

İHA Tabanlı Ortofotolarda Orman Alanlarının Derin Öğrenme ile Analizi

Deep Learning Analysis of Forest Areas in UAV-Based Orthophotos

İlyas ASLAN 

Dicle Üniversitesi Teknik Bilimler Meslek Yüksek Okulu, Mimarlık ve Şehir Planlama, Diyarbakır, Türkiye

ÖZ

Son yıllarda, insansız hava aracı (İHA) teknolojilerinin gelişmesiyle birlikte yüksek çözünürlüklü ortofotoların elde edilmesi kolaylaşmış ve bu verilerin arazi örtüsü analizlerinde kullanımı yaygınlaşmıştır. Özellikle derin öğrenme tabanlı yöntemler, karmaşık mekânsal görüntüleri öğrenebilme yetenekleri sayesinde yüksek çözünürlüklü görüntülerin sınıflandırılmasında etkin sonuçlar sunmaktadır. Bu çalışmada, İHA ile elde edilen ortofoto görüntüleri kullanılarak orman alanlarının sınıflandırılmasında derin öğrenme tabanlı yaklaşımlar değerlendirilmiştir. Çalışma kapsamında, orman veri seti üzerinde piksel tabanlı sınıflandırma yaklaşımı benimsenmiş olup, ağaç, gölge ve toprak olmak üzere üç temel sınıftan oluşmaktadır. Yer doğruluğu verileri kullanılarak eğitim ve test süreçleri gerçekleştirilmiştir. Model performansı doğruluk (accuracy), kayıp (loss) ve sınıf bazlı değerlendirme ölçütleri kullanılarak analiz edilmiştir. Orman veri seti üzerinde uygulanan MobileNet mimarisi ile %96,36 genel doğruluk elde edilmiştir. Elde edilen bulgular, derin öğrenme yöntemlerinin orman alanlarında arazi örtüsü sınıflandırmasında yüksek doğruluk ve hesaplama verimliliği sağladığını göstermektedir. Ayrıca çalışma, İHA tabanlı ortofotoların otomatik tematik harita üretiminde etkin bir şekilde kullanılabileceğini ortaya koymaktadır.

Anahtar Kelimeler: İHA, Ortofoto, Derin öğrenme, Sınıflandırma

ABSTRACT

In recent years, with the advancement of unmanned aerial vehicle (UAV) technologies, it has become easier to acquire high-resolution orthophotos, and the use of these data in land cover analysis has become increasingly widespread. Deep learning-based methods, in particular, provide effective results in the classification of high-resolution imagery due to their ability to learn complex spatial patterns. In this study, deep learning-based approaches were evaluated for the classification of forest areas using orthophoto images obtained from UAVs. Within the scope of the study, a pixel-based classification approach was adopted, and the dataset consisted of three main classes: tree, shadow, and soil. Training and testing processes were carried out using ground truth data. Model performance was analyzed using accuracy, loss, and class-based evaluation metrics. A general accuracy of 96.36% was achieved using the MobileNet architecture on the forest dataset. The findings demonstrate that deep learning methods provide high accuracy and computational efficiency in land cover classification of forest areas. Furthermore, the study reveals that UAV-based orthophotos can be effectively used for automatic thematic map production.

Keywords: UAV, Orthophoto, Deep learning, Classification

İlyas Aslan, Dicle Üniversitesi Teknik Bilimler Meslek Yüksek Okulu, Mimarlık ve Şehir Planlama, Diyarbakır, Türkiye

E-posta: ilyas.aslan@dicle.edu.tr / **ORCID ID:** 0000-0003-4388-6633

Geliş Tarihi: 27.04.2026 / **Kabul Tarihi:** 10.06.2026

Alıntı için; Aslan İ. İHA Tabanlı Ortofotolarda Orman Alanlarının Derin Öğrenme ile Analizi. Harran Üniversitesi Fen Bilimleri Dergisi. 2026;1(1):30-36.



