

# İHA TABANLI YÜKSEK ÇÖZÜNÜRLÜKLÜ ORTOFOTO GÖRÜNTÜLERİN ESA KULLANILARAK SINIFLANDIRILMASI

İlyas ASLAN<sup>1</sup>, Nizar POLAT<sup>2</sup>,

<sup>1</sup>Öğr. Gör., Dicle Üniversitesi, Teknik Bilimler MYO, Mimarlık ve Şehir Planlama Bölümü, Sur, Diyarbakır, ilyas.aslan@dicle.edu.tr

<sup>2</sup>Doç. Dr., Harran Üniversitesi, Harita Mühendisliği Bölümü, Osmanbey, Şanlıurfa, nizarpolat@harran.edu.tr

## ÖZET

İHA'lar (İnsansız Hava Araçları), yüksek çözünürlüklü ve güncel veriler sağlama kabiliyeti sayesinde uzaktan algılama ve haritalama çalışmalarında yaygın olarak kullanılmaktadır. İHA'lar sayesinde fotogrametrik çalışmalar, daha hızlı, ekonomik ve yüksek çözünürlüklü verilerle yapılabilmektedir. Bu çalışmada Harran Üniversitesi kampüsünde yer alan bir bölgeye ait İHA ile uçuş gerçekleştirilmiştir. Elde edilen fotoğraflar, ortofoto görüntülerine dönüştürülüp, En Yüksek Olasılıklı yöntemle sınıflandırıldıktan sonra Evrimsel Sinir Ağları(ESA) modele atılık oluşturulmak üzere sınıflandırma haritası oluşturulmuştur. ESA tabanlı yeni bir model kullanılarak, ortofoto görüntüler üzerinde ağaç, toprak ve gölge sınıfların tespiti ve ayrımı gerçekleştirilmiştir. Çalışma sonucunda, önerdiğimiz ESA modelinin sınıflandırma doğruluğu %96.75 olarak hesaplanıp tahmini sınıflandırma haritası elde edilmiştir. Elde edilen bulgular, İHA tabanlı ortofoto görüntülerin, uzaktan algılama ve haritalama çalışmalarında önerdiğimiz ESA modeli ile etkin bir şekilde sınıflandırılabilceğini ortaya koymaktadır.

**Anahtar Sözcükler:** Ortofoto, İnsansız Hava Araçları, Sınıflandırma, Evrimsel Sinir Ağı

## ABSTRACT

### CLASSIFICATION OF UAV-BASED HIGH-RESOLUTION ORTHOPHOTO IMAGES USING CNN

Unmanned Aerial Vehicles (UAVs) are widely used in remote sensing and mapping studies due to their ability to provide high-resolution and up-to-date data. Photogrammetric studies can be conducted more quickly, economically, and with higher resolution data thanks to UAVs. In this study, a UAV flight was conducted over a region within the Harran University campus. The obtained photographs were converted into orthophoto images, and after being classified according to the Maximum Likelihood method, a classification map was created to serve as a base for a Convolutional Neural Network (CNN) model. Using a new CNN-based model, the detection and differentiation of tree, soil, and shadow classes on orthophoto images were carried out. As a result of the study, the classification accuracy of our proposed CNN model was calculated to be 96.75%, and an estimated classification map was obtained. The findings indicate that UAV-based orthophoto images can be effectively classified in remote sensing and mapping studies using our proposed CNN model.

**Keywords:** Orthophoto, Unmanned Aerial Vehicles, Classification, Convolutional Neural Network

## 1. GİRİŞ

İnsansız Hava Araçları (İHA), modern uzaktan algılama teknolojilerinde devrim oluşturan araçlar arasında yer almaktadır. Yüksek çözünürlüklü görüntüleme sistemleri ve esnek kullanım olanakları sayesinde, tarım, orman yönetimi, kentsel planlama ve çevresel izleme gibi alanlarda geniş çapta kullanılmaktadır(Cheng et al., 2021). İHA tabanlı ortofoto görüntüleri, coğrafi olarak düzeltilmiş ve yüksek doğrulukla elde edilen fotoğraflar olup, yeryüzündeki nesnelerin doğru konumlarını ve özelliklerini incelemek için kullanılmaktadır. Ortofoto görüntüleri, hem görsel hem de mekansal bilgileri içermesi sebebiyle, sınıflandırma ve analiz süreçlerinde oldukça değerlidir(Yılmaz et al., 2018).

