil 3.1** Yapay zekânın tarihsel gelişimi ..... 12

**Şekil 3.2** Temsiller hiyerarşisi kavramını ifade etmek üzere düzenlenmiş görsel. 13

**Şekil 3.3** Aktivasyon fonksiyonlarının grafikleri ..... 16

**Şekil 3.4** UNet Derin Öğrenme Mimarisi ..... 19

**Şekil 3.5** SegFormer-MixVTB3 Derin Öğrenme Mimarisi ..... 21

**Şekil 3.6** DeepLabV3+ Derin Öğrenme Mimarisi ..... 22

**Şekil 3.7** Kesinlik ve duyarlılık kavramlarını ifade etmek için hazırlanmış görsel. TP: doğru pozitif sınıflandırma durumu, FP: yanlış sınıflandırma durumu, FN: yanlışlıkla sınıf dışında bırakma durumu, TN: doğru biçimde sınıf dışında bırakma durumunu ifade etmektedir. ..... 24

**Şekil 3.8** Kesişim-Birleşim oranı (IoU) değerini ifade etmek için hazırlanmış görsel ..... 24

**Şekil 4.1** Çalışma alanının Türkiye'deki konumu (solda) ve Kırklareli'ndeki konumu (sağda) ..... 26

**Şekil 4 2** Çalışma alanının 1/25000 ölçekli ortofotosu ..... 27

**Şekil 4.3** İş akışını anlatan diyagram ..... 27

**Şekil 4.4** Etiketleme İşleminin yapıldığı programın ekran görüntüsü ..... 28

**Şekil 4.5** Kaynarca eğitim veri setindeki sınıflara ait piksel sayısı ve yüzdesi ..... 30

**Şekil 4.6** Kaynarca doğrulama veri setindeki sınıflara ait piksel sayısı ve yüzdesi ..... 31

**Şekil 4.7** Kaynarca test veri setindeki sınıflara ait piksel sayısı ve yüzdesi ..... 31

**Şekil 4.8** Derin öğrenme yöntemleri ile elde edilen sınıflandırma doğruluk metriklerinin karşılaştırılması ..... 32

**Şekil 4.9** Sınıflandırılmış görüntülerin karşılaştırılması ..... 35

**Şekil 4.10** Haritası oluşturulan bölgenin ortofotosu ..... 38

**Şekil 4.11** Davulga test bölgesine ait el ile çizilmiş olan harita ..... 39

**Şekil 4.12** Derin öğrenme yöntemleri ile üretilen sınıflandırma sonuçlarının karşılaştırılması ..... 39

**Şekil 4.13** Davulga test bölgesine ait ortofoto (a), elle çizilen bina ve yol tabakalarını içeren harita (b), SegFormer ile üretilen bina ve yol tabakalarını içeren harita (c), DeepLabV3+ üretilen bina ve yol tabakalarını içeren harita (d), UNet++ ile üretilen bina ve yol tabakalarını içeren harita (e), Attention UNet ile üretilen bina ve yol tabakalarını içeren harita (f) ..... 43

# TABLO LİSTESİ

**Tablo 3.1** Aktivasyon fonksiyonunun seçimi.....15
**Tablo 4.1** Model değerlendirme metriklerinin karşılaştırılması .....29
**Tablo 4.2** Veri setindeki sınıf dağılımları .....30
**Tablo 4.3** Derin öğrenme ağlarının eğitim sürelerinin karşılaştırılması .....38
**Tablo 4.4** Davulga bölgesi test verisine ait sınıflandırma sonuçları .....40
**Tablo 4.5** Alan uygunluk katsayısı (AUK) değerleri .....44

# ÖZET

## Arazi Kullanım Haritalarının Üretilmesi Amacıyla Ortofotoların Derin Öğrenme Yöntemleri Kullanılarak Sınıflandırılması

Berfin Pelin GÜNER

Harita Mühendisliği Anabilim Dalı

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Programı

Yüksek Lisans Tezi

Danışman: Doç. Dr. Alper ŞEN

Arazi kullanımının doğru ve verimli şekilde belirlenmesi, sürdürülebilir kalkınma ve planlama süreçleri için kritik bir öneme sahiptir. Özellikle, tarım, yerleşim, sanayi ve ulaşım gibi alanlarda yapılan planlamalar, doğal kaynakların etkin kullanımı ve çevresel sürdürülebilirlik açısından büyük bir rol oynamaktadır.

Ortofoto, hava veya uzaktan algılama yöntemleriyle elde edilen görüntülerin coğrafi olarak düzeltilmiş ve coğrafi bilgi sistemlerine uygun hale getirilmiş versiyonudur. Bu görüntüler, arazi kullanımını analiz etme ve değerlendirme süreçlerinde kritik bir araç olarak kullanılmaktadır.

Derin öğrenme, makine öğrenmesinin alt dalı olarak, yapay sinir ağlarını kullanarak daha karmaşık ve soyut temsil seviyelerine ulaşmayı hedefler. Karmaşık veri setleri üzerinde etkili ve doğru sınıflandırma yapar. Ancak çok sayıda etiketli veri gereksinimi ve yüksek hesaplama maliyeti dikkate alınmalıdır.

Bu çalışmada, Kırklareli'nin Kaynarca ilçesinde insansız hava aracı kullanılarak yapılan uçuş ile elde edilen hava fotoğrafları Pix4D yazılımı ile değerlendirilerek üretilen ortofoto veri seti kullanılmıştır. Görüntüler, veri ön işleme sürecinde alt görüntülere ayrılmıştır. Bu veriler, bina, yol, bitki örtüsü ve arka plan olmak üzere dört ana sınıfa ayrılarak etiketlenmiş ve sınıflandırma işlemi gerçekleştirilmiştir.

Sınıflandırma işlemi için DeepLabv3+, UNet++, SegFormer-MixVTB3 ve Attention UNet algoritmaları kullanılmıştır. Bu algoritmalar belirli bir sınıflandırma amacı için tasarlanmış olup, çeşitli veri setlerinde farklı performans seviyeleri göstermektedir. Eğitilen model, eğitim setinde olmayan Afyonkarahisar'ın Davulga ilçesi ortofotosu üzerinde test edilmiştir. Ortofoto görüntülerin arazi kullanımı amacıyla sınıflandırılmasında DeepLabv3+ ve SegFormer-MixVTB3 algoritmalarının performansı, diğer yöntemlere göre daha iyi sonuçlar elde etmiştir. Böylece, arazi örtüsü sınıflarının derin öğrenme yöntemleri kullanılarak oluşturulması ile arazi kullanım haritalarına altlık sağlanmıştır. Bu bulgular, derin öğrenme yöntemlerinin arazi örtüsü sınıflandırmasına etkin bir şekilde uygulanabileceğini ve gelecekteki araştırmalarda daha geniş veri setleri ile daha iyi sonuçlar elde edilebileceğini göstermektedir.

**Anahtar Sözcükler:** Arazi kullanımı, cbs, derin öğrenme, ortofoto

# ABSTRACT

## Classification Of Orthophotos Using Deep Learning Methods For The Production Of Land Use Maps

Berfin Pelin GÜNER

Department of Geomatic Engineering

Remote Sensing and GIS MSc. Program

Master of Science Thesis

Supervisor: Assoc. Prof. Dr. Alper ŞEN

Determining land use accurately and efficiently is critical for sustainable development and planning processes. In particular, planning in areas such as agriculture, settlement, industry and transportation plays a major role in the effective use of natural resources and environmental sustainability.

Orthophoto is a geographically corrected version of the images obtained by aerial or remote sensing methods and made suitable for geographic information systems. These images are used as a critical tool in land use analysis and assessment processes.

Deep learning, as a sub-branch of machine learning, aims to reach more complex and abstract levels of representation using artificial neural networks. It performs effective and accurate classification on complex data sets. However, a large number of labeled data and high computational cost should be considered.

In this study, the orthophoto dataset produced by evaluating the aerial photographs obtained through an unmanned aerial vehicle flight in Kaynarca district of Kırklareli with Pix4D software was used. The images were divided into sub-images in the data pre-processing process. These data were labeled and classified into four main classes: building, road, vegetation and background.

DeepLabv3+, UNet++, SegFormer-MixVTB3 and Attention UNet algorithms were used for classification. These algorithms are designed for a specific classification purpose and show different performance levels on various data sets. The trained model was tested on the orthophoto of Davulga district of Afyonkarahisar, which was not included in the training set. The performance of DeepLabv3+ and SegFormer-MixVTB3 algorithms outperformed the other methods in classifying orthophoto images for land use. Thus, by producing land cover classes using deep learning methods, a basis for land use maps was provided. These findings show that deep learning methods can be effectively applied to land cover classification and better results can be obtained with larger data sets in future research.

**Keywords**. Land use, gis, deep learning, ortophoto

# 1
# GİRİŞ

Arazi kullanımının doğru ve verimli bir şekilde belirlenmesi, sürdürülebilir kalkınma ve etkili planlama için büyük bir öneme sahiptir. Doğru bir arazi kullanımı, doğal kaynakların sürdürülebilirliği, çevresel etkilerin minimize edilmesi ve toplumsal ihtiyaçların karşılanması açısından kritik bir rol oynamaktadır.

Arazi kullanımının belirlenmesinde çeşitli görüntüleme teknikleri kullanılmaktadır. Bunlar arasında uydu görüntüleri, hava fotoğrafları, insansız hava aracı (İHA) görüntüleri ve ortofoto gibi farklı görüntü çeşitleri yer almaktadır. Özellikle ortofotolar, hava fotoğraflarının fotogrametrik yöntemlerle geometrik olarak düzeltilmesiyle elde edilmekte olup, yüksek konum doğruluğu sunmaktadır. Bu doğruluk, coğrafi bilgi sistemleri (CBS) ile entegre edilerek farklı veri setlerinin bir arada kullanılması ve analiz edilmesi açısından önemli avantajlar sağlamaktadır. Ortofotoların sınıflandırılması, arazi kullanımının doğru ve detaylı bir şekilde belirlenmesi için kritik bir adım olup, bu süreç hem operatör tarafından görsel kontrolle yapılabilir hem de makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak otomatikleştirilebilir.

Makine öğrenmesi, veriyi kullanarak beklenen çıktıları üretebilecek kuralları öğrenme yeteneğine sahip bir tekniktir. Derin öğrenme ise, makine öğrenmesinin bir alt dalıdır ve yapay sinir ağlarını kullanarak daha karmaşık ve soyut temsil seviyelerine ulaşmayı hedefler.

Derin öğrenme, özellikle büyük veri setleri ve güçlü hesaplama kaynakları ile etkili hale gelir. Çok katmanlı sinir ağları (derin sinir ağları) kullanarak verilerdeki öznitelikleri ve desenleri otomatik olarak öğrenir ve çıkarır. Bu bağlamda, evrişimli sinir ağları (Convolutional Neural Network, CNN) gibi mimariler, hava

fotoğraflarının ve ortofotoların sınıflandırılmasında yaygın olarak kullanılmaktadır. Derin öğrenme yöntemleri, ortofotoları kullanarak karmaşık arazi kullanım türlerini (örneğin, tarım, sanayi, yerleşim alanları ve ulaşım ağları) otomatik bir şekilde tanımlamak ve sınıflandırmak için güçlü bir araç sunar.

Özellikle büyük ölçekli coğrafi analizlerde, derin öğrenme modellerinin sağladığı yüksek doğruluk ve otomasyon kapasitesi, el ile yapılan sınıflandırma süreçlerinin getirdiği zorlukları aşabilme yeteneği ile birleşir. Bununla birlikte, derin öğrenme yöntemlerinin etkili bir şekilde uygulanabilmesi için büyük miktarda etiketlenmiş veri gereksinimi, yüksek hesaplama gücü ve uzun eğitim süreçleri gibi bazı dezavantajlar da mevcuttur. Ancak, bu zorluklara rağmen, derin öğrenme teknikleri, ortofotolardan elde edilen veriler üzerinde karmaşık örüntüleri tanıma yetenekleri sayesinde, farklı arazi kullanım türlerinin doğru bir şekilde belirlenmesinde önemli bir rol oynamaktadır.

## 1.1 Literatür Araştırması

Ronneberger vd. (2015), genişletilmiş tıbbi görüntü veri setleri kullanarak UNet ağını eğitmiştir. U-Net mimarisi, tıbbi görüntülerin segmentasyonu için önerilen bir yöntemdir. Çalışmada, ISBI hücre izleme yarışması 2015'te PhC-U373 veri kümesi üzerinde %92 IoU (Intersection over Union - Kesişim Birleşim Oranı) değeri elde edildiği belirtilmektedir. DIC-HeLa veri kümesi üzerinde ise IoU değeri %77,5 olarak raporlanmıştır.

Chen vd. (2018), boşluklu (atrous) ayrık evrişimi kullanarak semantik görüntü segmentasyonu için bir kodlayıcı-çözücü mimarisi önermektedir. Çalışmada, genişletilmiş veri setleri ile eğitilen DeepLabv3+ ağı kullanılarak PASCAL VOC 2012 test setinde %89,0 ve Cityscapes test setinde %82,1 mIoU değerleri elde edilmiştir.

Oktay vd. (2018), Attention U-Net mimarisini, tıbbi görüntülerin segmentasyonu için geliştirmiştir. Yazarlar, dikkat mekanizmaları kullanarak modelin öğrenme sürecini optimize etmiş ve UNet ile Attention UNet ağlarının performanslarını değerlendirmiştir. Eğitim verileri, çeşitli tıbbi görüntü verilerinden elde edilmiştir. Attention U-Net modeli, geleneksel U-Net'e göre 0.835±0.057 duyarlılıkta bir değer elde ederek önemli bir segmentasyon performansı iyileştirmesi göstermiştir.

Qin vd. (2020), tıbbi görüntü segmentasyonu için MFUnet adlı yeni bir derin öğrenme modeli önererek, dinamik reseptif alan kullanımının yani bir derin öğrenme modelinin giriş görüntüsündeki farklı boyutlardaki nesnelere uyum sağlamak için algıladığı bölgeyi esnek bir şekilde ayarlayabilmesinin bölütleme doğruluğuna etkisini incelemiştir. MFUnet, U-Net mimarisi temel alınarak geliştirilmiş ve Selective Kernel (SK) evrişimi ile birleştirilmiştir MFUnet modeli, hücre çekirdeği, meme kanseri hücreleri, bağırsak histolojisinde bezler ve optik disk/kup segmentasyonu gibi dört farklı biyomedikal görüntü veri kümesi üzerinde test edilmiştir. Model performansı ortalama IoU metriği ile değerlendirilmiş ve U-Net, UNet++ ve CE-Net ile karşılaştırılmıştır. Sonuçlara göre MFUnet, ortalama IoU değerlerinde U-Net'e kıyasla 1,8 puan, UNet++'a kıyasla 1,45 puan ve CE-Net'e kıyasla 2,82 puan daha yüksek doğruluk elde etmiştir.

Xie vd. (2021), Transformer tabanlı SegFormer mimarisini tanıtmaktadır. En iyi model olan SegFormer-B5 ile Cityscapes doğrulama setinde %84,0 mIoU elde edilmiştir.

Anilkumar ve Venugopal (2022), hava görüntülerinin anlamsal segmentasyonunda derin öğrenme tekniklerinin kullanımını kapsamlı bir şekilde inceleyerek bu alandaki mevcut araştırmaları değerlendirmiştir. Çalışmada, U-Net, DeepLabv3, SegNet ve Tam Evrişimli Ağlar (Fully Convolutional Networks, FCN) gibi popüler segmentasyon modelleri karşılaştırılmış ve performansları sayısal olarak analiz edilmiştir. Makale, segmentasyon modellerinin karşılaştırmalı analizinin yanı sıra, veri dengesizliği, görüntü çözünürlüğü ve etiketleme doğruluğu gibi önemli zorluklara da değinmiştir. Sonuç olarak, gelecekte hibrit modellerin geliştirilmesi, veri artırma tekniklerinin iyileştirilmesi ve daha büyük veri kümelerinin kullanılması önerilmektedir. Bu çalışma, hava görüntülerinin segmentasyonu alanında çalışan araştırmacılar için önemli bir referans niteliğindedir.

Zhou vd. (2023), uzaktan algılama görüntülerinin anlamsal segmentasyonu için otomatik olarak optimize edilen bir derin öğrenme yöntemi önermektedir. Çalışmada, özellikle evrimsel arama stratejileri kullanılarak özelleştirilmiş bir evrişimli sinir ağı (CNN) mimarisi tasarlanmış ve bu yöntem EAS-CNN olarak adlandırılmıştır. Yazarlar, geleneksel CNN tabanlı segmentasyon yaklaşımlarının genellikle el ile tasarlandığını ve bu sürecin zaman alıcı olmasının yanı sıra optimal

bir yapı elde etmeyi zorlaştırdığını vurgulamaktadır. Bu bağlamda, önerilen EAS-CNN yöntemi, CNN mimarisini evrimsel algoritmalarla otomatik olarak optimize ederek insan müdahalesine duyulan ihtiyacı azaltmayı amaçlamaktadır. Önerilen model, ISPRS Vaihingen veri setinde %91,2 genel doğruluk ve %83,3 mIoU; ISPRS Potsdam veri setinde ise %91,6 genel doğruluk ve %87,1 mIoU elde ederek yüksek segmentasyon başarımı göstermiştir. Çalışma, uzaktan algılama alanında bina, yol ve arazi örtüsü sınıflandırmalarında etkin sonuçlar sunarak hassas tarım, kentsel planlama ve çevresel izleme gibi uygulamalar için önemli bir katkı sağlamaktadır.

Hu vd. (2023) tarafından geliştirilen *MCSGNet*, arazi örtüsü sınıflandırması için derin öğrenmeye dayalı yeni bir kodlayıcı-çözücü mimarisi önermektedir. Uzaktan algılama görüntülerinden arazi türlerinin doğru sınıflandırılması, çevresel izleme, şehir planlaması ve doğal kaynak yönetimi gibi alanlarda kritik bir rol oynamasına karşın mevcut yöntemler düşük doğruluk, gürültüye duyarlılık ve zayıf genelleme kapasitesi gibi sorunlarla karşı karşıyadır. Bu çalışmada geliştirilen *MCSGNet* çok ölçekli bağlamsal bilgi kılavuzluğu sağlanarak sınıflandırma performansının artırılması hedeflenmiştir. Model, Artık Kanal Dikkat (*Residual Channel Attention ,RCA)* modülü ile yerel ve küresel özellikleri etkin şekilde çıkarırken, Evrişimsel Dikkat Bilgi Etkileşimi (*Convolutional Attention Information Interaction, CAII)* modülüyle bilgi akışını güçlendirmektedir. Ayrıca, Anlamsal Bilgi Yönlendirme (*Semantic Information Guidance, SIG)* ve Çok Ölçekli Birleştirme (*Multi-Scale Fusion, MSF)* modülleri kullanılarak çok katmanlı özelliklerin etkileşimi sağlanmış ve detay kaybı en aza indirilmiştir. Model LandCover ve WHDLD veri setleri üzerinde test edilmiş ve değerlendirme için Oratalama Piksel Doğruluğu (Mean Pixel Accuracy, MPA) Mean Intersection over Union (MIOU) ve Frequency Weighted Intersection over Union (FWIOU) metrikleri kullanılmıştır. LandCover veri setinde MPA %94,56 MIOU %87,43 ve FWIOU %91,10; WHDLD veri setinde MPA %76,12 MIOU %64,24 ve FWIOU %83,12 olarak hesaplanmıştır. Bu sonuçlar, *MCSGNet*'in mevcut yöntemlere kıyasla daha yüksek doğruluk ve genelleme kabiliyeti sunduğunu göstermektedir.