Bu dergide yayınlanan makaleler Creative Commons Atıf- 4.0 Uluslararası Lisansı ile lisanslanmıştır.
Articles published in this journal are licensed under a Creative Commons Attribution- 4.0 International License.

GİRİŞ

Fotogrametri, yeryüzüne ait nesne ve yüzeylerin geometrik özelliklerinin görüntüler aracılığıyla belirlenmesini sağlayan temel bir mühendislik disiplini (Kraus, 2007). Son yıllarda İHA'ların yaygınlaşmasıyla birlikte, yüksek mekânsal çözünürlüğe sahip görüntülerin düşük maliyet ve yüksek esneklikle elde edilmesi mümkün hâle gelmiştir. İHA'lar, düşük uçuş irtifası ve yüksek bindirme oranları sayesinde yüksek doğrulukta ortofoto üretimine olanak tanımakta ve bu veriler özellikle arazi örtüsü analizlerinde yaygın olarak kullanılmaktadır (Colomina ve Molina, 2014; Nex ve Remondino, 2014).

İHA tabanlı ortofotolar, tarımsal, kentsel ve doğal alanlarda detaylı mekânsal bilgi sunmalarına rağmen, yüksek çözünürlükten kaynaklanan piksel karmaşıklığı, gölge etkileri ve sınıflar arasındaki benzerlikler nedeniyle sınıflandırma sürecinde zorluklar barındırmaktadır (Blaschke, 2010). Geleneksel sınıflandırma yöntemleri bu tür karmaşık veri yapılarında sınırlı performans gösterebilmekte, bu durum daha gelişmiş yöntemlerin kullanılmasını gerekli kılmaktadır.

Derin öğrenme yöntemleri, özellikle evrimsel sinir ağları (ESA), görüntü verilerinden otomatik olarak ayırt edici özellikler çıkarabilme yetenekleri sayesinde son yıllarda uzaktan algılama ve fotogrametri alanlarında yaygın olarak kullanılmaktadır. ESA tabanlı modeller, yüksek çözünürlüklü ortofotolarda karmaşık mekânsal görüntüleri öğrenerek sınıflandırma doğruluğunu artırmaktadır (Fırat ve Hanbay, 2023; Aslan ve Polat, 2024; LeCun vd., 2015). Literatürde, İHA ortofotoları üzerinde gerçekleştirilen çalışmalarda derin öğrenme yöntemlerinin, geleneksel yaklaşımlara kıyasla daha yüksek doğruluk ve daha tutarlı sonuçlar sunduğu ortaya konulmuştur (Osco vd., 2021; Cheng vd., 2024).

İHA tabanlı ortofoto görüntülerinin sınıflandırılmasına yönelik çalışmalar son yıllarda önemli ölçüde artış göstermiştir. Özellikle derin öğrenme yöntemlerinin uzaktan algılama alanında yaygınlaşmasıyla birlikte, yüksek çözünürlüklü görüntüler üzerinde daha başarılı sonuçlar elde edilmeye başlanmıştır. Colomina ve Molina (2014), İHA fotogrametrisinin veri üretim süreçlerindeki esnekliğini ve yüksek doğruluk

potansiyelini ortaya koyarak bu teknolojinin harita mühendisliğindeki önemini vurgulamıştır.