Evrimsel Sinir Ağları (ESA), özellikle görüntü işleme ve görsel veri analizinde yaygın olarak kullanılan bir tür derin öğrenme modelidir. Geleneksel sinir ağlarının gelişmiş bir versiyonu olan ESA'lar, görüntülerdeki mekansal ve zamansal korelasyonları yakalamak için özel olarak tasarlanmıştır(Dabetwar et al., 2023).

İHA'lar tarafından toplanan yüksek çözünürlüklü görüntüler, geleneksel uydu görüntülerine kıyasla daha ayrıntılı bilgi sağlamaktadır(Uysal et al., 2015). Bununla birlikte, bu kadar büyük ve karmaşık veri setlerinin analiz edilmesi, gelişmiş sınıflandırma tekniklerini gerektirmektedir. ESA, özellikle bu tür büyük veri setlerinde üstün başarı göstermekte ve görüntülerdeki farklı yüzey türlerini doğru bir şekilde sınıflandırma yeteneğine sahiptir. Bu sınıflandırma işlemi, tarımsal alanların belirlenmesi, arazi kullanımı ve kaplama analizi gibi uygulamalarda oldukça faydalıdır (Safonova et al., 2019).

Bu çalışma, İHA tabanlı yüksek çözünürlüklü ortofoto görüntülerinin ESA kullanılarak sınıflandırılması üzerine odaklanmaktadır. Çalışmanın temel amacı, ESA yönteminin İHA görüntüleri üzerindeki sınıflandırma performansını değerlendirmek ve özellikle mekansal çözünürlük analizlerinde sağladığı avantajları ortaya koymaktır.

## 2. VERİ SETİ VE YÖNTEM

### 2.1 Veri Seti

Çalışma alanı olarak Harran Üniversitesi Osmanbey Kampüsü'nde bulunan bir alan seçilmiştir. Bu konumun kapsamlı hava görüntülerini yakalamak için titizlikle planlanmış bir fotogrametrik uçuş görevi gerçekleştirildi. Uçuş görevi, %80 örtüşmeli 11 diziden oluşuyordu ve DJI Mavic 2 Pro drone kullanılarak 40 metre yükseklikte gerçekleştirildi. Bu uçuşlar sırasında toplam 345 coğrafi etiketli fotoğraf çekildi. SFM yöntemiyle bindirmeli çekilen fotoğraflarla, 10 cm mekansal çözünürlük ile Agisoft yazılımında ortofoto oluşturulmuştur.



Şekil 1. Ortofoto

### 2.2. Yöntem

#### 2.2.1. En Yüksek Olasılıklı Yöntem

Uzaktan algılama verilerinin sınıflandırılmasında kullanılan istatistiksel bir yöntemdir. Genellikle uydu görüntülerinin farklı arazi sınıflarına (örneğin tarım arazisi, orman, su) ayrılmasında kullanılır. Bu yöntemde, her pikselin hangi sınıfa ait olduğuna karar vermek için olasılık hesaplamaları yapılır (Aslan and Polat, 2024). Bu çalışmada üç sınıfa (Ağaç, Toprak, Gölge) ait oluşturulan ortofoto ile Arcgis yazılımında en yüksek olasılıklı yöntemle göre kontrollü sınıflandırma yapılmıştır.

#### 2.2.2. Evrişimsel Sinir Ağı(ESA)

Derin öğrenme teknikleri son zamanlarda İHA görüntü sınıflandırması için yaygın olarak kullanılmaktadır. Evrişimli sinir ağı (CNN), İHA görüntü sınıflandırması için sıklıkla kullanılan derin öğrenme yöntemlerinden biridir. ESA, daha ayırt edici özellikler sağlayabilen güçlü bir özellik öğrenmesine sahip olduğundan, daha yüksek kalitede görüntü sınıflandırması gerçekleştirebilir (Ereken and Tarhan, 2022). Sınıflandırma probleminde, öğrenilen özellikler ne kadar ayırt edici olursa, problemi çözmek o kadar kolay olur. Bu da sınıflandırma performansını önemli ölçüde artırır. ESA, Şekil 2'de gösterildiği gibi evrişim, havuzlama, düzleştirme, tam bağlantılı (FC) ve softmax katmanlarından oluşan derin bir sinir ağıdır. Evrişim katmanı, giriş verilerine evrişim uygulayarak özellikleri çıkarmak için kullanılan ESA'nın ilk katmanıdır. Görüntü verilerinden yararlı bilgileri çıkarmak için hesaplanan gerçekleştirildiği ESA'nın yapı taşıdır (Fırat and Hanbay, 2023).

**Giriş Katmanı (Input Layer):** Modelin işlediği ham veri burada verilir. Görüntülerde, her piksel giriş olarak alınır ve bu katmanda işlenir(Safonova et al., 2019).