Wahbi vd. (2023) çalışmalarında, derin öğrenme yöntemlerini kullanarak Fas'ın Souss-Massa bölgesindeki kırsal yerleşim alanlarının tespit edilmesini amaçlamaktadır. Geleneksel görüntü işleme teknikleri, kırsal bölgelerde yer alan

düzensiz ve çeşitli yapı malzemelerinden oluşan yerleşim alanlarını tespit etmede yetersiz kalmaktadır. Veri seti olarak Sentinel-2 uydu görüntüleri kullanılarak derin öğrenme modelleriyle sınıflandırma gerçekleştirilmiştir. Çalışmada, UNet, filtre sayısı artırılmış UNet ve ResUNet olmak üzere üç farklı model denenmiş ve performansları doğruluk, kesinlik, duyarlılık, F1 skoru ve ROC eğrisi gibi metrikler kullanılarak değerlendirilmiştir. Elde edilen sonuçlara göre, en yüksek doğruluk %97.6 ve %54.1 F1 skoru filtre sayısı artırılmış UNet modeliyle elde edilmiştir. UNet modeli %83,0 doğruluk ve %86.2 kesinlik sunarken, ResUNet modeli %72,7 doğruluk ve %81.2 kesinlik ile daha düşük performans göstermiştir. Çalışma, filtre sayısının artırılmasının modelin özellik çıkarma yeteneğini güçlendirerek daha yüksek doğruluk sağladığını ortaya koymuştur. Ayrıca, model performansının kullanılan uydu görüntülerinin çözünürlüğü ve eğitim veri setinin büyüklüğünden önemli ölçüde etkilendiği gözlemlenmiştir. Çalışmanın sonuçları, kırsal yerleşim alanlarının haritalanması için derin öğrenme yöntemlerinin etkili bir şekilde kullanılabileceğini göstermektedir. Bununla birlikte, model doğruluğunu artırmak amacıyla Sentinel-1 ve Sentinel-2 verilerinin birleştirilmesi, eğitim verilerinin arttırılması ve Google Earth Engine (GEE) gibi bulut tabanlı sistemlerden faydalanılması önerilmektedir.

Abbas vd. (2024), çalışmalarında havadan görüntülerden coğrafi unsurları (binalar, ormanlar, su kütleleri ve yollar) hızlı ve doğru bir şekilde haritalamak için derin öğrenme tekniklerinin nasıl kullanabileceğini incelemişlerdir. Çalışma, uzaktan algılama verilerinin analizini derin öğrenme yöntemleriyle daha verimli hale getirmeyi ve doğruluğu artırmayı amaçlamaktadır. Çalışmada, Vanilla-UNet, DeeplabV3 ResNet50 ve ResNet50 UNet evrişimsel sinir ağları kullanılarak 256x256 piksel çözünürlüğünde 1000'den fazla yüksek çözünürlüklü havadan görüntü üzerinde eğitim yapılmıştır. DeepLabV3 ResNet50 modeli %94,77, ResNet50 UNet modeli %94,37 ve Vanilla-UNet modeli %91,31 doğruluk göstermiştir. Bu çalışma derin öğrenme yöntemlerinin coğrafi unsurların haritalanmasında güçlü bir araç olduğunu ve bu yöntemlerin şehir planlaması, altyapı izleme ve çevresel analizler gibi alanlarda sağladığı yüksek doğruluğun geleneksel yöntemlere göre büyük bir avantaj sunduğunu vurgulamaktadır. Derin öğrenme modellerinin büyük veri setlerini işleme kapasitesi, bu tür haritalama çalışmalarının daha hızlı ve doğru bir şekilde yapılmasına olanak tanımaktadır.

Ge vd. (2025) çalışmalarında önerdikleri yöntem, MobilNetV2 omurgası üzerine inşa edilmiştir. Model, yüksek seviyeli özellikler için Filtrelenmiş Hibrit Dikkat Mekanizması (Filtered Hybrid Attention Mechanism, FHAM) ve düşük seviyeli özellikler için Çoklu Dikkat Mekanizması (Multi-head Attention Mechanism, MAM) olmak üzere iki temel bileşenden oluşmaktadır. Deneyler, LoveDA, ISPRS Vaihingen ve Gaofen-3 (GF-3) SAR uydu veri kümeleri üzerinde gerçekleştirilmiştir. Önerilen model, LoveDA veri setinde mIoU değerini %63,86'ya, F1 skorunu %76,92'ye çıkararak önceki yöntemlere kıyasla belirgin iyileşmeler sağlamıştır. ISPRS Vaihingen veri setinde mIoU %87,37'ye, F1 skoru %93,20'ye; GF-3 SAR veri setinde ise mIoU %79,92'ye, F1 skoru %88,70'e ulaşmıştır. DeepLabV3+, PSPNet ve RAANet gibi popüler segmentasyon modelleriyle kıyaslandığında, özellikle çok sınıflı karmaşık sahnelerde ve küçük veri setleriyle çalışırken daha yüksek doğruluk elde edilmiştir. Sonuçlar, önerilen hibrit dikkat mekanizmasının uzaktan algılama görüntülerinde detay koruma ve bağlamsal farkındalığı artırmada etkili olduğunu göstermektedir. Bu yaklaşım, hesaplama verimliliğini sağlarken, semantik segmentasyon doğruluğunu da geliştirmektedir.

## 1.2 Tezin Amacı

Bu çalışmanın amacı, kırsal alanlarda arazi kullanım haritası oluşturmak için ortofotolardan derin öğrenme ağları kullanılarak arazi örtüsü sınıflandırması yapmaktır. Ayrıca, farklı derin öğrenme ağalarının ortofoto sınıflandırma performansını karşılaştırarak elde edilen haritanın, el ile oluşturulan haritalarla uyumunu ve doğruluğunu değerlendirmeyi hedeflemektedir.

## 1.3 Hipotez

Derin öğrenme yöntemleri arazi örtüsü sınıflandırma görevlerinde kullanılabilir.

Üretilen arazi örtüsü sınıfları arazi kulanım haritalarının oluşturulmasında altlık sağlayabilir.

Derin öğrenme yöntemleri, kırsal alanlarda el ile yapılan arazi sınıflandırmasına kıyasla daha hızlı, maliyet etkin ve ölçeklenebilir harita üretimi çözümleri sunabilir.

# 2
# ARAZİ KULLANIM HARİTALARININ ÜRETİLMESİNDE CBS VE DERİN ÖĞRENME

## 2.1 CBS

Coğrafi Bilgi Sistemleri (CBS), mekansal verilerin toplanması, saklanması, analiz edilmesi ve görselleştirilmesi sürecinde kullanılan güçlü bir araçtır. CBS, arazi kullanımının izlenmesi, değerlendirilmesi ve yönetilmesi açısından önemli avantajlar sunar. Uydu görüntüleri, ortofotolar ve hava fotoğrafları gibi uzaktan algılama verileri, CBS ortamına entegre edilerek arazi kullanımının sınıflandırılması ve değişimlerin izlenmesi sağlanır. Son yıllarda, CBS ile birlikte derin öğrenme gibi gelişmiş yöntemler, arazi kullanım sınıflandırmasında yoğun olarak kullanılmaya başlanmıştır. Derin öğrenme algoritmaları, büyük veri kümeleri üzerinde karmaşık desenleri öğrenme kapasitesine sahiptir ve bu sayede uydu görüntülerinden yüksek doğrulukla arazi kullanım türlerinin sınıflandırılmasına olanak tanır (Zhu vd., 2017). Örneğin, CNN gibi derin öğrenme teknikleri, arazi türlerinin görsel özelliklerini belirlemede oldukça başarılıdır ve büyük veri kümeleri üzerinde çalışarak farklı arazi kullanım türlerini otomatik olarak ayırt edebilir. Derin öğrenme tekniklerinin CBS'ne entegrasyonu, arazi kullanım analizlerinin doğruluğunu artırmakta ve daha hızlı sonuçlar elde edilmesine olanak tanımaktadır. Bu nedenle, CBS ve yapay zekâ destekli analizlerin yaygınlaşması, sürdürülebilir arazi yönetimi ve çevresel planlama süreçlerinde kritik bir rol oynamaktadır.

## 2.2 Arazi Kullanımı

Arazi kullanımının belirlenmesi, coğrafi bölgelerdeki insan faaliyetlerinin ve doğal çevrenin kapsamlı bir analizidir. Bu süreç, hangi alanların tarımsal, kentsel, sanayi, orman ya da su alanları olarak kullanıldığını, aynı zamanda bu alanların işlevsel

değişimlerini tanımlamak ve haritalarının oluşturulması amacıyla yapılır. Arazi kullanım belirlemesi, sürdürülebilir kalkınma politikalarının oluşturulmasında, kaynak yönetiminde ve çevresel etki değerlendirmelerinde kritik rol oynar.

Arazi kullanımının belirlenmesinde Coğrafi Bilgi Sistemleri (CBS) ve uzaktan algılama gibi teknolojilerden faydalanılır. Uydu görüntüleri, hava fotoğrafları ve dijital haritalar kullanılarak yapılan bu analizler, arazi üzerindeki çeşitli kullanım türlerini detaylandırarak farklı sınıflar altında toplar. Örneğin, uydu görüntülerinden elde edilen veriler, şehirleşme, tarım alanlarının genişlemesi, orman kayıpları veya su kaynaklarının azalması gibi arazi kullanımındaki değişimleri zaman içinde izlemeyi mümkün kılar. Bu değişimlerin izlenmesi, çevresel ve sosyal etkenlerin yerel ve küresel düzeydeki etkilerinin anlaşılmasına da katkı sağlar.

Arazi kullanımının belirlenmesinin başlıca amaçları, doğal kaynakların korunması, şehir planlaması ve altyapı geliştirme, çevresel etki değerlendirmesi, tarım ve gıda güvencesi ile doğal afet yönetimi olarak sıralanabilir. Doğal kaynakların korunması, ormanlık alanlar, tarım arazileri ve su kaynakları gibi kaynakların korunması için stratejik planlama yapılmasına olanak tanır. Şehirleşme ve altyapı ihtiyaçları için kullanılacak alanların doğru belirlenmesi ise şehir planlamasının etkinliğini artırır. Çevresel etki değerlendirmesi, çevresel planlama ve sürdürülebilirlik stratejileri için önemlidir. Ayrıca, tarım ve gıda güvencesi açısından da tarımsal alanların doğru sınıflandırılması ve yönetilmesi, gıda arz güvenliğini destekler (Tilman vd., 2001). Doğal afet yönetimi bağlamında da arazi kullanımının doğru belirlenmesi, sel, yangın ve heyelan gibi afet risklerinin azaltılmasına katkı sağlar (Nedovic-Budic vd., 2004).

CORINE (Coordination of Information on the Environment), Avrupa'da çevresel izleme ve kaynak yönetimini desteklemek amacıyla geliştirilen bir sınıflandırma sistemidir. 1985'te başlatılan CORINE, Avrupa'daki farklı arazi kullanım türlerini 44 sınıfa ayırarak çevresel değişimlerin izlenmesini kolaylaştırır. İlk veri seti 1990'da oluşturulmuş ve 2000, 2006, 2012 ve 2018 yıllarında güncellenmiştir. Avrupa Çevre Ajansı tarafından yönetilen CORINE, uydu görüntüleri ve CBS analizleri kullanılarak geliştirilmiştir (Bossard vd., 2000).

CORINE sınıflandırma sistemine göre ortofotolar kullanılarak derin öğrenme tabanlı sınıflandırma çalışmaları son yıllarda oldukça ilgi görmüştür. Bu çalışmalar, özellikle yüksek çözünürlüklü uydu görüntüleri veya insansız hava araçları (İHA) ile elde edilen ortofotolar üzerinden, CORINE standartlarına uygun arazi kullanım sınıflarının otomatik olarak belirlenmesini amaçlamaktadır.

Benzer bir şekilde, Castelluccio vd. (2017) İtalya'nın kırsal bölgelerindeki tarım alanlarının sınıflandırılmasında derin öğrenme tabanlı bir model kullanarak CORINE standartlarına uygun analizler yapmıştır. Çalışmalarında CNN tabanlı bir model kullanarak ortofoto veriler üzerinden arazi kullanım sınıfları olan ekili alan, orman, çıplak arazi ve su kütlelerini ayırmışlardır. Bu sınıflandırmada, özellikle karmaşık alanlarda CNN'nin yüksek doğruluk oranları sunması, CORINE veri seti ile uyumlu bir sınıflandırma modeli geliştirilmesine katkı sağlamıştır. (Castelluccio vd., 2017).

Bachantourian vd. (2022), Akdeniz bölgesinde 2018 yılına ait veri setlerini karşılaştırarak orman, tarım ve kentleşmiş alanları tanımlamada veri setlerinin performansını değerlendirir. Sonuçlar, CLC veri setinin %37,47 ile en yüksek genel doğruluğa sahip olduğunu, MODIS ve ESA-CCI-LC'nin ise daha düşük doğruluk oranlarına (%22 civarında) sahip olduğunu göstermektedir. Özellikle, tüm veri setlerinde ormanlık alanların eksik sınıflandırıldığı görülmüş ve geniş sınıflandırmalar için (örneğin, orman ve orman dışı alanlar) doğruluğun %70 üzeri belirlenmiştir. Çalışmada, CORINE 2018 veri seti Kassandra referans veri setine göre doğruluk açısından karşılaştırılmış ve özellikle ormanlık alanların sınıflandırılmasında bazı yetersizlikler gözlemlenmiştir. Bu tür çalışmalar, derin öğrenme teknikleri ve CORINE sisteminin entegrasyonunun, coğrafi bilgi sistemleri ve uzaktan algılama alanında arazi sınıflandırma süreçlerinde büyük bir potansiyele sahip olduğunu göstermektedir.

# 3
# YAPAY ZEKÂ-MAKİNE ÖĞRENMESİ-DERİN ÖĞRENME

## 3.1 Yapay Zekâ

Yapay zekâ, insan benzeri düşünme ve problem çözme yeteneklerini taklit etmeyi hedefleyen bir disiplin olarak tanımlanabilir. Yapay zekânın kökleri, 1950'li yıllara kadar uzanmaktadır. Alan Turing, 1950 yılında yayımladığı "Computing Machinery and Intelligence" başlıklı makalesinde, makinelerin düşünme yeteneğini sorgulamış ve bu bağlamda Turing Testi'ni önermiştir (Turing, 1950). Turing Testi, bir makinenin insan benzeri zekâ sergileyip sergilemediğini belirlemek için kullanılan bir ölçüttür. Bu dönemde, ilk programlar ve algoritmalar geliştirilmiş ve yapay zekânın temel ilkeleri oluşturulmuştur.

1956 yılında düzenlenen Dartmouth Konferansı, yapay zekâ araştırmalarının resmi olarak başladığı yer olarak kabul edilmektedir. John McCarthy, Marvin Minsky, Nathaniel Rochester ve Claude Shannon gibi önde gelen bilim insanları, burada yapay zekânın potansiyelini tartışmış ve ilk sistemlerin geliştirilmesine yönelik adımlar atılmıştır. Ancak, 1960'lar ve 1970'lerde gerçekleştirilen araştırmalar, sınırlı başarı oranları nedeniyle yapay zekâ çalışmalarının duraklama dönemine girmesine neden olmuştur.

## 3.2 Makine Öğrenmesi

Makine öğrenmesi, yapay zekânın bir alt dalı olarak, bilgisayarların verilerden öğrenmesini ve belirli görevleri yerine getirmesini sağlayan algoritmaları içerir. 1980'lerin başında öne çıkmaya başlayan makine öğrenmesi, regresyon ve sınıflandırma gibi temel yöntemlerin yanı sıra, destek vektör makineleri (SVM) ve karar ağaçları gibi daha karmaşık yöntemler geliştirilmiştir (Bishop, 2006).

Makine öğrenmesinin önemli bir dönüm noktası, 1997 yılında IBM'in Deep Blue bilgisayarının dünya satranç şampiyonu Garry Kasparov'u yenmesidir. Bu başarı, makine öğrenmesinin potansiyelini ve uygulama alanlarını gösteren önemli bir örnek teşkil etmektedir. 2000'li yılların başlarında, büyük veri ve güçlü hesaplama kaynaklarının ortaya çıkmasıyla, makine öğrenmesi uygulamaları hız kazanmıştır. Veri madenciliği, görüntü işleme ve doğal dil işleme gibi alanlarda makine öğrenmesi teknikleri yoğun bir şekilde kullanılmaya başlanmıştır. Bu dönemde, özellikle denetimli öğrenme ve denetimsiz öğrenme yaklaşımları yaygınlaşmıştır (Jordan ve Mitchell, 2015).