Nex ve Remondino (2014) tarafından yapılan çalışmada, İHA sistemlerinin farklı uygulama alanlarında sağladığı avantajlar değerlendirilmiş ve yüksek çözünürlüklü veri üretiminin sınıflandırma çalışmalarına katkısı incelenmiştir. Geleneksel görüntü analiz yöntemlerinin sınırlılıklarına dikkat çeken Blaschke (2010), nesne tabanlı görüntü analizinin (OBIA) yüksek çözünürlüklü verilerde daha etkin sonuçlar sunduğunu belirtmiştir. Derin öğrenme alanındaki gelişmelerle birlikte, LeCun vd. (2015), evrimsel sinir ağlarının görüntü işleme problemlerinde üstün performans sağladığını ortaya koymuştur. Bu yaklaşımlar uzaktan algılama alanına da uyarlanmış ve yüksek çözünürlüklü ortofotoların sınıflandırılmasında başarılı sonuçlar elde edilmiştir. Örneğin, Osco vd. (2021), İHA görüntüleri üzerinde derin öğrenme yöntemlerinin tarımsal ve doğal alanların sınıflandırılmasında yüksek doğruluk sağladığını göstermiştir. Benzer şekilde, Cheng vd. (2024), derin öğrenme tabanlı modellerin karmaşık mekânsal görüntüleri öğrenme yeteneği sayesinde sınıflandırma performansını önemli ölçüde artırdığını belirtmiştir.

Bu çalışmalar genel olarak değerlendirildiğinde, İHA tabanlı ortofoto görüntülerinin sınıflandırılmasında derin öğrenme yöntemlerinin önemli avantajlar sunduğu görülmektedir. Ancak farklı veri setleri üzerinde model performansının karşılaştırılması ve hesaplama verimliliğinin değerlendirilmesi konularında hâlâ sınırlı sayıda çalışma bulunmaktadır. Bu yönüyle mevcut çalışma, literatürdeki bu boşluğu doldurmayı hedeflemektedir.

MATERYAL VE METOT

Materyal

Çalışma bölgesi olarak Harran Üniversitesi Osmanbey Kampüsü'nde bulunan bir alan seçilmiştir. Alana ait kapsamlı hava görüntülerini elde edilmesi için titizlikle planlanmış bir fotogrametrik uçuş görevi gerçekleştirilmiştir. Uçuş görevi, %80 örtüşmeli 11 diziden oluşarak, 40 metre yükseklikte gerçekleştirilmiştir. Bu uçuşlar sırasında toplam 345 coğrafi etiketli fotoğraf çekilmiştir. Bu görüntülerden Agisoft yazılımı yardımıyla (James ve Robson, 2012) alana ait (Şekil 1) ortofoto oluşturulmuştur.



Şekil 1. Orman alanı ortofoto


Alan, SfM yöntemiyle, bindirmeli çekilen fotoğraflarla, 10 cm mekânsal çözünürlüklü olup, üç sınıfa ayrılmıştır (Snavely vd., 2008).

Tablo 1'de veri kümesinde yer alan sınıfları ve her bir sınıfa ait örnek sayısını göstermektedir.

Tablo 1. Orman alanı veri kümesi

Orman alanı veri kümesi			
No	Renk	Sınıf	Örnek sayısı
1	Red	Ağaç	3488
2	Green	Toprak	4482
3	Blue	Gölge	354
Toplam örnek sayısı		8324	

İHA görüntülerinden elde edilen ortofoto ile ArcGIS yazılımında En yüksek olasılıklı yöntem (Richards ve Jia, 2006) ile yer doğruluğu (Şekil 2) oluşturulmuştur.



Şekil 2. Orman alanı yer doğruluğu

Orman alanına ait yer doğruluğu, İHA tabanlı ortofotodan türetilmiş olup derin öğrenme tabanlı sınıflandırma modellerinin eğitimi ve değerlendirilmesi amacıyla referans veri olarak oluşturulmuştur (Aslan ve Polat, 2026). Haritada ağaç, toprak ve gölge sınıflarının mekânsal dağılımı, ortofotonun yüksek mekânsal çözünürlüğünü yansıtacak şekilde ayrıntılı biçimde temsil edilmekte, özellikle ağaç-gölge geçiş bölgeleri, modelin ayırt etme yeteneğini sınavan kritik alanlar olarak öne çıkmaktadır.