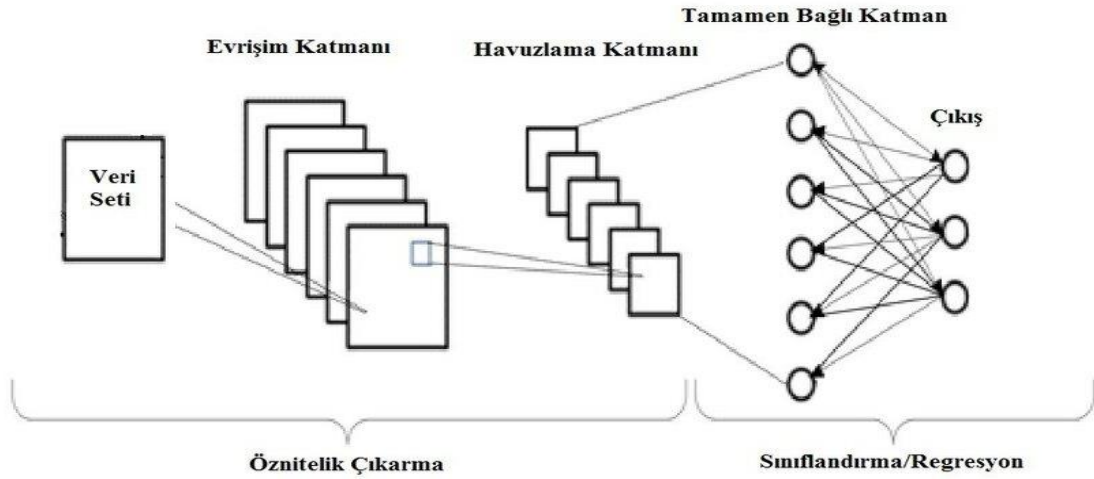
**Evrişim Katmanı (Convolutional Layer):** CNN'nin ana yapı taşıdır. Görüntüden belirli özellikleri çıkarmak için küçük filtreler (kernel) kullanılarak evrişim (convolution) işlemi yapılır. Bu katman, görüntüdeki kenar, doku gibi temel özellikleri tanır(Saqib et al., 2017).

**Aktivasyon Fonksiyonu (Activation Function):** Genellikle **ReLU (Rectified Linear Unit)** kullanılır. Girdiyi doğrusal olmayan bir hale getirir ve negatif değerleri sıfıra eşitleyerek modelin öğrenme kabiliyetini artırır(Behera et al., 2023).

**Havuzlama Katmanı (Pooling Layer):** Evrişim katmanından gelen çıktıyı küçültmek ve önemli özellikleri koruyarak hesaplama yükünü azaltmak için kullanılır. Genellikle **Maksimum Havuzlama (Max Pooling)** yöntemiyle çalışır, bu yöntem her bölgedeki maksimum değeri alır(Behera et al., 2023).

**Tam Bağlantılı Katman (Fully Connected Layer):** Bu katman, görüntüde öğrenilen özellikleri sınıflandırmak için kullanılır. Tüm nöronlar birbirine bağlanarak ağırlıklar güncellenir ve sınıflandırma gerçekleştirilir(Erekan and Tarhan, 2022).