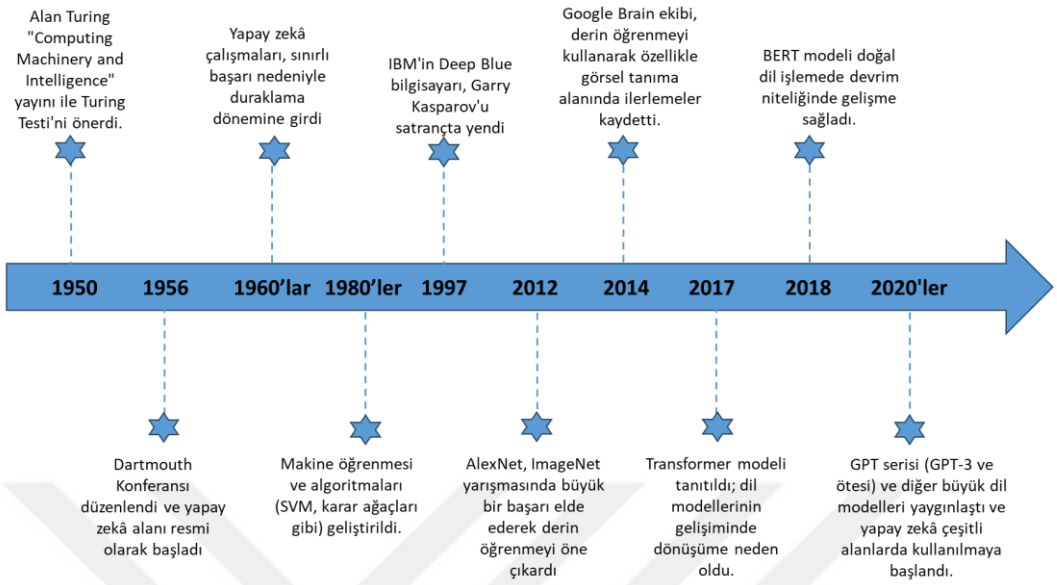
Makine öğrenmesinde kullanılan temel algoritmalar, genellikle denetimli ve denetimsiz öğrenme olarak iki ana kategoriye ayrılmaktadır. Denetimli öğrenme, modelin eğitilmesi için etiketlenmiş verilerin kullanıldığı bir yöntemdir. Bu yöntemde, model geçmiş verilerden öğrenir ve gelecekteki verilere uygulamak üzere tahminlerde bulunur. Denetimsiz öğrenme ise, modelin etiketlenmemiş verilerle eğitildiği bir yöntemdir. Bu tür yöntemler, verilerdeki yapıları keşfetmek ve gruplama gibi görevleri yerine getirmek için kullanılır (Hastie vd., 2009).

Makine öğrenmesi karmaşık veriyi kullanma, anlamsal segmentasyon ve sınıflandırma için kuvvetli bir matematiksel araçtır. Makine öğrenmesi veriyi ve beklenen çıktıları kullanarak yeni verilere özgün cevaplar üretebilecek kuralları öğrenir. Bilgiyi verilen kurallar çerçevesinde işlemektense bu bilgiyi nasıl işleyeceğine dair öğrenme görevlerini yerine getirmeyi, duruma özgü yeni kurallar yaratabilmeyi hedefler. Makine öğrenmesi modelleri genel olarak girdi veriyi beklenen çıktılara dönüştürmeyi başaracak fonksiyon ve ilişkili parametrelerden oluşmaktadır. Bu fonksiyon ve parametre setlerinin seçilmesi, ilgili parametrelerin otomatik biçimde öğrenilmesinin sağlanması ana araştırma alanları olarak ön plana çıkmıştır (Goodfellow vd., 2015).

## 3.3 Derin Öğrenme

Derin öğrenmenin ilerlemesi, büyük veri setlerinin ve güçlü hesaplama kaynaklarının erişilebilir hale gelmesiyle hızlanmıştır. 2012 yılında Hinton'un ekibi, ImageNet yarışmasında derin öğrenme yöntemlerini kullanarak diğer sistemlere göre büyük bir başarı elde etmiştir. Bu başarı, derin öğrenmenin görsel

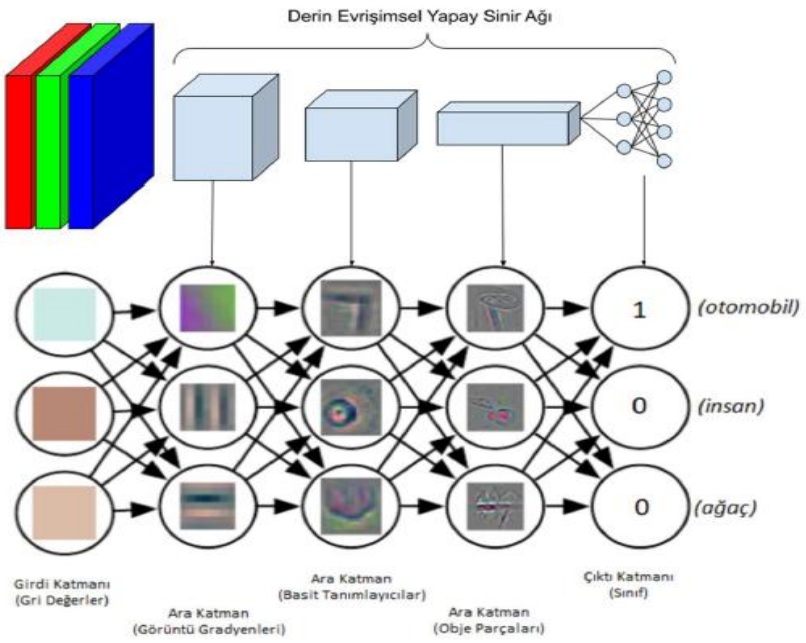
tanıma alanında devrim niteliğinde bir etkisi olduğunu göstermiştir (Krizhevsky vd., 2012). Şekil 3.1'de yapay zekânın tarihsel gelişimi gösterilmiştir.




**Şekil 3.1** Yapay zekânın tarihsel gelişimi (Goodfellow vd., 2016; Hastie vd., 2009; Jordan ve Mitchell, 2015; Krizhevsky vd., 2012; LeCun vd., 2015)

Derin öğrenme temellerini yapay sinir ağlarından alan bir makine öğrenmesi tekniğidir. Kavramın isminde geçen derinlik terimi modellerin içerdiği katman sayısına bir referans olarak kullanılmaktadır. Bu yaklaşımda amaç çok sayıda sıralı katmandan oluşan modeller kullanarak sınıflandırma, segmentasyon ve obje yakalama gibi veri işleme görevleri için daha kullanışlı olduğu düşünülen bir temsiller hiyerarşisi elde etmektir.

Yapay Sinir Ağları (YSA), biyolojik sinir sisteminden esinlenerek geliştirilen ve bilgi işleme kapasitesine sahip algoritmalardır. Bu ağlar, genellikle çok sayıda katmandan ve her katmanda yer alan birçok yapay nörondan oluşur. Her nöron, belirli bir giriş verisini işleyerek diğer nöronlara sinyaller gönderir ve bu sayede girdi verilerinden sonuç çıkarımı yapılır. YSA, makine öğreniminin bir alt alanı olan derin öğrenmenin temelini oluşturur ve günümüzde görüntü işleme, dil işleme ve ses tanıma gibi çeşitli alanlarda yoğun olarak kullanılmaktadır (Goodfellow vd., 2016; LeCun vd., 2015).




**Şekil 3.2** Temsiller hiyerarşisi kavramını ifade etmek üzere düzenlenmiş görsel (Goodfellow vd, 2015).

Bir yapay sinir ağı, katmanlar halinde organize edilmiştir (Şekil 3.2); genellikle bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanı bulunur. Giriş katmanı, ham veriyi alır ve her nöron, bu veriyi ağırlıklandırır, aktivasyon fonksiyonları kullanarak işleme sokar ve sonraki katmana iletir. Gizli katmanlar, veriyi daha yüksek soyutlama seviyelerinde işleyerek karmaşık ilişkiler yakalar. Çıkış katmanı ise ağın nihai tahmin veya sınıflandırma sonucunu verir (Rumelhart vd.,1986).

YSA'nın eğitimi, genellikle hata geri yayılım (backpropagation) algoritması ile yapılır. Bu yöntem, ağın çıkışında yapılan hatayı azaltmak amacıyla her bağlantı ağırlığını günceller. Eğitim sürecinde, bir kayıp fonksiyonu yardımıyla hata ölçülür ve bu hata, ağın ağırlıklarına geri beslenerek ağırlıkların optimize edilmesini sağlar (Rumelhart vd.,1986). Öğrenme oranı gibi hiperparametreler, eğitim sürecinin doğruluğunu ve hızını doğrudan etkiler.

YSA'nda aktivasyon fonksiyonları, nöronların çıktılarını sınırlandırarak öğrenme kapasitesini artırır. Yaygın olarak kullanılan aktivasyon fonksiyonları arasında sigmoid, hiperbolik tanjant (tanh) ve ReLU (Rectified Linear Unit) yer alır. ReLU,

özellikle derin öğrenme modellerinde yüksek başarı oranı ile öne çıkar; negatif değerleri sıfıra indirgerken pozitif değerleri olduğu gibi geçirir, bu sayede gradyan kaybı (vanishing gradient) sorununu azaltır (Glorot ve Bengio, 2010; Nair ve Hinton, 2010).

YSA'nın daha derin ve karmaşık yapılara sahip olan türevleri derin sinir ağları olarak adlandırılır. Derin Sinir Ağları (DSA - Deep Neural Networks, DNN), çok katmanlı yapılarıyla verilerden soyut özellikler öğrenme yeteneğini artırır. Derin sinir ağları, sinyalin her katmanda işlenmesiyle daha karmaşık ve soyut temsiller oluşturur ve görüntü tanıma, doğal dil işleme gibi alanlarda insan düzeyine yakın performans sergiler (LeCun vd., 2015).

DSA yapıları, çok katmanlı yapay sinir ağları olarak birden fazla gizli katmana sahiptir ve her bir katman, bir önceki katmandan gelen veriyi işleyerek daha üst düzeyde özellikler çıkartır. DSA'nın her katmanı, veriyi farklı bir soyutlama seviyesine taşır ve böylece veri çok daha detaylı bir şekilde temsil edilebilir hale gelir. Görüntü tanıma gibi bir görevde, ilk katmanlar kenar ve renk gibi temel özellikleri çıkarırken, son katmanlara doğru daha karmaşık formlar ve nesne özellikleri yakalanır (LeCun vd., 2015).

### 3.3.1 Aktivasyon Katmanı

Aktivasyon fonksiyonları, derin öğrenme modellerinde doğrusal olmayan dönüşümler oluşturarak, ağın karmaşık veri ilişkilerini öğrenebilmesini sağlayan temel bileşenlerdir. Bu fonksiyonlar, nöronlara gelen giriş değerlerini işler ve bir sonraki katmana iletilecek çıktıları belirler. Eğer bir yapay sinir ağı yalnızca doğrusal işlemlerden oluşursa, ne kadar katman eklenirse eklensin, bu ağ yalnızca doğrusal fonksiyonları modelleyebilir ve karmaşık problemlerin çözümünde yetersiz kalır. Oysa gerçek dünyadaki veriler genellikle doğrusal olmayan ve çok boyutlu ilişkiler içerir.

Aktivasyon fonksiyonlarının en önemli rolü, modele doğrusal olmayan karar sınırlarını öğrenebilme yeteneği kazandırmasıdır (Tablo 3.1). Örneğin, ReLU (Rectified Linear Unit) gibi yaygın kullanılan aktivasyon fonksiyonları, negatif girdileri sıfıra eşitleyerek pozitif değerleri doğrudan iletir. Bu özellik, gradyan hesaplamalarını basitleştirerek öğrenme sürecinin daha hızlı ve etkin hale gelmesini

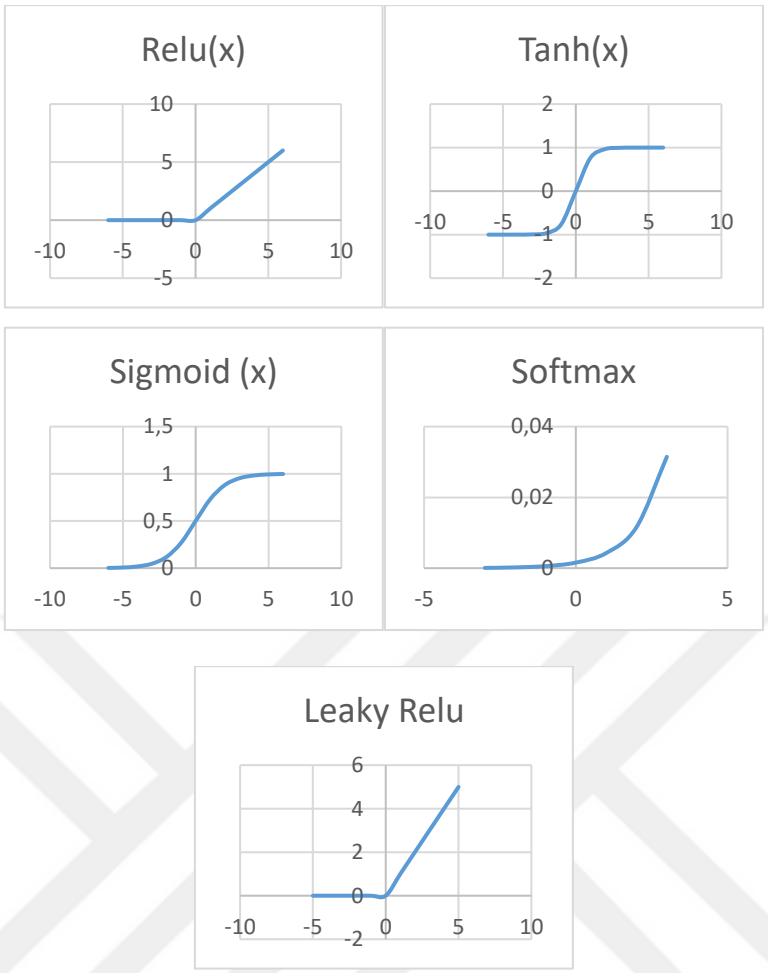
sağlar. Buna karşılık Sigmoid ve Tanh gibi fonksiyonlar girdileri belirli bir aralığa sıkıştırarak, ağırlıkların daha kontrollü güncellenmesine yardımcı olur. Ancak bu tür fonksiyonlar, özellikle derin ağlarda gradyan sönmesi (Vanishing Gradient) problemine yol açabilmektedir.

Ayrıca, aktivasyon fonksiyonları ağın çıktı katmanında da önemli bir rol oynar. Özellikle Softmax fonksiyonu, sınıflandırma problemlerinde çıktı değerlerini 0 ile 1 arasına normalize ederek, bu değerlerin olasılık dağılımı şeklinde yorumlanmasını sağlar. Böylece modelin, farklı sınıflara ait olasılıkları doğru bir şekilde temsil etmesine olanak tanır (Şekil 3.3).

Sonuç olarak, aktivasyon fonksiyonları derin öğrenme modellerinin doğrusal olmayan problemleri çözebilmesini sağlayarak, modelin öğrenme kapasitesini artırır. Bu sayede sinir ağları, karmaşık veri setlerinde anlamlı örüntüleri öğrenebilir ve yüksek performanslı sonuçlar elde edebilir.

**Tablo 3.1** Aktivasyon fonksiyonunun seçimi

| **Aktivasyon Fonksiyonu** | **Kullanım Alanı** |
|---|---|
| Sigmoid | İkili sınıflandırma problemlerinde kullanılır (örneğin, bir şeyin doğru mu yanlış mı olduğunu belirlemek). |
| Tanh | Gizli katmanlarda kullanılır; verileri -1 ile 1 arasında dengeler. |
| ReLU | Gizli katmanlarda en yaygın kullanılan fonksiyon; hesaplama hızlıdır. |
| Leaky ReLU | ReLU'nun geliştirilmiş versiyonu; negatif değerleri tamamen sıfıra indirmez ve 'ölü nöron' problemini azaltır. |
| Softmax | Çıkış katmanında çok sınıflı problemler için kullanılır; her sınıf için olasılık hesaplar. |




**Şekil 3.3** Aktivasyon fonksiyonlarının grafikleri

### 3.3.2 Evrişim Katmanı

Evrişim katmanı, derin öğrenme modellerinin özellikle görüntü işleme, nesne tanıma ve doğal dil işleme gibi alanlarda yaygın olarak kullanılan temel bileşenlerinden biridir. Evrişimsel Sinir Ağları (CNN) mimarisinin yapı taşı olan bu katman, girdiler üzerinde küçük boyutlu filtreler (kernels) kullanarak verinin anlamlı özelliklerini çıkarır ve modelin karmaşık yapıları öğrenmesini sağlar. Bu süreç, evrişim adı verilen matematiksel bir işlemle gerçekleştirilir.

Evrişim işlemi sırasında, öğrenilebilir parametrelerden oluşan filtreler giriş verisi üzerinde kaydırılarak (sliding) hareket eder. Bu filtreler, verinin küçük parçalarıyla çarpılıp toplanarak bir özellik haritası (feature map) oluşturur. Bu işlem sayesinde model, girdideki kenarlar, dokular, renkler gibi düşük seviyeli özellikleri öğrenir. Daha derin katmanlarda ise bu basit özellikler bir araya getirilerek daha karmaşık yapılar örneğin, nesneler veya yüzler tanımlanır.

Evrişim katmanının en önemli avantajlarından biri parametre paylaşımı ilkesidir. Aynı filtre, giriş verisinin tamamı üzerinde kullanıldığı için öğrenilecek parametre sayısı büyük ölçüde azalır. Bu durum, modelin hem verimli çalışmasını hem de aşırı öğrenme (overfitting) riskini azaltmasını sağlar. Ayrıca, evrişim işlemi verinin uzamsal (spatial) bilgisini korur; yani görüntülerdeki piksel komşuluk ilişkileri analiz edilerek anlamlı örüntüler ortaya çıkarılır.

Evrişim katmanında bazı önemli parametreler bulunur. Bunlar; filtre boyutu, adım (stride) ve dolgu (padding) olarak sıralanabilir. Filtre boyutu, genellikle 3x3 veya 5x5 gibi küçük matrislerden oluşur ve analiz edilecek bölgenin boyutunu belirler. Adım değeri, filtrenin giriş verisi üzerinde ne kadar piksel ilerleyeceğini gösterir. Daha büyük adım değerleri çıktı boyutunu küçültürken, küçük adımlar daha ayrıntılı bir analiz sağlar. Dolgu ise, filtrenin giriş verisinin kenarlarında da çalışabilmesi için girişe eklenen sıfırlardır. Özellikle aynı dolgu (same padding) kullanıldığında çıktı boyutu girişle aynı kalırken, geçerli dolgu (valid padding) kullanıldığında çıktı boyutu küçülür.

Evrişim katmanları, düşük seviyeli özelliklerden başlayarak yüksek seviyeli temsil öğrenimi sağlar. Örneğin, ilk katmanlarda kenarlar ve basit geometrik desenler öğrenilirken, sonraki katmanlarda bu desenler birleşerek nesne ve yapı gibi karmaşık ilişkiler ortaya çıkarılır. Özellikle ReLU gibi aktivasyon fonksiyonları ile birlikte kullanıldığında, evrişim katmanlarının doğrusal olmayan dönüşümler gerçekleştirmesi sağlanır. Bu dönüşümler, modelin doğrusal olmayan veri yapılarında daha başarılı olmasına yardımcı olur.