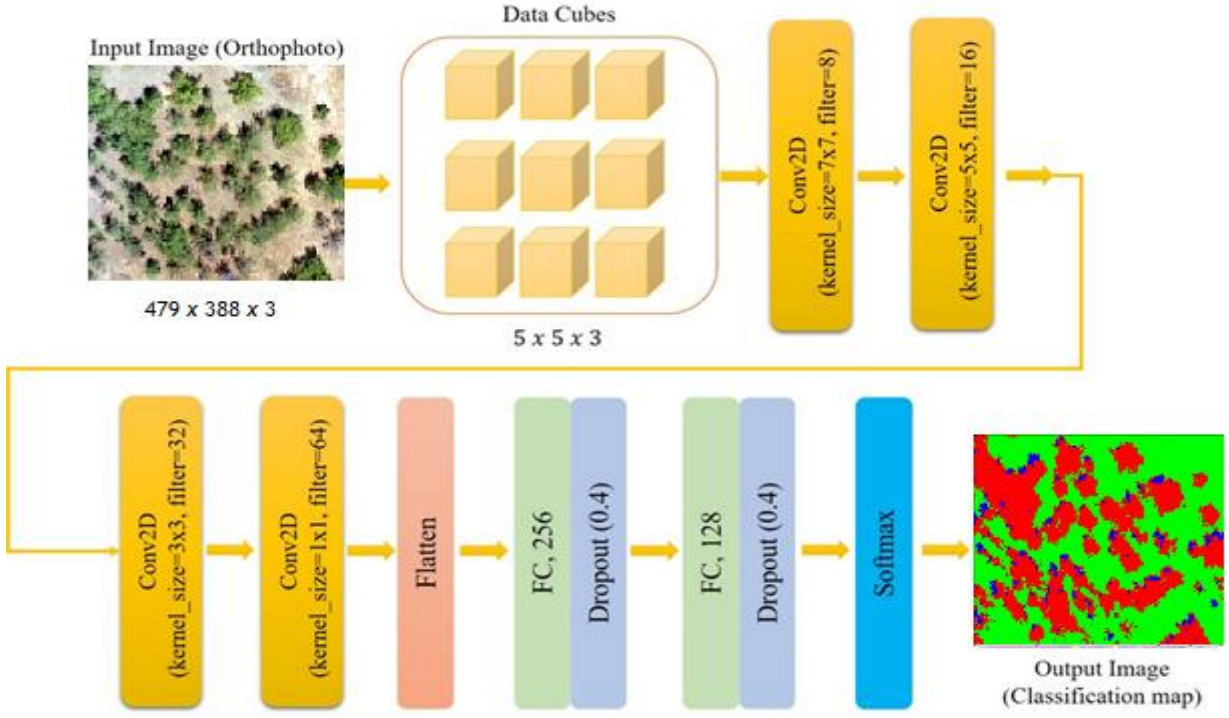
**Çıkış Katmanı (Output Layer):** Modelin tahmin sonuçlarını verir. Genellikle sınıflandırma problemleri için **Softmax** aktivasyon fonksiyonu kullanılır ve son katmanda modelin çıktıları (örneğin bir sınıfa ait olma olasılıkları) hesaplanır(Li et al., 2020).



Şekil 2. ESA mimarisi(Hamylton et al., 2020)

### 2.2.3 Önerilen Yöntem

Bu çalışmada, yüksek çözünürlüklü ortofoto görüntü sınıfı için yepyeni bir ESA yöntemi önerilmiştir. Önerilen ESA yönteminde, Şekil 3'te gösterildiği gibi bir düzleştirme, mutlak bağlantılı (FC), dropout ve softmax sınıf katmanlarının yardımıyla birlikte 4 ardışık evrişim katmanı içerir.



Şekil 3. Önerilen Yöntem


### 3. BULGULAR

Deneyel çalışmalarda kodlar python programlama dilinde yazılmıştır. Python kodları için Google Colab Pro+ platformu kullanılmıştır. Colab deneylerimiz için donanım hızlandırıcı olarak GPU'ları (Grafik İşleme Birimleri) kullanmaktadır. Ortofoto veri seti için %20-80 arasında bir test-öğretme oranı kullanılmıştır.


Agisoft yazılımında oluşturulan ortofoto ile ArcGIS yazılımında kontrollü sınıflandırma yaparak elde ettiğimiz groundtruthu önerdiğimiz yeni bir ESA mimarisinde uyguladıktan sonra elde edilen parametreler ve şekiller aşağıda göstermiştir.

Tablo 1. Sınıflandırma sonuçları

	Ağaç	Toprak	Gölge
<b>Accuracy (%)</b>	97	98.	93
<b>Precision (%)</b>	97	99	74
<b>Recall (%)</b>	95	99	90
<b>F1 score (%)</b>	96	99	82
<b>OA (%)</b>	96.75		
<b>AA (%)</b>	94.68		
<b>K (%)</b>	93.95		



Şekil 4. Sınıflandırma haritası (Groundtruth)



Şekil 5. Tahmin haritası

#### 4. SONUÇLAR

Bu çalışmada, Harran Üniversitesi kampüsünde bulunan birormanlık alana ait ağaç, gölge ve toprağı sınıflandırmak için bir İHA uçuşu gerçekleştirilmiştir. SFM fotogrametrik yaklaşımı kullanılarak belirli bir örtüşme oranına sahip belirli lokasyonlarda fotoğraflar çekilmiştir. Agisoft yazılımı kullanılarak fotoğraflardan ortofotolar oluşturulduktan sonra, groundtruhtu oluşturmak için ArcGIS yazılımında sınıflandırma tamamlanmıştır. Çalışma alanından toplanan

veri kümesinde toplam üç sınıf bulunmaktadır. Sınıflandırma sürecini gerçekleştirmek için derin öğrenmeye dayalı bir yaklaşım önerilmiştir. Önerilen yaklaşım yeni bir 2B CNN yöntemidir. Yaklaşımımız, minimum sayıda parametreyi koruyarak sınıflandırma performansını artırmayı amaçlamaktadır. Sınıflandırma sonucunda elde edilen ortalama doğruluğumuz 96.75 bulunmuştur. Ortofoto sınıflandırmasında oldukça yüksek bir etki gösterilmiştir. Son olarak, önerilen yöntemimiz, giriş görüntüsünden daha kapsamlı özellik tahminleri elde etmek için çeşitli çekirdek boyutlarını ve çıkarılan özellikleri birleştiren çok rotalı bir yaklaşım kullanmaktadır.