Evrişim katmanları günümüzde pek çok alanda kullanılmaktadır. Görüntü sınıflandırma, nesne tespiti ve segmentasyon gibi uygulamalar başlıca kullanım alanlarıdır. Örneğin, bir görüntüde yer alan nesnelerin tespit edilmesi veya tıbbi görüntülerde anomali belirlenmesi gibi problemler evrişim katmanları sayesinde yüksek doğrulukla çözülebilmektedir. Ayrıca, doğal dil işleme alanında metin verisi üzerinde bir boyutlu (1D) evrişimler uygulanarak kelime ve cümle seviyesinde anlamlı desenler öğrenilmektedir.

Evrişim katmanları derin öğrenme modellerinin veri üzerinde anlamlı özellikler öğrenmesini sağlayarak, modelin karmaşık problemlerde yüksek performans

göstermesine olanak tanır. Özellikle görüntü ve mekânsal verilerdeki başarılı uygulamaları, bu katmanların modern yapay zekâ çözümlerinin vazgeçilmez bir parçası olmasını sağlamıştır.

### 3.3.3 Hiperparametreler

**Çapraz Entropi Kaybı**

Özellikle sınıflandırma problemlerinde yaygın olarak kullanılan bir kayıp fonksiyonudur. İki olasılık dağılımı arasındaki farkı ölçer (genellikle gerçek etiketlerin ve model tahminlerinin olasılık dağılımları). Bu kayıp fonksiyonu, modelin sınıflandırma doğruluğunu maksimize etmek için özellikle faydalıdır, çünkü yanlış tahminler üzerinde daha yüksek ceza uygular. Bu durum, modelin doğru sınıfları tahmin etme olasılığını artırır ve sınıflandırma görevlerinde sıkça tercih edilir.

**Öğrenme Hızı**

Öğrenme hızı, genellikle α ile gösterilir ve stokastik gradyan iniş algoritmasının en önemli parametrelerinden biridir. Bu değer, her gradyan adımında model parametrelerinin ne kadar güncelleneceğini belirler. Çok düşük bir öğrenme hızı, algoritmanın çok yavaş öğrenmesine, çok yüksek bir öğrenme hızı ise algoritmanın optimum çözümü aşırı sıçrayarak bulamamasına neden olabilir.

**Öğrenme Hızı Azalımı**

Öğrenme hızının zamanla azaltılması işlemidir. Bu, algoritmanın başlangıçta büyük adımlar atmasına ve zamanla adımlarını küçülterek minimum bir değere daha hassas bir şekilde yaklaşmasına olanak tanır. Bu parametrenin kullanımı, algoritmanın hızlı başlayıp yavaşlamasını ve böylece optimuma stabil bir şekilde yaklaşmasını sağlar. Momentum (β) ise modelin ağırlıklarını güncellerken önceki adımlardaki güncellemelerin bir kısmını dikkate alan bir iyileştirme yöntemidir. Bu yöntem, modelin mevcut gradyanlara dayanarak değil, aynı zamanda önceki gradyanların birikimini de kullanarak ağırlıklarını güncellemesini sağlar. (URL2)

**Yığın Boyutu**

Yığın boyutunun belirlenmesi, modelin performansı ve eğitim süresi açısından kritik öneme sahiptir. Küçük bir yığın boyutu, modelin parametrelerinin daha sık

güncellenmesine neden olur ve bu da daha hızlı öğrenme sağlayabilir; ancak bu durum, hesaplama yükünü artırabilir. Öte yandan, büyük bir yığın boyutu, daha az güncellemeyle eğitim sürecini hızlandırabilir; ancak modelin öğrenme süreci yavaşlayabilir.

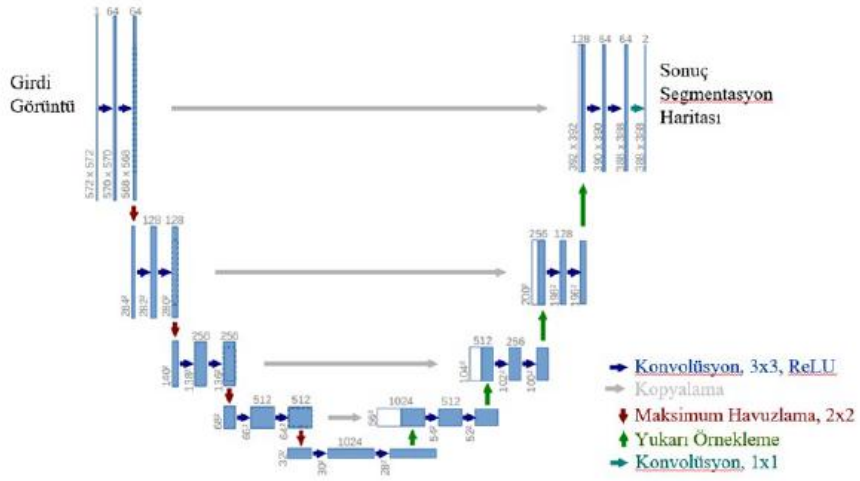
**Epok Sayısı**

Epok sayısı, bir eğitim veri setinin model tarafından kaç kez işlendiğini gösterir. Her epokta modelin ağırlıkları tekrar hesaplanarak güncellenir. Bu süreç, modelin performansını optimize etmek için önemli bir adımdır.

### 3.3.4 Derin Öğrenme Ağları

**UNet++**

UNet mimarisi, tıbbi görüntü segmentasyonu gibi biyomedikal görüntü analizinde yaygın olarak kullanılan derin öğrenme modellerinden biridir (Ronneberger vd., 2015). UNet, semantik segmentasyon problemlerine yönelik olarak tasarlanmıştır ve U şeklinde bir yapıya sahiptir. Gelneksel UNet mimarisi tam olarak bağlantılı bir ağ olup, katmanlı bir yapı izler ve özellik çıkarımını destekleyen bir encoder-decoder (kodlayıcı-çözücü) yapısını temel alır. Kodlayıcı kısmı, girdi görüntüsünü giderek daha küçük ve daha yüksek düzeyde özelliklere ayırırken, çözücü kısmı bu özellikleri kullanarak orijinal görüntü boyutunda bir çıktı üretir. Kodlayıcı ve çözücü arasında, aynı seviyede olan katmanlar arasında atlamalı bağlantılar vardır; bu sayede orijinal çözünürlükteki bilgilerin bir kısmı korunur (Şekil 3.4).




**Şekil 3.4** UNet Derin Öğrenme Mimarisi (Srivastava, 2014)

UNet++ mimarisi, UNet'in temel yapısını geliştirmektedir. UNet++'ta, atlamalı bağlantılar doğrudan değil, bir dizi yoğun katmandan geçirilerek yapılır. Bu sayede, ara katmanlarda daha fazla bilgi işlenir ve daha zengin özellikler çıkarılır. Bu bağlantılar, özellik haritalarının daha düzgün bir şekilde aktarılmasını sağlar ve segmentasyon doğruluğunu artırır. Bu yapının amacı, görüntü özelliklerini daha iyi yakalamak ve detay kaybını en aza indirgemektir. Her bir atlamalı bağlantı, birden fazla aşamalı yoğun katmandan geçer ve bu şekilde bilgi daha etkili bir şekilde taşınır.

**Attention UNet**

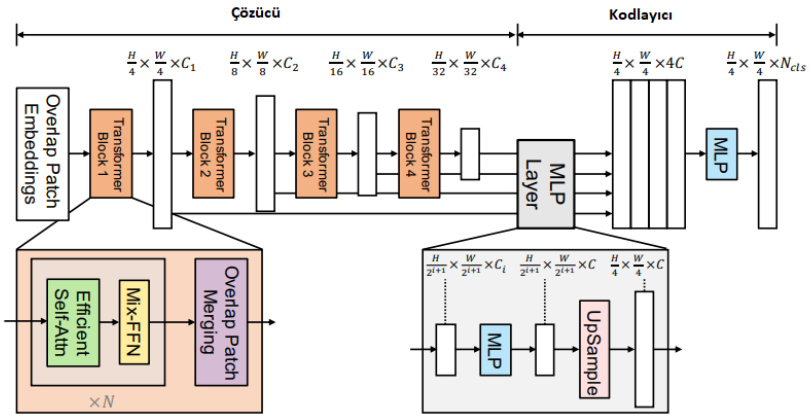
Attention UNet, tıbbi görüntü segmentasyonunda UNet'in başarısını artırmak için dikkat (attention) mekanizmasını entegre eden bir modeldir. Bu mimari, UNet'in güçlü özelliklerini kullanırken, özellikle önemli özellikleri seçici olarak vurgulayan bir attention (dikkat) modülü ekleyerek daha hassas segmentasyon sonuçları sunar. İlk olarak 2018 yılında Oktay vd. tarafından tanıtılmıştır ve özellikle tıbbi verilerdeki küçük veya belirsiz nesneleri algılama yeteneği ile öne çıkar.

Bu mekanizmalar, modelin belirli bölgelerdeki özelliklere daha fazla odaklanmasını sağlayarak, özellikle karmaşık ve zor segmentasyon görevlerinde performansı artırmayı hedefler. Dikkat modülleri, hangi özelliklerin kritik olduğunu belirlemek için kodlayıcı ve çözücü arasındaki atlama bağlantılarına eklenmiştir. Özellikle küçük veya düşük kontrastlı nesneleri vurgulamak açısından yararlıdır (Oktay vd., 2018).

**SegFormer-MixVTB3**

Yama birleştirme ve hiyerarşik dönüştürücülere sahip SegFormer-MixVTB3, çok seviyeli özellikleri çıkararak çeşitli çözünürlüklere uyarlanabilir hale getirir (Şekil 3.5). SegFormer-MixVTB3, iki önemli bileşene dayanan verimli bir segmentasyon çerçevesi sunar: Bunlar, birden fazla çözünürlükte öznitelikler üretmek için hiyerarşik bir dönüştürücü kodlayıcı ve nihai segmentasyon sonucuna ulaşmak için bu çeşitli öznitelikleri entegre eden modern bir Tüm-ÇKA (Çok Katmanlı Algılayıcı) kod çözücüdür. Başlangıçta görüntü tahmin görevinin hassasiyetini arttırmak için daha küçük 4 × 4 yamalara bölünür. Bu yamalar daha sonra çeşitli çözünürlüklerde öznitelikler elde etmek için dönüştürücü kodlayıcı tarafından

işlenir. Daha sonra Tüm-ÇKA kod çözücü, segmentasyon maskesini küçültülmüş bir çözünürlükte tahmin etmek için bu özelliklerden yararlanır (Xie vd., 2021). Geliştirilmiş özellik temsili ve hesaplama verimliliği yama birleştirme ve kendi kendine dikkat stratejileri ile elde edilir. Karma-İBA (İleri Beslemeli Ağ) modülü, İBA içine 3 × 3 evrişim ekleyerek ve geleneksel konumsal kodlamayı atlayarak segmentasyon doğruluğunu artırır. ÇKA tabanlı bir kod çözücü kullanarak etkinliği korurken mimariyi basitleştirmek için kodlayıcının geniş alıcı alanından yararlanır. Bu tasarım, kodlayıcıdan gelen çok seviyeli çıktıların sorunsuz bir şekilde birleştirilmesini ve iyileştirilmesini sağlar, Böylece segmentasyon parametrelerinin tahmin edilmesi sürecini kolaylaştırır (Xie vd., 2021).

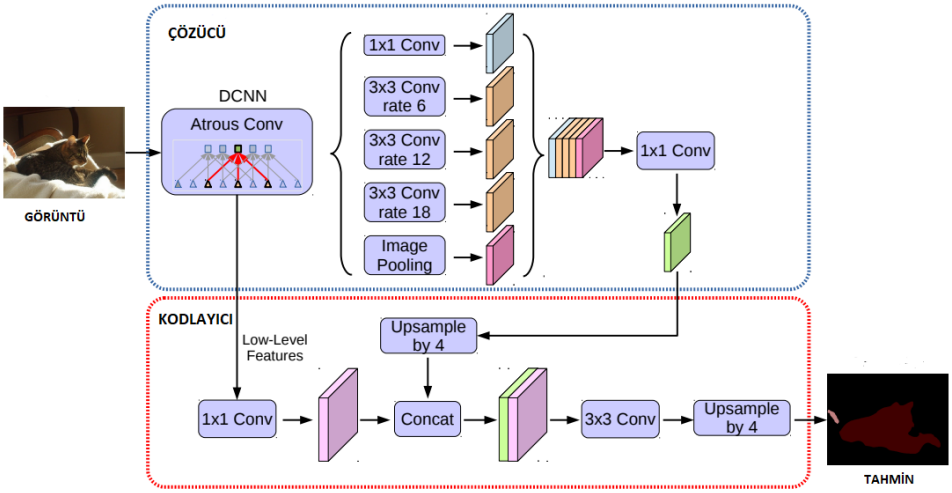



**Şekil 3.5** SegFormer-MixVTB3 Derin Öğrenme Mimarisi (Xie vd., 2021)

**DeepLabV3+**

DeepLabv3+ derin öğrenme algoritması, semantik segmentasyon görevleri için etkili bir modeldir ve özellikle arazi kullanım analizi gibi yüksek çözünürlüklü görüntü işleme problemlerinde kullanılmaktadır. Model, geniş alanlardan bilgi toplamak için boşluklu (atrous) evrişimi kullanarak görüntü çözünürlüğünü düşürmeden geniş bağlam bilgisini işler (Şekil 3.6). Bunun yanı sıra, kodlayıcı-çözücü mimarisi sayesinde düşük çözünürlükte çıkarılan özellik haritaları yüksek çözünürlüğe dönüştürülerek ayrıntılı segmentasyon maskeleri üretilir. DeepLabv3+'ın Boşluklu Mekânsal Piramit Havuzu (Atrous Spatial Pyramid Pooling, ASPP) modülü, farklı ölçeklerdeki özellikleri yakalayarak modelin hem

büyük hem de küçük nesneleri ayırt etmesini sağlar (Chen vd., 2018). Bu özellikler, modelin arazi kullanımı analizleri gibi çeşitli uzaktan algılama görevlerinde yüksek doğrulukta sonuçlar vermesini sağlamaktadır.




**Şekil 3.6** DeepLabV3+ Derin Öğrenme Mimarisi (Chen vd., 2018)

### 3.3.5 Değerlendirme Metrikleri

İdeal olarak bir makine öğrenmesi çözümünün eğitim verilerinden öğrendiği kural setini daha önce karşılaşmadığı verilerde başarı ile uygulayabilmesi hedeflenmektedir. Bu amaçla geliştirilen modellerin karşılaştırılabilmesi ve elde edilen sonuçların ölçülebilmesi için çeşitli ölçütler kullanılmaktadır. Özellikle segmentasyon ve nesne yakalama görevleri girdi veri noktası bazında doğru sınıflandırmanın ötesinde nesne geometrilerinin aslına uyan sonuçlar üretilmesini gerektirdiğinden bu amaca uygun değerlendirme ölçütlerine ihtiyaç duyulmaktadır. Modeller, özellikle veri setinde tematik sınıflara ait örnekleri doğru etiket ile eşleştirmede hem sınıf içi hem de sınıflar arası varyasyonlara daha çok maruz kaldıkları için başarılı olmaktadırlar. Veri setinde ağırlıkla bulunan tematik sınıflar lehine sonuçlar üreterek ortalama doğruluğu artıran fakat sınıf bazında ortalama doğruluğu düşüren öğrenme süreçleri ortaya çıkabilmektedir. Bu sebeple sınıf bazında doğrulukların irdelenmesi objektif ve bütüncül bir değerlendirme için önemli olmaktadır.

Eşitlik 3.1'de verilen genel doğruluk, (overall accuracy, OA) tüm makine öğrenmesi çalışmalarında kullanılabilecek en temel değerlendirme ölçütü olarak görülmektedir. Herhangi bir girdi veri setinde yürütülecek bir test için OA değeri

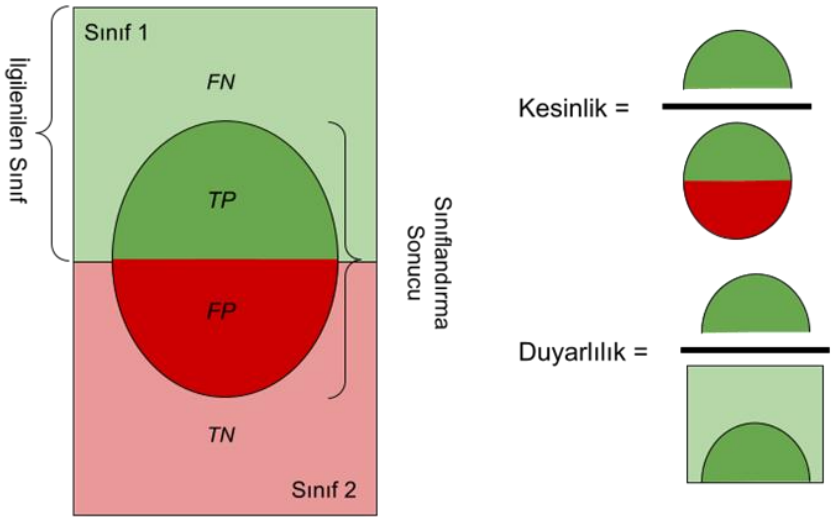
doğru sonuçlandırılan test sonuçlarının tüm test sonuçlarına oranı şeklinde hesaplanabilir. Sınıf bazında ortalama doğruluk (mean class accuracy, mAcc) bir diğer temel değerlendirme ölçütüdür. Yürütülen bir test için mAcc değeri, girdi veri setinde sınıf bazında hesaplanan doğruluk oranlarının sınıf sayısına göre ortalaması ile bulunur. Modellerin farklı sınıftan test örneklerine karşı başarısı farklı olabildiğinden bütünsel bir değerlendirme için sıklıkla tercih edilen bir metriktir (Guo vd., 2021).

$$\text{Genel Doğruluk} = \frac{\text{Doğru Sınıflandırılan Sonuçların Sayısı}}{\text{Örneklem Boyutu}} \tag{3.1}$$

Eşitlik 3.2'de verilen kesinlik; bir sınıfa atanan örnekler arasında doğru olanların sayısının, bu sınıfa atanan tüm örneklere oranı olarak ifade edilebilir. Duyarlılık ise belirli bir sınıfın örnek uzayda fark edilebilirliğinin bir ölçütü olarak; doğru sınıflandırılan örnek sayısının bu sınıfa ait tüm tahminlere oranı şeklinde hesaplanabilir (Ghorbanzadeh vd., 2019).

$$Kesinlik = \frac{TP}{TP + FP} \tag{3.2}$$

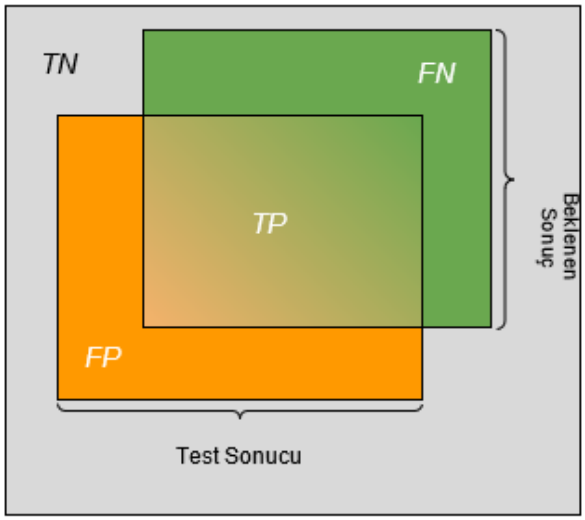
$$Duyarlılık = \frac{TP}{TP + FN} \tag{3.3}$$




**Şekil 3.7** Kesinlik ve duyarlılık kavramlarını ifade etmek için hazırlanmış görsel. TP: doğru pozitif sınıflandırma durumu, FP: yanlış sınıflandırma durumu, FN: yanlışlıkla sınıf dışında bırakma durumu, TN: doğru biçimde sınıf dışında bırakma durumunu ifade etmektedir. (Guo vd., 2021)

Jaccard Skoru yaygın biçimde kullanılan bir metrik olarak ön plana çıkmaktadır (Guo vd., 2021). Eşitlik 3.4'de verilen IoU değerinin hesaplanması, test sonuçları ve beklenen değerler tarafından oluşturulan kümeler üzerinde tanımlı bir küme problemi olarak ifade edilebilir.

$$IoU = \frac{TP}{TP + FP + FN} \tag{3.4}$$




**Şekil 3.8** Kesişim-Birleşim oranı (IoU) değerini ifade etmek için hazırlanmış görsel (Guo vd., 2021)

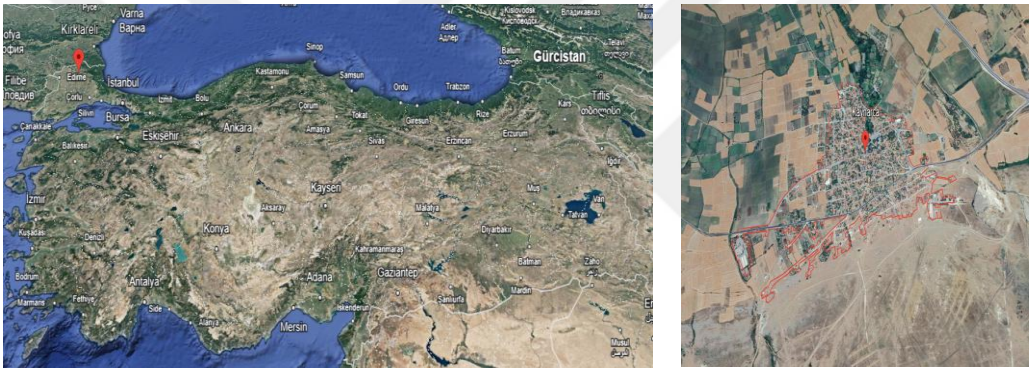
Kesinlik ve duyarlılık değerleri oranlar ile ifade edildiklerinden F1-skoru kesinlik ve duyarlılık değerlerinin, oranların ortalamasını elde etmek için kullanılan harmonik ortalaması şeklinde hesaplanmaktadır (Eşitlik 3.5). Hesaplama yöntemi olarak harmonik ortalama fonksiyonu kullanması neticesinde kesinlik ya da duyarlılık değerlerinden birinin diğerine göre çok düşük olması durumunda F1-skorunun düşük olana yakın biçimde ortaya çıkacağı görülmüştür. F1-skoru kesinlik ve duyarlılık metriklerinin birbirlerine göre dengeli olup olmadığını da gösterebilen bir metrik olarak ön plana çıkmıştır.

$$F1\ skoru = 2x\frac{KesinlikxDuyarlılık}{Kesinlik+Duyarlılık} \quad (3.5)$$

# 4
# UYGULAMA

## 4.1 Veri Seti

Bu çalışmada, Kırklareli Kaynarca Belediyesi'nin talep ve yetkisi doğrultusunda İller Bankası Anonim Şirketi kontrolörlüğünde üretilmiş olan ortofotolar veri kaynağı olarak kullanılmıştır. Şekil 4.1 ve Şekil 4.2'de çalışma alanı gösterilmiştir.




**Şekil 4.1** Çalışma alanının Türkiye'deki konumu (solda) ve Kırklareli'ndeki konumu (sağda) (URL1)

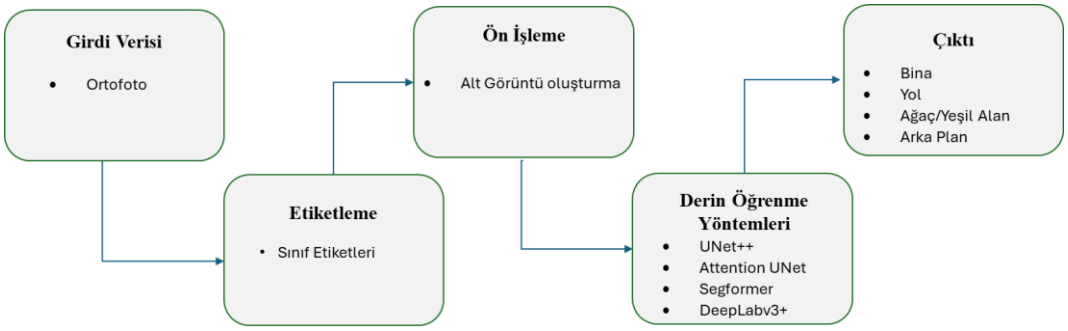
DJI Matrice 300 İHA ile Kaynarca beldesinde gerçekleştirilen uçuşlar, Pix4D yazılımıyla değerlendirilerek 5,45 cm yer örnekleme aralığı (YÖA) ile yatay (XY) ve düşey (Z) eksenleri için sırasıyla 7 ve 9 mm karesel ortalama hata (RMSE) ile elde edilen ortofoto veri seti kullanılmıştır.



**Şekil 4 2** Çalışma alanının 1/25000 ölçekli ortofotosu

## 4.2 Yöntem

Bu çalışmada, veri seti olarak 1/1000 ölçekli ortofotolar kullanılmıştır. İlk olarak, ön işleme adımı ile veriler modellerin işleyebileceği uygun bir formata dönüştürülmüştür. Ön işleme yapılmış görüntüler etiketlenmiş ve UNet++, Attention UNet, Segformer_MixVTB3 ve DeepLabv3+ gibi derin öğrenme yöntemleri uygulanarak ortofoto verileri üzerinde sınıf bazlı segmentasyon yapılmıştır. Bu süreç sonucunda bina, yol, yeşil alan ve arka plan sınıflarına ait bölgeler belirlenerek çıktılar oluşturulmuştur. Şekil 4.3'te iş akış diyagramı gösterilmiştir.




**Şekil 4.3** İş akışını anlatan diyagram

### 4.2.1 Ön İşleme

Veriler bina, yol, bitki örtüsü (ağaç/yeşil alan) ve arka plan olmak üzere 4 sınıfa ayrılarak Anylabeling yazılımında etiketlenmiştir (Şekil 4.4). Etiketleme işlemini takiben, derin öğrenme ağlarının eğitimi ve testi için görüntüler sol üst köşelerinden itibaren 512x512 piksellik alt görüntülere ayrılmıştır ve toplam 1247 alt görüntü üretilmiştir. Bu görüntülerin %60'ı eğitim (747), %20'si doğrulama (250) ve %20'si test (250) verisi olarak kullanılmıştır. Görüntülere maksimum-minimum normalizasyonu uygulanmış olup eğitim setindeki görüntülere 45, 135, 225 ve 315 derecelik döndürme, 0,5 ve 0,2 ölçekleme ve kontrast germe işlemleri uygulanmıştır.




**Şekil 4.4** Etiketleme İşleminin yapıldığı programın ekran görüntüsü

### 4.2.2 Eğitim

Seçilen modellerin eğitilmesi için PyTorch, doğruluk analizi işlemleri için ise scikit-learn kütüphanesi kullanılmıştır. Eğitimler Nvidia RTX 4090 ekran kartlı bir bilgisayarda yapılmış olup her bir yöntem için minimum parça sayısı (batch size) iki, Adam optimizasyon algoritması, Kategorik Çapraz Entropi kayıp fonksiyonu ve 0,0001 öğrenme hızı oranı seçilmiştir. Ağların eğitimi için ImageNet veri setinde eğitilmiş modeller ile aktarımlı öğrenme (transfer learning) yapılmıştır.

## 4.3 Bulgular

Derin öğrenme yöntemlerinin performansı, kullanılan model karşılaştırma metrikleriyle kapsamlı bir şekilde değerlendirilmiştir. Bu bağlamda, dört farklı modelin başarısını ölçmek amacıyla IoU (Intersection over Union) ve F1 skoru temel kriterler olarak incelenmiştir (Tablo 4.1).

**Tablo 4.1** Model değerlendirme metriklerinin karşılaştırılması

| | **UNet++** | | **AttentionUNet** | | **DeepLabv3+** | | **SegFormer-MixVTB3** | |
|---|---|---|---|---|---|---|---|---|
| **Sınıf** | **IoU** | **F1-skor** | **IoU** | **F1-skor** | **IoU** | **F1-skor** | **IoU** | **F1-skor** |
| **Arka Plan** | 0,8670 | 0,9287 | 0,8737 | 0,9326 | 0,8863 | 0,9397 | 0,8860 | 0,9396 |
| **Bina** | 0,8457 | 0,9164 | 0,8521 | 0,9201 | 0,8747 | 0,9332 | 0,8805 | 0,9364 |
| **Yol** | 0,6965 | 0,8211 | 0,7103 | 0,8306 | 0,7685 | 0,8691 | 0,7795 | 0,8761 |
| **Ağaç** | 0,6616 | 0,7963 | 0,6725 | 0,8042 | 0,7031 | 0,8257 | 0,6834 | 0,8120 |
| **Ort** | 0,7677 | 0,8656 | 0,7772 | 0,8719 | 0,8082 | 0,8919 | 0,8074 | 0,8910 |

Elde edilen bulgulara göre, DeepLabv3+ ve SegFormer-MixVTB3 modellerinin genel performans açısından diğer modellere kıyasla daha iyi olduğunu ortaya koymaktadır. Ortalama IoU ve F1-skorları açısından DeepLabv3+ modeli sırasıyla 0,8082 ve 0,8919; SegFormer-MixVTB3 modeli ise 0,8074 ve 0,8910 değerlerine ulaşmıştır.

Her iki modelin özellikle geniş ölçekli veri setleri ve karmaşık desenlerin sınıflandırılmasında başarılı olduğu belirlenmiştir. DeepLabv3+, geniş bağlamsal bilgi yakalama yeteneği sayesinde arka plan (IoU: 0,8863; F1: 0,9397) ve ağaç/yeşil alan (IoU: 0,7031, F1: 0,8257) sınıflarında en iyi performansı göstermiştir. Öte yandan, SegFormer-MixVTB3, bina (IoU: 0,8805; F1: 0,9364) ve yol (IoU: 0,7795; F1: 0,8761) sınıflarında en yüksek başarıyı elde etmiştir. Özellikle transformer tabanlı yapısı ve çok seviyeli özellik birleştirme mekanizması, karmaşık sınıflar üzerinde etkili sonuçlar sunmasını sağlamıştır.

Attention UNet ve UNet++ modelleri, genel performans açısından diğer modellere göre daha düşük sonuçlar vermiştir. Attention UNet, dikkat mekanizmaları içermesine rağmen incelenen ortofotolar üzerinde belirgin bir üstünlük sağlayamamıştır. UNet++ modeli ise, yüksek çözünürlüklü ve karmaşık sınıf yapısına sahip görüntülerle başa çıkmakta zorluk yaşamıştır. Ancak bu modellerin,

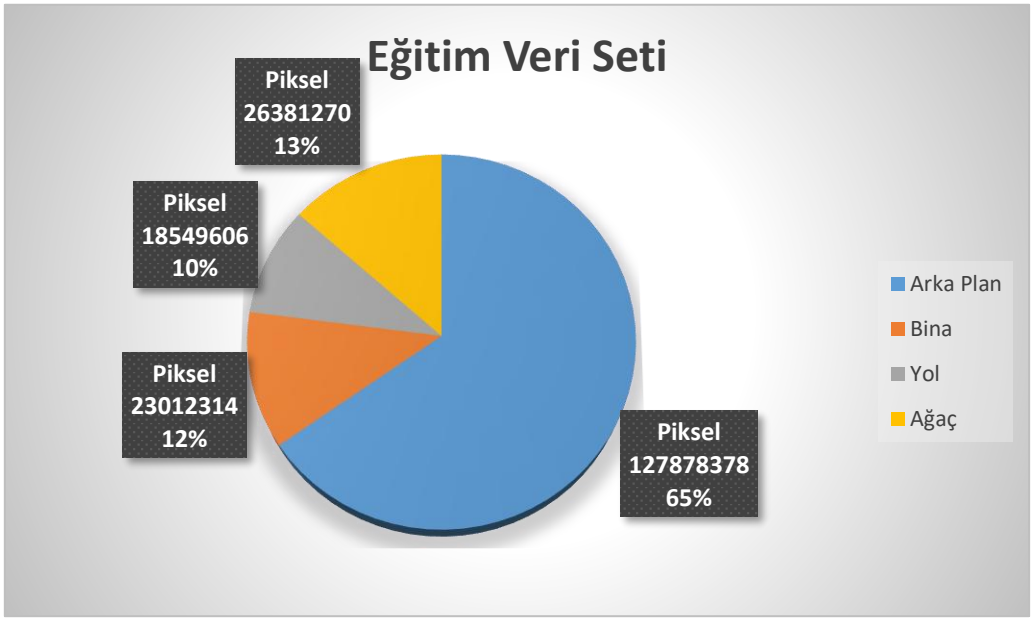
özellikle tıbbi görüntü analizi gibi farklı uygulama alanlarında daha etkili olabileceği unutulmamalıdır.

Değerlendirme sırasında, ağaç/yeşil alan sınıfı tüm modellerde en düşük performansı sergilemiştir. Bunun nedeni, bu sınıfın homojen olmayan yapısı ve belirgin sınırlarının bulunmamasıdır. Bu durum, derin öğrenme algoritmalarının bu tür sınıfları sınıflandırmada zorlandığını göstermektedir. Düşük IoU ve F1-skorları, bu sınıfın karmaşık yapısı ve çeşitlilik içermesi nedeniyle ortaya çıkmıştır.

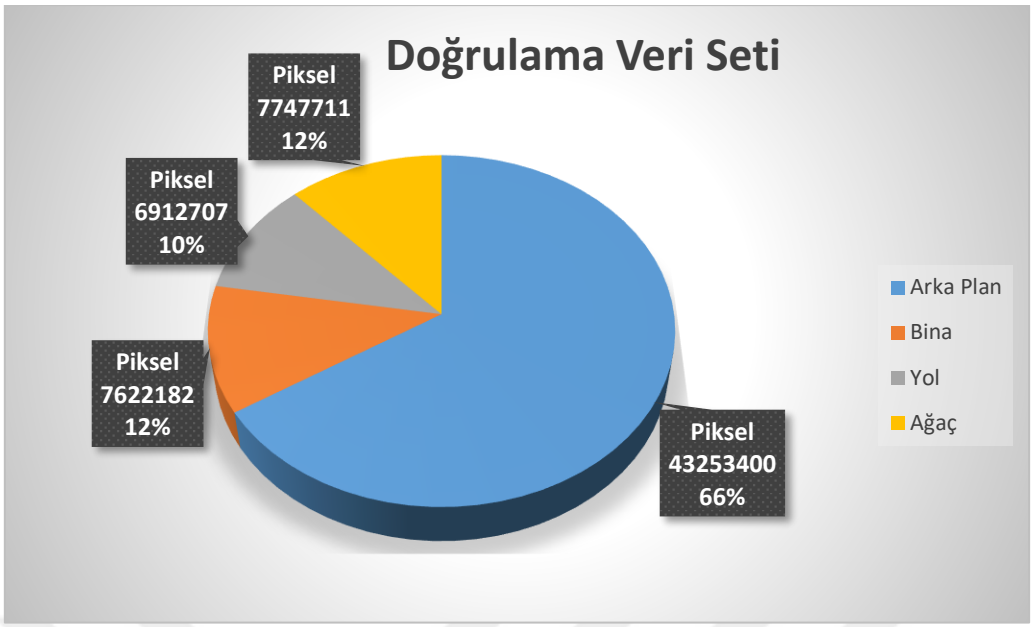
Tablo 4.2, Şekil 4.5, Şekil 4.6 ve Şekil 4.7'de görüldüğü gibi, eğitim, doğrulama ve test setinde bina, yol ve ağaç sınıflarının kendi arasında dengeli dağılması nedeniyle arka plan sınıfının daha fazla var olmasına rağmen derin öğrenme ağlarının performansını etkilememektedir.