## KAYNAKLAR

- Aslan, İ., Polat, N.,** 2024. Deep learning-based classification of mature and immature lavender plants using UAV orthophotos and a hybrid CNN approach. *Earth Sci. Informatics* 17, 1713–1727. <https://doi.org/10.1007/s12145-023-01200-7>
- Behera, T.K., Bakshi, S., Sa, P.K.,** 2023. A Lightweight Deep Learning Architecture for Vegetation Segmentation using UAV-captured Aerial Images. *Sustain. Comput. Informatics Syst.* 37, 100841. <https://doi.org/10.1016/j.suscom.2022.100841>
- Cheng, Z., Gong, W., Tang, H., Juang, C.H., Deng, Q., Chen, J., Ye, X.,** 2021. UAV photogrammetry-based remote sensing and preliminary assessment of the behavior of a landslide in Guizhou, China. *Eng. Geol.* 289, 106172. <https://doi.org/10.1016/j.enggeo.2021.106172>
- Dabetwar, S., Padhye, R., Kulkarni, N.N., Niezrecki, C., Sabato, A.,** 2023. Performance evaluation of deep learning algorithms for heat loss damage classification in buildings from UAV-borne infrared images. *J. Build. Eng.* 75, 106948. <https://doi.org/10.1016/j.job.2023.106948>
- Ereken, O.F., Tarhan, C.,** 2022. **Breast Cancer Detection using Convolutional Neural Networks.** *ISMSIT 2022 - 6th Int. Symp. Multidiscip. Stud. Innov. Technol. Proc.* 597–601. <https://doi.org/10.1109/ISMSIT56059.2022.9932694>
- Firat, H., Hanbay, D.,** 2023. Comparison of 3D CNN based deep learning architectures using hyperspectral images. *J. Fac. Eng. Archit. Gazi Univ.* 38, 521–534. <https://doi.org/10.17341/gazimmfd.977688>
- Hamylton, S.M., Morris, R.H., Carvalho, R.C., Roder, N., Barlow, P., Mills, K., Wang, L.,** 2020. Evaluating techniques for mapping island vegetation from unmanned aerial vehicle (UAV) images: Pixel classification, visual interpretation and machine learning approaches. *Int. J. Appl. Earth Obs. Geoinf.* 89, 102085. <https://doi.org/10.1016/j.jag.2020.102085>
- Li, H., Ghamisi, P., Rasti, B., Wu, Z., Shapiro, A., Schultz, M., Zipf, A.,** 2020. A multi-sensor fusion framework based on coupled residual convolutional neural networks. *Remote Sens.* 12, 1–21. <https://doi.org/10.3390/RS12122067>
- Safonova, A., Tabik, S., Alcaraz-Segura, D., Rubtsov, A., Maglins, Y., Herrera, F.,** 2019. Detection of fir trees (*Abies sibirica*) damaged by the bark beetle in unmanned aerial vehicle images with deep learning. *Remote Sens.* 11. <https://doi.org/10.3390/rs11060643>
- Saqib, M., Daud Khan, S., Sharma, N., Blumenstein, M.,** 2017. A study on detecting drones using deep convolutional neural networks. 2017 14th IEEE Int. Conf. Adv. Video Signal Based Surveillance, AVSS 2017. <https://doi.org/10.1109/AVSS.2017.8078541>
- Uysal, M., Toprak, A.S., Polat, N.,** 2015. DEM generation with UAV Photogrammetry and accuracy analysis in Sahitler hill. *Meas. J. Int. Meas. Confed.* 73, 539–543. <https://doi.org/10.1016/j.measurement.2015.06.010>
- Yılmaz, H.M., Mutluoğlu, Ö., Ulvi, A., Yaman, A., Bilgilioglu, S.S.,** 2018. İnsansız Hava Aracı ile Ortofoto Üretimi ve Aksaray Üniversitesi Kampüsü Örneği Created Tree Dimensional Model of Aksaray University Campus With Unmanned Aerial Vehicle 3, 129–136.