**Tablo 4.2** Veri setindeki sınıf dağılımları

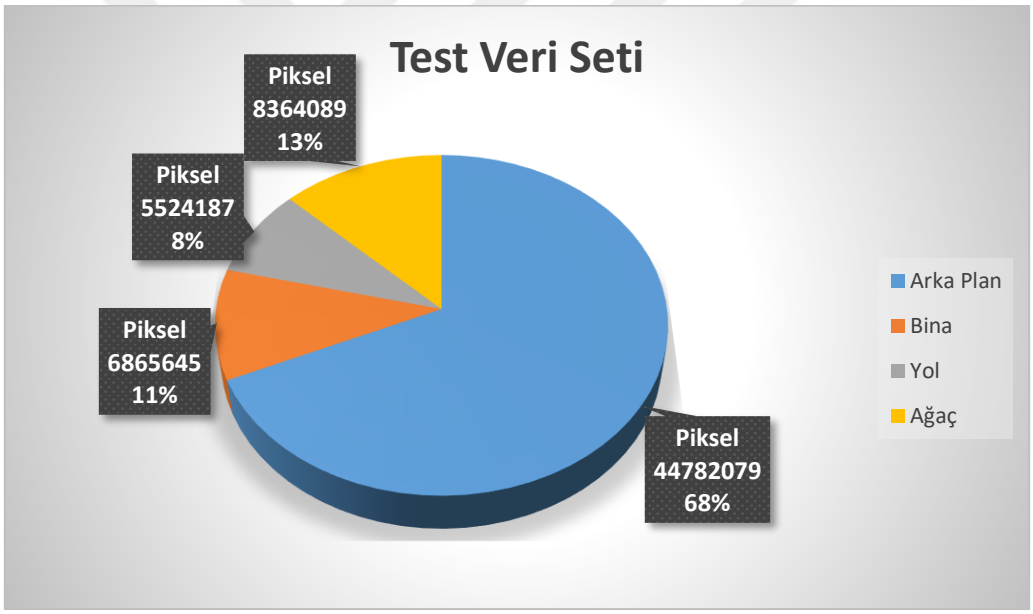
| | Eğitim | | Doğrulama | | Test | |
|---|---|---|---|---|---|---|
| | Piksel | Yüzde (%) | Piksel | Yüzde (%) | Piksel | Yüzde (%) |
| Arka Plan | 127878378 | 65,30% | 43253400 | 66,00% | 44782079 | 68,33% |
| Bina | 23012314 | 11,75% | 7622182 | 11,63% | 6865645 | 10,48% |
| Yol | 18549606 | 9,47% | 6912707 | 10,55% | 5524187 | 8,43% |
| Ağaç | 26381270 | 13,47% | 7747711 | 11,82% | 8364089 | 12,76% |




**Şekil 4.5** Kaynarca eğitim veri setindeki sınıflara ait piksel sayısı ve yüzdesi




**Şekil 4.6** Kaynarca doğrulama veri setindeki sınıflara ait piksel sayısı ve yüzdesi




**Şekil 4.7** Kaynarca test veri setindeki sınıflara ait piksel sayısı ve yüzdesi

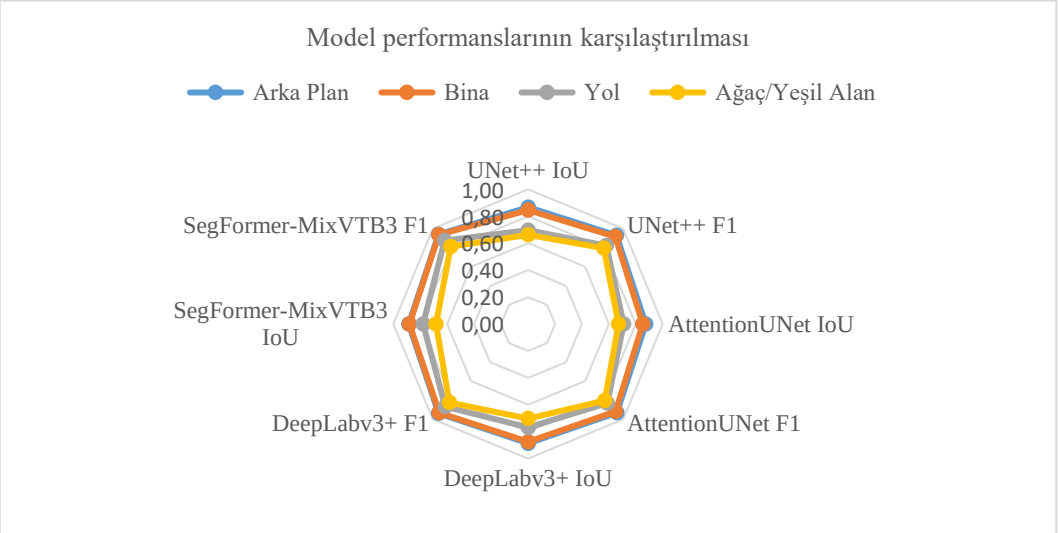
### 4.3.1 Modeller Arası Karşılaştırma

Derin öğrenme yöntemleri ile elde edilen sınıflandırma doğruluk metriklerinin karşılaştırılması Şekil 4.8'de verilmiştir. DeepLabv3+ ve SegFormer-MixVTB3 modelleri, genellikle geniş veri setlerinde ve karmaşık desenlerde yüksek doğruluk sunan sınıflandırma algoritmaları olarak öne çıkmaktadır. DeepLabv3+, görüntülerdeki detayları etkin bir şekilde çıkarabilen çok katmanlı yapısı sayesinde ve SegFormer_MixVTB3, dönüştürücü tabanlı yapısı ve yama birleştirme

mekanizması ile üstün performans sergilemiştir. Dönüştürücü mimarisinin, farklı çözünürlüklerdeki görüntülerde çalışma performansı, SegFormer-MixVTB3'ün başarılı segmentasyon yapabilmesinin temel nedenidir.

Attention UNet modeli, çalışmada incelenen ortofotoların sınıflandırılmasında, dikkat mekanizmalarının potansiyelini gösterememiştir. UNet++ modeli ise bu çalışmada kullanılan ortofotoların yüksek çözünürlüğü ve karmaşık sınıf yapısı gibi zorluklarıyla başa çıkmakta diğer modellere göre daha zayıf performans göstermiştir. Bu çalışma, derin öğrenme tabanlı dört farklı modelin ortofotoların sınıflandırılması görevlerinde nasıl performans gösterdiğini karşılaştırmalı olarak ortaya koymaktadır.

DeepLabv3+ ve SegFormer-MixVTB3, yüksek doğruluk oranları ve çeşitli sınıflarda sağladıkları üstün performans ile ön plana çıkmıştır. Bu iki model, geniş ölçekli veri setleri ve karmaşık arazi sınıflandırma görevlerinde tercih edilebilir. Attention UNet ve UNet++, diğer modellere göre daha düşük performans göstermiştir; ancak bu modellerin tıbbi görüntü analizi gibi diğer alanlarda daha etkili olabileceği göz önünde bulundurulmalıdır.




**Şekil 4.8** Derin öğrenme yöntemleri ile elde edilen sınıflandırma doğruluk metriklerinin karşılaştırılması

### 4.3.2 Sınıflandırılmış Görüntülerin Karşılaştırılması

Şekil 4.9 bir numaralı görüntüde, etiket verisi ile kıyaslandığında Unet++ ağının yeşil alan tanımada geri kaldığı, SegFormer-MixVTB3 ağının ise yeşil alanda en iyi performansı sergilediği görülmektedir.

İki numaralı görüntüde, DeepLab ağında ağaç sınıfına ağaç gölgesinin karıştığı gözlemlenmektedir. Bina köşelerinde keskin yakalama sağlayan ve en az gürültülü sonuç veren ağın DeepLab olduğu gözlemlenmiştir. UNet++ ağının hem yeşil alan hem de bina sınıfında gürültü oluşturduğu görülmektedir.

Üç numaralı görüntüde, UNet++, Deeplab ve Attention UNet ağlarında bina gölgesi bina sınıfında etiketlenerek hatalı sınıflandırma yapıldığı görülmektedir. Ayrıca UNet++ ve Attention UNet ağlarının arabanın zeminden yüksekliği ve renk bilgisi sebebi ile bina olarak sınıflandırdığı görülmektedir.

Dört numaralı görüntüde, UNet++ ağı yol sınıfında diğer ağlara göre daha fazla gürültü oluşturmuş ve ağaçların gölgeleri diğer sınıfında etiketlenerek yanlış sınıflandırılmıştır. Tüm ağların bina köşelerinde gürültü oluşturduğu gözlemlenmiştir.

Beş numaralı görüntüde, UNet++ ve Attention UNet, bina çatısına olan renk benzerliği ve zeminden yüksekliği sebebi ile arabayı bina olarak sınıflandırmıştır. Bina köşelerinde bulunan gölgeler yol sınıfında sınıflandırılması gerekirken diğer olarak sınıflandırılmıştır. SegFormer-MixVTB3 ağının bina köşelerinde en keskin yakalamayı yaptığı gözlemlenmiştir.

Altı numaralı görüntüde, Attention UNet ve UNet++ ağlarının diğer ağlara göre daha fazla gürültü oluşturduğu ve yeşil alan sınıfında bina gölgerinin düştüğü alanları yol olarak sınıflandırması gerekirken diğer olarak sınıflandırdığı görülmüştür. Deeplab ve UNet++ ağlarının bina aralarında kalan alanları bina olarak sınıflandırarak hatalı sınıflandırma yaptığı gözlemlenmektedir.

Yedi numaralı görüntüde, tüm ağlarda yol sınıfının gölge ile karışarak doğru sınıflandırılamadığı ve yolların sınıflandırılmasında en iyi performansı SegFormer-MixVTB3 ağının gösterdiği görülmüştür. Tüm ağların performansı incelendiğinde bina köşelerindeki gölgelerin diğer olarak sınıflandırıldığı görülmektedir.

Sekiz numaralı görüntüde, tüm ağlarda gölgeler yol ve yeşil alan sınıflarında yanlış sınıflandırmalara sebep olmuştur. SegFormer-MixVTB3 ağının yol ve yeşil alan sınıfında diğer ağlara göre daha iyi performans gösterdiği gözlemlenmiştir.

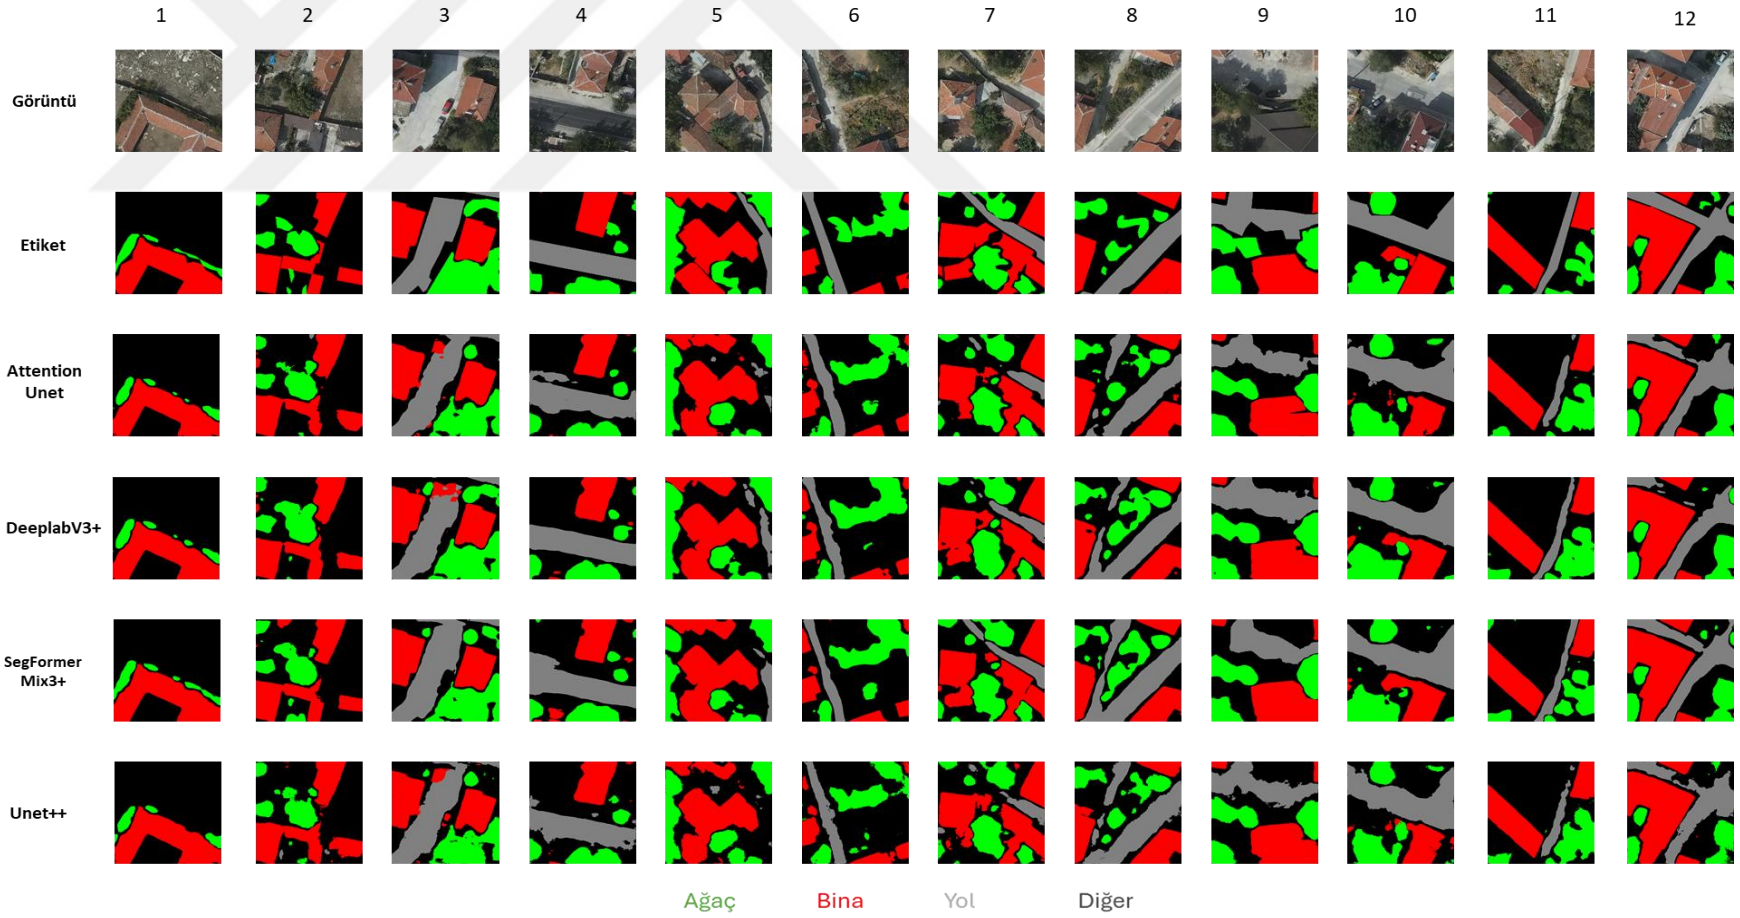
Dokuz numaralı görüntüde, Attention UNet, Deeplab ve UNet++ ağlarının özellikle yol sınıfında gürültü ürettiği gözlemlenmiştir. Attention UNet ve Unet++ ağlarının

ağaçların gölgelerini yeşil alan sınıfında sınıflandırması gerekirken diğer olarak sınıflandırdığı görülmüştür. Attention UNet ağının bina olarak sınıflandırılması gereken alanda gölge düşen alanları diğer olarak sınıflandırıdığı görülmektedir.

10 numaralı görüntüde, Deeplab ve SegFormer-MixVTB3 ağlarının herhangi bir yeşil alan olmayan bölgede rastgele gürültü şeklinde yeşil alan olarak sınıflandırma yaptığı görülmüştür. UNet++ ve Attention UNet, ağaçlarda dar boğaz yapmış ve yeşil alan olarak belirlenmesi gereken yerleri diğer sınıfında göstermiştir.

11 numaralı görüntüde, renk ve geometrinin belirgin olduğu çatılarda tüm ağların bina köşelerini yakalarken keskin sonuç verdiği görülmüştür. Yol ve bina sınıfının geçişlerinde yol olarak belirlenmesi gereken yerler diğer sınıfında gösterilmiştir.

12 numaralı görüntüde, Unet++ yol sınıfında oldukça fazla gürültü oluşturmuştur. Tüm ağlarda bina gölgesi yol sınıfında olması gerekirken diğer olarak gösterilmiştir. Bina sınıfında çatıların renk farkının belirgin şekilde ayırt edilebilmesi ve düzgün ve ayrık nizam yapılaşma olması tüm ağlarda bina sınıfında bina köşelerinin doğru sınıflandırılmasında etkili olduğu görülmektedir.




**Şekil 4.9** Sınıflandırılmış görüntülerin karşılaştırılması

## 4.4 Değerlendirme

Sınıflandırma sürecinde çeşitli zorluklarla karşılaşılmıştır. Bunların başında sınıflar arasındaki dengesizlik gelmektedir. Bina ve yol gibi sınıflar daha belirgin geometrik özelliklere sahipken, ağaç/yeşil alan gibi doğal sınıflar homojen olmayan bir yapıya sahiptir. Bu durum, modellerin belirgin sınıfları doğru bir şekilde sınıflandırmasını sağlarken, karmaşık yapıya sahip sınıflarda düşük performans göstermesine neden olmuştur. Özellikle ağaç/yeşil alan sınıfındaki düşük IoU ve F1-skorları bu durumun bir yansımasıdır.

Bir diğer zorluk, bazı sınıfların belirsiz sınırlarından kaynaklanmaktadır. Ağaç/yeşil alan gibi doğal sınıflarda, sınıflar arasındaki sınırların belirgin olmaması, modellerin öğrenme sürecini zorlaştırmıştır. Bu tür sınıfların detaylı bir şekilde ayrıştırılması, modelin özellik çıkarma kapasitesine bağlıdır ve bu sınıflarda düşük doğruluk değerleriyle sonuçlanmıştır.

Eğitim verilerinin çeşitlilik eksikliği de önemli bir zorluk olarak öne çıkmaktadır. Veri setinde bazı sınıfların yeterince temsil edilmemesi, özellikle nadir görülen veya karmaşık desenler içeren sınıfların sınıflandırılmasını zorlaştırmıştır. Örneğin, belirli türden bir bitki örtüsünün az sayıda örneği bulunması, modelin farklı türdeki bitki örtülerini ayırt etme yeteneğini sınırlandırmıştır.

Modellerin yapısal özellikleri de sınıflandırmada zorluklar yaratmıştır. Özellikle Attention UNet ve UNet++ modelleri, yüksek çözünürlüklü ve karmaşık sınıflara sahip veri setinde beklenen performansı gösterememiştir. Örneğin, Attention UNet, dikkat mekanizmalarına sahip olmasına rağmen, karmaşık sınıfların belirlenmesinde başarılı olamamıştır. Benzer şekilde, UNet++ modeli, veri setinin yüksek çözünürlüğü nedeniyle küçük detayları ayırt etmekte zorlanmıştır.

Doğal sınıfların yapısal özellikleri, yapay sınıflara kıyasla daha fazla zorluk yaratmıştır. Bina ve yol gibi yapay sınıflar, keskin sınırlarla kolayca tanımlanabilirken, ağaç/yeşil alan gibi doğal sınıflar öznel ve değişken özellikler taşımaktadır. Bu durum, doğal sınıfların genelleme hatalarına daha açık olmasına yol açmıştır.

Ağların eğitim süreleri, tercih edilen ağ mimarilerinin yapısal karmaşıklığı, parametre sayısı, kullanılan katman tipleri ve hesaplama maliyetleriyle doğrudan ilişkilidir.

DeepLabv3+, 2 saat 51 dakikalık eğitim süresine sahiptir. Görece optimize edilmiş ve yaygın olarak kullanılan, klasik CNN tabanlı bu mimari, en kısa eğitim süresine sahip olmuştur. Bu durum, söz konusu mimarinin hem parametre sayısı hem de derinlik açısından verimli bir yapıya sahip olmasından kaynaklanmaktadır.

Attention UNet 3 saat 44 dakikalık eğitim süresine sahiptir. Orijinal U-Net mimarisine eklenen dikkat mekanizmaları ile daha karmaşık bir yapı sunarak uzamsal ve kanal düzeyinde daha ince taneli özellik yakalama kapasitesine sahiptir. Bu eklenen karmaşıklık modelin doğruluk potansiyelini artırırken, hesaplama maliyetini yükseltmekte ve dolayısıyla eğitimin daha uzun sürmesine neden olmaktadır.

UNet++ 4 saat 55 dakika eğitim süresine sahiptir, orijinal U-Net'in daha modüler, yoğun bağlantılı ve çok katmanlı atlama yapıları ile genişletilmiş bir sürümüdür. Bu yaklaşımla segmentasyon doğruluğunun artırılması hedeflenirken, ek katmanlar ve bağlantılar aracılığıyla mimari karmaşıklık ve parametre sayısı yükselir. Bunun sonucu olarak, modelin eğitimi daha fazla zaman alır.

SegFormer-MixVTB3 7 saat 5 dakikalık eğitim süresi ile eğitimi en uzun süren ağ olmuştur. Transformer tabanlı bir mimari olması nedeniyle daha fazla parametre ve hesaplama kaynağı gerektirir. Özellikle uzamsal dikkat mekanizmaları ile çoklu ölçekte özellik çıkarımının yoğun kullanımı GPU bellek tüketimini ve işlem süresini artırmakta, bu da eğitimin en uzun sürede tamamlanmasına yol açmaktadır.

Bu ağların eğitim süreleri, mimari karmaşıklık, parametre sayısı, dikkat mekanizmalarının kullanımı ve hesaplama yoğunluğu gibi faktörlerle doğrudan ilişkilidir. Daha gelişmiş ve karmaşık mimariler genellikle daha yüksek performans potansiyeli sunmakla birlikte, bu durum eğitim süresi ve hesaplama maliyeti açısından ilave bir yük oluşturmaktadır.

Son olarak, veri setinin yüksek çözünürlüklü olması, modellerin hesaplama maliyetini artırmış ve küçük detayların doğru bir şekilde öğrenilmesini zorlaştırmıştır. Özellikle UNet++ gibi yapıların, yüksek çözünürlüklü verilerdeki

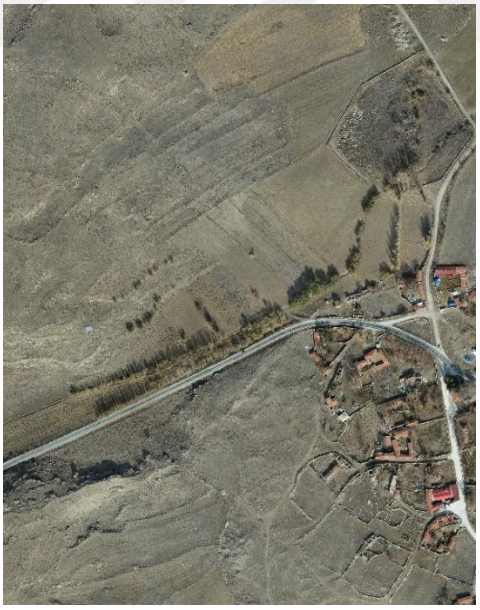
küçük detayları işleme konusundaki yetersizliği, performans kaybına neden olmuştur (Tablo 4.3).

**Tablo 4.3** Derin öğrenme ağlarının eğitim sürelerinin karşılaştırılması

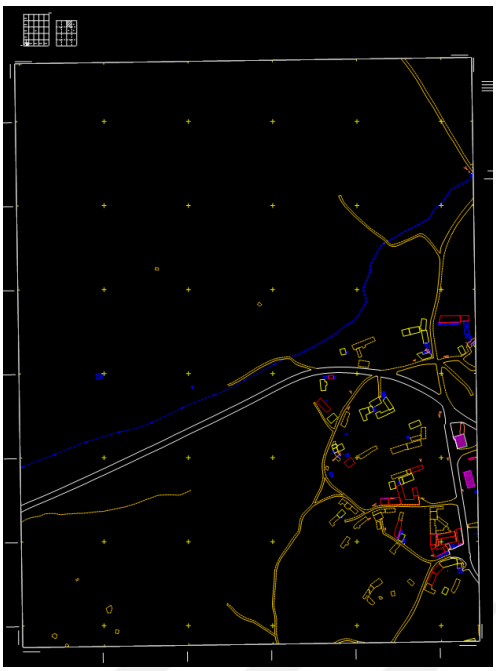
| | |
|---|---|
| **DeepLabv3+** | 2 saat 51 dakika |
| **Attention U-Net** | 3 saat 44 dakika |
| **UNet++** | 4 saat 55 dakika |
| **SegFormer-MixVTB3** | 7 saat 5 dakika |

### 4.3.3 Derin Öğrenme ile Arazi Kullanım Haritalarının Üretilmesi

Derin öğrenme ile elde edilen sınıflardan üretilen arazi kullanımı haritasının kullanılabilirliğini irdelemek amacıyla eğitim setinde olmayan, Afyonkarahisar'ın Davulga ilçesine ait ortofotoda modeller test edilmiştir (Şekil 4.10). Derin öğrenme ile elde edilen sınıflar kullanılarak üretilen haritalar, el ile çizilmiş harita (Şekil 4.11) ile karşılaştırılmıştır.

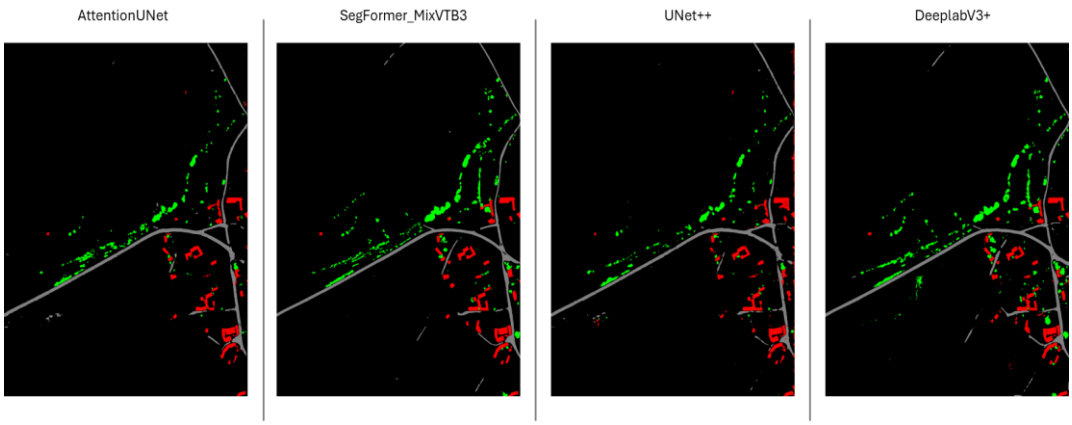


**Şekil 4.10** Haritası oluşturulan bölgenin ortofotosu



**Şekil 4.11** Davulga test bölgesine ait el ile çizilmiş olan harita

Elle çizim ile üretilen haritada yapıların köşeleri oldukça net bir şekilde belirlenmiştir. Operatör, farklı yapı türlerini (sundurmalar, depolar, ahırlar) ve yol kenarlarını düzgün bir biçimde ayrıştırmış, detay hassasiyeti yüksek bir çıktı sağlamıştır.




**Şekil 4.12** Derin öğrenme yöntemleri ile üretilen sınıflandırma sonuçlarının karşılaştırılması

Dört modelin sınıflandırma performansları karşılaştırıldığında (Tablo 4.4 ve Şekil 4.12), Segformer_MixVTB3 modelinin genel olarak en iyi sonuçları sunduğu görülmektedir. Özellikle bina ve yeşil alan sınıflarında, nesne sınırlarının daha iyi korunması ve doğru tahminlerin daha yüksek olması nedeniyle Segformer_MixVTB3 modeli tercih edilebilir bir yöntem olarak öne çıkmaktadır. DeepLabV3+, genel performansı güçlü olan bir diğer model olup, yeşil alan ve bina sınıflandırmalarında Segformer_MixVTB3 kadar başarılı olmasa da dengeli bir sonuç sunmaktadır. Attention UNet ve UNet++ modelleri ise özellikle bina ve yeşil alan sınıflarında diğer modellere kıyasla daha düşük performans sergilemiş olup, bu sınıfların doğru belirlenmesi açısından yeterli bulunmamaktadır.

Bu bulgular, ortofoto tabanlı arazi kullanımı sınıflandırmalarında model seçiminde önemli farklılıkların olabileceğini göstermektedir. Yapılan analizler, Segformer_MixVTB3 ve DeepLabV3+ modellerinin özellikle bina ve yeşil alan sınıfları açısından daha iyi sonuçlar sunduğunu ortaya koymaktadır. Çalışmanın amacına bağlı olarak, bina ve yeşil alan tespitinin kritik olduğu durumlarda Segformer_MixVTB3 modeli tercih edilebilirken, genel bir denge arayan uygulamalar için DeepLabV3+ daha uygun bir seçenek olabilir.

**Tablo 4.4** Davulga bölgesi test verisine ait sınıflandırma sonuçları

| | **Arka Plan** | | | |
|---|---|---|---|---|
| | **IoU** | **Precision** | **Recall** | **F1-Score** |
| **Attention UNet** | 0,9745 | 0,9804 | 0,9938 | 0,9871 |
| **Deeplabv3p** | 0,9795 | 0,9892 | 0,9902 | 0,9897 |
| **Segformer** | 0,9850 | 0,9890 | 0,9959 | 0,9924 |
| **UNet++** | 0,9727 | 0,9802 | 0,9922 | 0,9861 |
| | **Bina** | | | |
| | **IoU** | **Precision** | **Recall** | **F1-Score** |
| **Attention UNet** | 0,7097 | 0,9146 | 0,7600 | 0,8302 |
| **Deeplabv3p** | 0,7971 | 0,9081 | 0,8670 | 0,8871 |
| **Segformer** | 0,8456 | 0,9412 | 0,8928 | 0,9163 |
| **UNet++** | 0,6227 | 0,7468 | 0,7893 | 0,7675 |
| | **Yol** | | | |
| | **IoU** | **Precision** | **Recall** | **F1-Score** |
| **Attention UNet** | 0,6883 | 0,8654 | 0,7708 | 0,8154 |
| **Deeplabv3p** | 0,7671 | 0,8737 | 0,8628 | 0,8682 |

**Tablo 4.4** Davulga bölgesi test verisine ait sınıflandırma sonuçları (Devamı)

| | | | | |
|---|---|---|---|---|
| **Segformer** | 0,7824 | 0,9503 | 0,8157 | 0,8779 |
| **UNet++** | 0,6944 | 0,8832 | 0,7647 | 0,8197 |
| | **Yeşil Alan** | | | |
| | **IoU** | **Precision** | **Recall** | **F1-Score** |
| **Attention UNet** | 0,3214 | 0,7199 | 0,3673 | 0,4864 |
| **Deeplabv3p** | 0,5092 | 0,6764 | 0,6733 | 0,6748 |
| **Segformer** | 0,6180 | 0,8357 | 0,7035 | 0,7639 |
| **UNet++** | 0,2865 | 0,7261 | 0,3212 | 0,4454 |

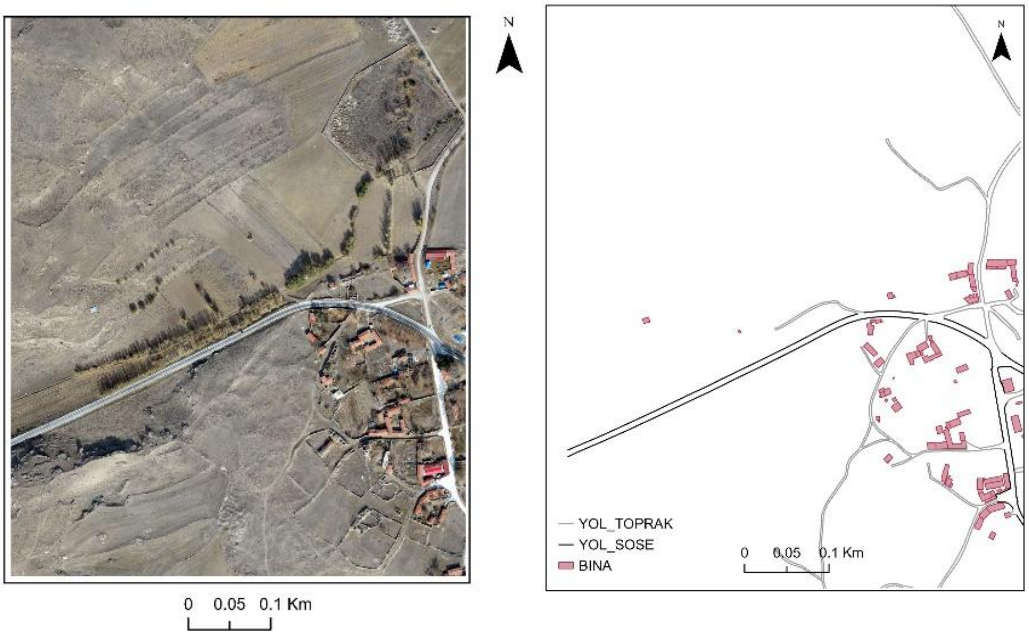
Sınıf ağırlıkları, derin öğrenme tabanlı görüntü segmentasyon çalışmalarında modelin farklı sınıflara verdiği önemi belirleyen kritik bir faktördür. Ortofoto gibi dengesiz veri dağılımına sahip veri setlerinde bazı sınıfların çok fazla yer kaplaması, modelin küçük ya da daha az temsil edilen sınıfları öğrenmesini zorlaştırabilir.

Bu çalışmada, arka plan sınıfının oldukça yüksek doğrulukla sınıflandırıldığı, ancak yeşil alan ve yol gibi sınıfların daha düşük IoU ve F1 skorlarına sahip olduğu görülmektedir. Özellikle derin öğrenme modelleri, ağırlıklı olarak veri setinde en çok bulunan sınıfları öğrenmeye eğilimlidir. Eğer veri setinde arka plan ve bina sınıfı fazla örneğe sahipse, modelin öğrenme süreci doğal olarak bu sınıflara kayabilir ve nadir ya da karmaşık yapıya sahip sınıfların (örneğin yollar veya yeşil alanlar) doğru şekilde tespit edilmesi zorlaşabilir.

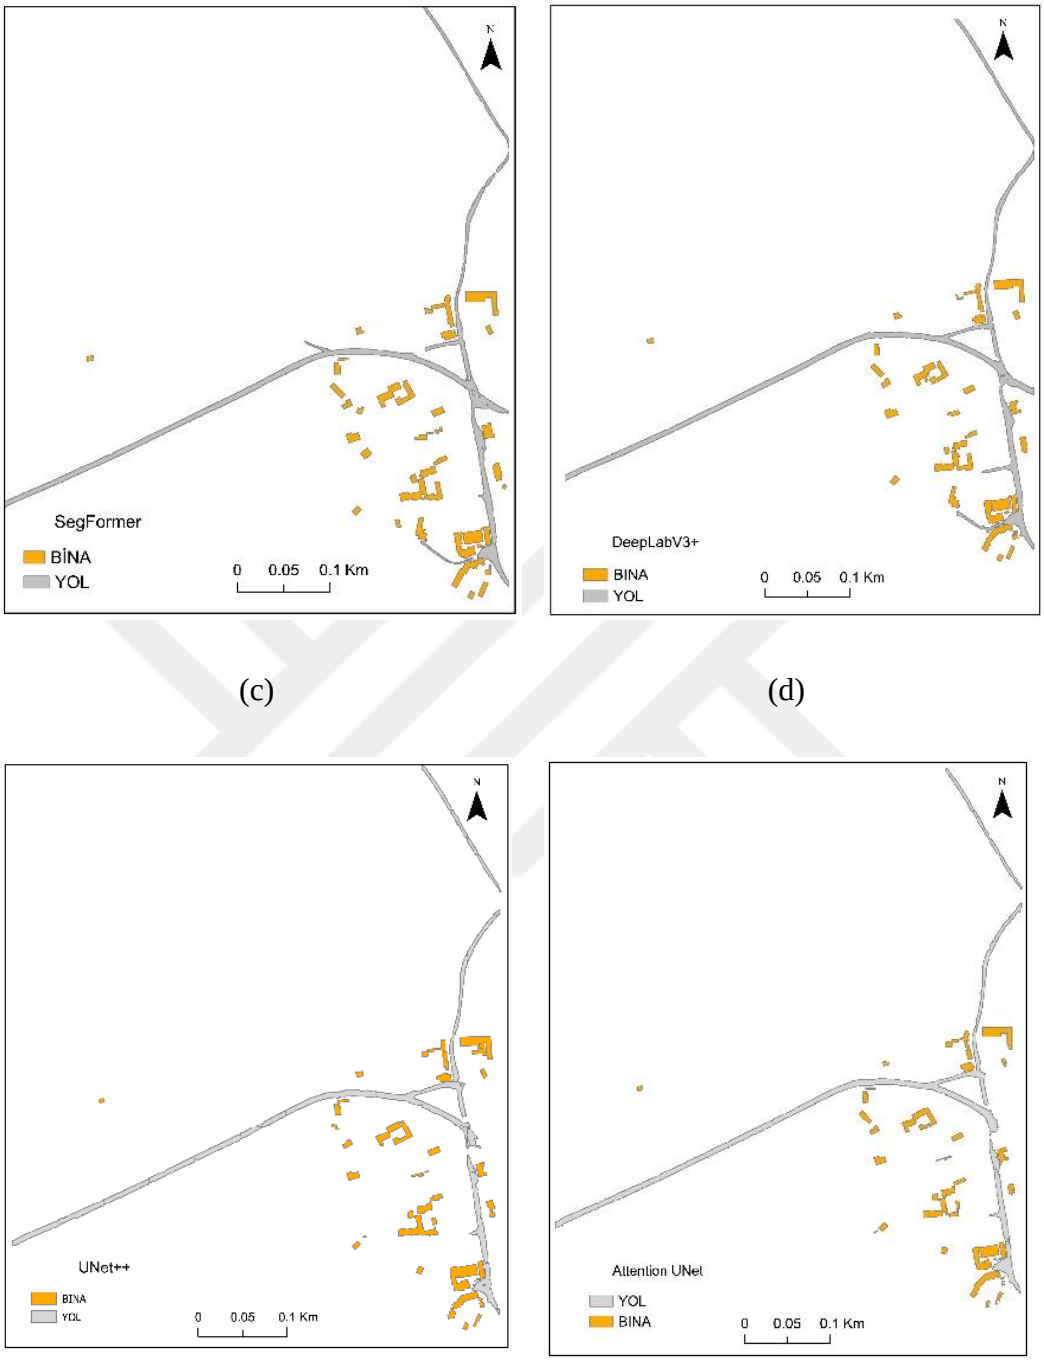
Bu dengesizliği gidermek için sınıf ağırlıklarının doğru belirlenmesi büyük önem taşır. Daha az temsil edilen veya tespit edilmesi zor olan sınıfların kayıp fonksiyonundaki etkisini artırarak modelin bu sınıflara daha fazla odaklanması sağlanabilir. Örneğin, model yeşil alanları düşük doğrulukla sınıflandırıyorsa, bu sınıfa daha fazla ağırlık verilerek hata yapmanın maliyeti artırılabilir. Böylece model, bu sınıfı daha iyi öğrenmeye eğilimli olur.

Derin öğrenme ile sınıflandırılan görüntüler ArcGIS Pro yazılımı kullanılarak otomatik olarak raster-vektör dönüşümü (Raster to Polygon) aracıyla vektör veriye dönüştürülmüştür. Bina Ayak İzini Düzenleme (Regularize Building Footprint) aracı ile vektör formata getirilen bina köşeleri dik açılı olarak düzenlenmiştir. Şekil 4.13b'de operatör tarafından üretilen vektör formatında referans ve derin öğrenme ile sınıflandırılan bina ve yol tabakalarını içeren haritalar (Şekil 4.13c-f)

görülmektedir. Referans binaların ve sınıflandırılan binaların alan örtüşmesi alan uygunluk katsayısı ile hesaplanmıştır. Alan uygunluk katsayısı referans alanı ve tahmin edilen alanın kesişiminim, referans alanı ve tahmin edilen alanın birleşimine oranıdır. Tablo 4.5 incelendiğinde en iyi bina örtüşmesinin %76,07 ile SegFormer algoritması ile elde edildiği görülmektedir. Bunu, %71,46 ile DeepLabV3+, %68,77 ile Attention UNet ve %67,79 ile UNet++ algoritmaları ile yapılan tahminler takip etmektedir. Referans harita ile elden edilen örtüşme oranlarının, etiket veriler kullanılarak elde edilen doğruluk oranları ile uyum gösterdiği anlaşılmaktadır. Üstü ağaçlarla kaplı bina nesnelerinin etiketlenememesi nedeniyle eksik tahmin edilmesi dışında, derin öğrenme yöntemleri kullanılarak gerçekleştirilen bina sınıflandırmasının arazi kullanım haritalarının üretimi açısından önemli bir potansiyel sunduğu değerlendirilmiştir. Şose tipi yollara ait referans ve derin öğrenme ile tahmin edilen orta eksenler karşılaştırıldığında, uzunluklarının eşit olduğu tespit edilmiştir. Ancak, toprak yolların derin öğrenme yöntemleri ile sağlıklı bir şekilde çıkarılamadığı belirlenmiştir. Bitki örtüsü, derin öğrenme ağları kullanılarak alan geometrisi biçiminde tespit edilmişken, referans veride ağaçlar nokta geometrisi ile işaretlenmiştir. Bu nedenle, ağaçların oluşturduğu bitki örtüsü referans ve tahmin edilen haritalar arasında metrik olarak karşılaştırılamamıştır.



(a) (b)




(c) (d)

(e) (f)

**Şekil 4.13** Davulga test bölgesine ait ortofoto (a), elle çizilen bina ve yol tabakalarını içeren harita (b), SegFormer ile üretilen bina ve yol tabakalarını içeren harita (c), DeepLabV3+ üretilen bina ve yol tabakalarını içeren harita (d), UNet++ ile üretilen bina ve yol tabakalarını içeren harita (e), Attention UNet ile üretilen bina ve yol tabakalarını içeren harita (f)

**Tablo 4.5** Alan uygunluk katsayısı (AUK) değerleri

| | Referans alanı ($m^2$) | Tahmin alanı ($m^2$) | Kesişim ($m^2$) | Birleşim ($m^2$) | AUK= (Kesişim/ Birleşim)* 100 (%) |
|---|---|---|---|---|---|
| DeepLabV3+ | 4706,836 | 4038.492 | 3644,947 | 5100,381 | 71,46 |
| Attention UNet | 4706,836 | 3578.844 | 3376,233 | 4909,447 | 68,77 |
| SegFormer | 4706,836 | 4309.375 | 3895,478 | 5120,733 | 76,07 |
| UNet++ | 4706,836 | 3846,000 | 3461,655 | 5091,181 | 67,99 |

Derin öğrenme ile üretilen harita, büyük yapıları ve bitki örtüsünü sınıflandırma konusunda genel olarak başarılı olsa da yapı ve yol kenarları gibi detaylarda belirsizlikler gözlenmiştir. Bu durum, doğruluk seviyesinin bazı bölgelerde düşmesine neden olmaktadır. Operatör tarafından oluşturulan haritada ise yapı sınırları düzgün ve ayrıntılı bir biçimde belirtilmiş, yol kenarları hassas bir şekilde çizilmiştir. Dolayısıyla detay seviyesi oldukça yüksek bir çıktı elde edilmiştir.

Derin öğrenme ile üretilen haritada, yeşil alanlar ve bitki örtüsü genellikle doğru tespit edilmiştir. Ancak yapı sınıflandırmasında bazı yanlış pozitifler ve nesne birleşimleri dikkat çekmektedir. Bu durum, modelin büyük veri setleri üzerindeki çalışma kapasitesine rağmen detay hassasiyetinin el ile yapılana göre düşük olduğunu ortaya koymaktadır. Operatör tarafından oluşturulan harita, yapı sınıflandırması ve detay belirlemede daha tutarlı ve doğrudur. Ancak bu yöntemin zaman alıcı olduğu ve öznellik taşıyabileceği unutulmamalıdır.

Derin öğrenme yöntemleri, büyük veri setlerinde hızlı analiz yapma avantajı sunmaktadır. Özellikle tarım arazileri, bitki örtüsü gibi doğal alanların sınıflandırmasında ve büyük çaplı arazi analizlerinde kullanılabilir. Bununla birlikte, detay gerektiren yapı sınıflandırması için el ile yapılan düzenlemelere ihtiyaç duyulabilir. Operatör tarafından çizilen harita, daha detaylı ve hassas çalışmalar için uygundur. Ancak operatörün bir paftayı ortalama iki saatte çizdiği göz önüne alınırsa zamansal maliyetin yüksek olduğu dikkate alınarak, daha geniş bölgeler için verimli bir yöntem olmadığı söylenebilir.

Yapılan analiz sonucunda, derin öğrenme yöntemlerinin büyük veri setlerinde hızlı ve genel analizler için uygun olduğu; ancak detay hassasiyetinin el ile yapılana göre

düşük olduğu tespit edilmiştir. Derin öğrenme teknikleri özellikle geniş coğrafi bölgelerin hızlı bir şekilde analiz edilmesi ve doğal kaynakların haritalanması gibi süreçlerde büyük avantaj sağlamaktadır. Buna karşın, detaylı nesne sınıflandırması ve küçük yapıların sınırlarının net olarak belirlenmesi gibi durumlarda operatör tarafından yapılan çizimler daha doğru ve tutarlı sonuçlar vermektedir.

Bu bağlamda, ilerleyen çalışmalar için derin öğrenme yöntemlerinin doğruluğunu artırmak adına model eğitiminde kullanılacak veri setlerinin zenginleştirilmesi, nesne sınırlarının daha hassas belirlenmesini sağlayacak ek algoritmaların kullanılması önerilmektedir. Ayrıca, elle çizim yöntemleri ile derin öğrenme çıktılarının bir arada kullanıldığı hibrit yaklaşımlar hem zaman verimliliği hem de doğruluk açısından optimum sonuçlar elde edilmesini sağlayabilir.

# 5
# SONUÇ

Bu tez çalışmasında, arazi kullanımının doğru bir şekilde belirlenmesi amacıyla, ortofotoların derin öğrenme yöntemleri kullanılarak arazi örtüsünün sınıflandırılması üzerine yoğunlaşılmıştır. Kırklareli'nin Kaynarca ilçesinde insansız hava araçları ile elde edilen ortofotolar üzerinde yapılan sınıflandırma işlemlerinde bina, yol, bitki örtüsü ve arka plan olmak üzere dört temel sınıf ele alınmış, bu sınıflandırmalar için DeepLabv3+, UNet++, SegFormer-MixVTB3 ve Attention UNet algoritmaları kullanılmıştır. Kaynarca ilçesine ait test verisi kullanıldığında DeepLabv3+ ve Segformer-MixVTB3 algoritmalarının sınıflandırma performansı diğer yöntemlere göre daha yüksek doğrulukta çıkmıştır.

Ayrıca, derin öğrenme ile elde edilen sınıflandırmayı değerlendirmek amacıyla, model eğitim setinde yer almayan Afyonkarahisar'ın Davulga ilçesine ait bir ortofoto üzerinde model test edilmiştir. Buna ek olarak, operatör tarafından oluşturulan referans harita ile derin öğrenme ile elde edilen haritalar karşılaştırılmıştır. Elde edilen sonuçlara göre SegFormer-MixVTB3 algoritmasının sınıflandırma performansı diğer yöntemlere göre daha yüksek doğruluktadır.

Elde edilen sonuçlara göre, DeepLabv3+ ve SegFormer-MixVTB3 algoritmalarının performansları, özellikle bina ve yol gibi belirgin geometrik özelliklere sahip sınıflarda daha yüksek doğruluk oranları ile diğer yöntemlerin önüne geçmiştir. Ancak, doğal sınıfların sınıflandırılmasında tüm modellerin görece düşük performans sergilediği, bu durumun sınıflar arasındaki sınırların belirsizliğinden kaynaklandığı belirlenmiştir. Bunun yanında, veri setinde bazı sınıfların yetersiz temsil edilmesi, özellikle nadir rastlanan veya karmaşık desenler barındıran sınıfların doğru sınıflandırılmasını güçleştirmiştir.

Eğitim süreleri açısından en hızlı sonuç veren DeepLabv3+ olmuştur. Buna karşın, SegFormer-MixVTB3 algoritmasının daha uzun bir eğitim süreci gerektirse de detay yakalama kapasitesi ve doğruluk oranları, bu dezavantajı dengelemiştir.

Sınıflandırma sürecinde, modellerin eğitimi sırasında karşılaşılan zorluklar dikkat çekmiştir. Eğitim sırasında veri setinin çeşitlilik eksikliği, doğal sınıfların karmaşık yapısı ve bazı modellerin mimari sınırlamaları gibi sorunlarla da karşılaşılmıştır. Bu zorlukların üstesinden gelmek için veri artırma tekniklerinin çeşitlendirilmesi, sınıf dengesizliklerini gidermek için örnekleme yöntemlerinin kullanılması ve modellerin yapısal özelliklerinin geliştirilmesi önerilebilir. Özellikle belirsiz sınırları ayırt edebilmek için bağlamsal bilgi yakalamaya yönelik geliştirmeler, sınıflandırma performansını artırmak için önemli bir adım olacaktır. Bu zorlukların çözümü, modellerin genelleme yeteneğini artırarak sınıflandırma süreçlerini daha başarılı hale getirebilir.

Bu çalışma, derin öğrenme yöntemlerinin arazi kullanım analizlerinde etkili bir şekilde kullanılabileceğini göstermiştir. Elde edilen sonuçlar, bu yöntemlerin büyük veri setlerinde el ile yapılana göre hem daha hızlı hem de maliyet açısından daha avantajlı olduğunu ortaya koymaktadır. Bununla birlikte, özellikle doğal sınıfların daha hassas bir şekilde sınıflandırılabilmesi için gelecekte daha geniş ve çeşitlendirilmiş veri setleriyle çalışmalar yapılması gerektiği anlaşılmıştır.

Sonuç olarak, derin öğrenme tekniklerinin arazi kullanım analizlerinde sağladığı katkılar, hem bilimsel araştırmalar hem de pratik uygulamalar açısından umut vericidir. Bu tür yöntemlerin, sürdürülebilir çevre yönetimi ve planlama süreçlerinde önemli bir araç olarak değerlendirilebileceği açıktır.

# KAYNAKÇA


Abbas, S., Almadhor, A., Sampedro, G. A., Alsubai, S., Al Hejaili, A., Strážovská, Ľ., & Zaidi, M. M. (2024). Efficient geospatial mapping of buildings, woodlands, water and roads from aerial imagery using deep learning. *PeerJ Computer Science, 10*, e2039.

Abbas, S., Almadhor, A., Sampedro, G. A., Alsubai, S., Al Hejaili, A., Strážovská, Ľ., & Zaidi, M. M. (2024). Efficient geospatial mapping of buildings, woodlands, water and roads from aerial imagery using deep learning. PeerJ Computer Science, 10, e2039.

Anilkumar, P., & Venugopal, P. (2022). Research Contribution and Comprehensive Review towards the Semantic Segmentation of Aerial Images Using Deep Learning Techniques. Security and Communication Networks, 2022.

Bachantourian, M., Chaleplis, K., Gemitzi, A., Kalabokidis, K., Palaiologou, P., & Vasilakos, C. (2022). Evaluation of MODIS, Climate Change Initiative, and CORINE Land Cover Products Based on a Ground Truth Dataset in a Mediterranean Landscape. Land, 11(9), 1453.

Bishop, C. M. (2006). Pattern Recognition and Machine Learning. Springer.

Bossard, M., Feranec, J., & Otahel, J. (2000). CORINE Land Cover Technical Guide – Addendum 2000. European Environment Agency (EEA).

Castelluccio, M., Poggi, G., Sansone, C., & Verdoliva, L. (2017). Land use classification in remote sensing images by convolutional neural networks. Pattern Recognition, 61, 539-556.

Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. ECCV, 833–851.

Çarkacı, N. (2024, Aralık 25). Derin öğrenme uygulamalarında en sık kullanılan hiper-parametreler. Deep Learning Türkiye | Medium. Erişim adresi: https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4

European Environment Agency (EEA). (2020). Land Cover and Change. Erişim adresi: https://www.eea.europa.eu

Foley, J. A., DeFries, R., Asner, G. P., Barford, C., Bonan, G., Carpenter, S. R., & Snyder, P. K. (2005). Global consequences of land use. Science, 309(5734), 570-574.

Ge, S., Liu, D., Shi, X., Zhao, X., Wang, X., & Fan, J. (2025). Semantic segmentation of remote sensing images based on filtered hybrid attention mechanisms. Engineering Letters, 33(1), 80-89.

Ghorbanzadeh, O., Blaschke, T., Gholamnia, K., Meena, S. R., Tiede, D., & Aryal, J. (2019). Evaluation of Different Machine Learning Methods and Deep-Learning Convolutional Neural Networks for Landslide Detection. Remote Sensing, 11, 196.

Goodfellow, I. J., Bengio, Y., & Courville, A. C. (2015). Deep learning. Nature, 521(7553), 436–444.

Google Earth. (2024, Aralık 24). Kırklareli Kaynarca [Harita görüntüsü]. Erişim adresi:https://earth.google.com/web/search/kırklarelikaynarca/@41.66003097,27.4766259,201.56997638a,1673.14761238d,35y,323.47964188h,44.99684938t,0r

Guo, Y., Wang, H., Hu, Q., Liu, H., Liu, L., & Bennamoun, M. (2021). Deep Learning for 3D Point Clouds: A Survey. IEEE Transactions on Pattern Analysis and Machine Intelligence, 43, 4338-4364.

Hastie, T., Tibshirani, R., & Friedman, J. (2009). The Elements of Statistical Learning: Data Mining, Inference, and Prediction (2nd ed.). Springer.

Hu, K., Zhang, E., Dai, X., Xia, M., Zhou, F., Weng, L., & Lin, H. (2023). MCSGNet: A encoder–decoder architecture network for land cover classification. Remote Sensing, 15(11), 2810.

Jordan, M. I., & Mitchell, T. M. (2015). Machine Learning: Trends, Perspectives, and Prospects. Science.

Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. Advances in Neural Information Processing Systems.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. Nature, 521(7553), 436–444.

Nedovic-Budic, Z., Knaap, G. J., & Hopkins, L. D. (2004). The future of GIS and planning: Converging technologies and diverging interests. Journal of the American Planning Association, 70(2), 184-198.

Oktay, O., Schlemper, J., Le Folgoc, L., Lee, M., Heinrich, M., Misawa, K., ... & Rueckert, D. (2018). Attention U-Net: Learning where to look for the pancreas. arXiv preprint arXiv:1804.03999.

Qin, X., Wu, C., Chang, H., Lu, H., & Zhang, X. (2020). Match Feature U-Net: Dynamic receptive field networks for biomedical image segmentation. Symmetry, 12(8), 1230.

Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. MICCAI 2015, 234–241.

Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning Representations by Back-Propagating Errors. Nature, 323(6088), 533–536.

Russell, S., & Norvig, P. (2016). Artificial Intelligence: A Modern Approach. Pearson.

Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. The Journal of Machine Learning Research, 15(1), 1929-1958.

Tilman, D., Cassman, K. G., Matson, P. A., Naylor, R., & Polasky, S. (2001). Agricultural sustainability and intensive production practices. Nature, 418(6898), 671-677.

Wahbi, M., El Bakali, I., Ez-zahouani, B., Azmi, R., Moujahid, A., Zouiten, M., ... & El Kharki, O. (2023). A deep learning classification approach using high spatial satellite images for detection of built-up areas in rural zones: Case study of Souss-Massa region-Morocco. Remote Sensing Applications: Society and Environment, 29, 100898.

Xie, E., Wang, W., Yu, Z., Anandkumar, A., Alvarez, J. M., & Luo, P. (2021). SegFormer: Simple and efficient design for semantic segmentation with transformers. NeurIPS, 34, 12077–12090.

Zhou, H., Yang, J., Zhang, T., Dai, A., & Wu, C. (2023). EAS-CNN: Automatic design of convolutional neural network for remote sensing images semantic segmentation. International Journal of Remote Sensing, 44(13), 3911-38.

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

# TEZDEN ÜRETİLMİŞ YAYINLAR

**Konferans Bildirileri**

**1**. Güner, B. P., Bayrak, O. C., & Şen, A. (2024). Arazi kullanımın belirlenmesi amacıyla ortofoto görüntülerin derin öğrenme yöntemleriyle sınıflandırılması. Uzal-CBS2024, 17-19 Ekim 2024, Aksaray.