Metod

MobileNet

MobileNet, özellikle mobil ve gömülü sistemler gibi kaynak kısıtlı platformlar için geliştirilen, hafif ve hızlı bir ESA mimarisidir. Geleneksel derin öğrenme ağlarının yüksek hesaplama maliyetine sahip olması, özellikle gerçek zamanlı görüntü işleme gibi uygulamalarda önemli bir dezavantaj oluşturur (Agarap, 2017). Bu bağlamda, MobileNet mimarisi hem hesaplama verimliliğini artırmak hem de model boyutunu azaltmak amacıyla geliştirilmiş ve derin öğrenme alanında önemli bir alternatif hâline gelmiştir (Howard vd., 2017).

MobileNet mimarisinin temelini, standart evrişim katmanları yerine kullanılan derinlemesine ayrılabilir evrişimler (depthwise separable convolutions) oluşturur (Şekil 3). Bu yöntem, klasik evrişim katmanlarında yer alan işlemi iki aşamaya böler:

a. Derinlemesine (depthwise) evrişim, her bir giriş kanalı için ayrı ayrı evrişim uygular.


b. Noktasal (pointwise) evrişim ise 1x1 boyutundaki filtrelerle kanal birleştirmesi yapar (Sandler vd., 2018). Bu iki işlem kombinasyonu, geleneksel evrişim katmanlarına kıyasla hem parametre sayısını hem de hesaplama yükünü büyük ölçüde azaltır. MobileNet mimarisi, bu sayede hem yüksek doğruluk oranlarını koruyabilmekte hem de model karmaşıklığını azaltarak daha düşük donanımlarla çalışabilmektedir (Howard vd., 2017; Sandler vd., 2018).

MobileNet mimarisi, çeşitli sürümleriyle (MobileNetV1, V2, V3) gelişimini sürdürmüş ve her bir sürümde performans ve verimlilik artırılmıştır (Howard vd., 2017). Özellikle MobileNetV2, "inverted residuals" ve linear bottleneck gibi yeni yapılarla geliştirilmiş; bu

yapı, bilgi kaybını minimize ederek daha iyi özellik öğrenimi sağlamıştır (Sandler vd., 2018). MobileNetV3 ise otomatik makine öğrenimi (AutoML) teknikleriyle optimize edilerek, belirli görevler için en verimli yapıların seçilmesini mümkün kılmıştır (Howard vd., 2019).

MobileNet mimarisinin İHA görüntülerinin sınıflandırılmasında tercih edilmesinin temel nedeni, bu

mimarının düşük parametre sayısı ve düşük hesaplama gereksinimi ile çalışabilmesidir (Howard vd., 2017). İHA tabanlı görüntü işleme sistemlerinde, özellikle sınırlı işlemci kapasitesi, bellek kısıtları ve enerji tüketimi gibi donanımsal sınırlamalar, kullanılabilecek derin öğrenme modellerinin karmaşıklığını doğrudan etkilemektedir (Chowdhury vd., 2021).



Şekil 3. MobileNet modeli (Sandler vd., 2018)

BULGULAR

Bu çalışmada, orman veri seti üzerinde MobileNet mimarisinin sınıflandırma performansı değerlendirilmiştir. Modelin başarımı, sınıf bazlı doğruluk (accuracy), precision, recall ve F1-score ölçütleri ile birlikte genel doğruluk (overall accuracy), ortalama doğruluk (average accuracy) ve Kappa katsayısı kullanılarak analiz edilmiştir (Foody, 2002; Congalton ve Green, 2019; Cohen, 1960; Landis ve Koch, 1977).

Tablo 2 incelendiğinde, modelin ağaç, toprak ve gölge sınıflarında yüksek doğruluk değerleri elde ettiği görülmektedir. Özellikle gölge sınıfında %98,21

doğruluk değeri ile en yüksek sınıf doğruluğu elde edilmiştir. Ağaç ve toprak sınıflarında ise sırasıyla %97,15 ve %96,32 doğruluk değerleri elde edilmiştir. Precision ve recall değerleri (Powers, 2011) birlikte değerlendirildiğinde, modelin özellikle ağaç ve toprak sınıflarında dengeli ve yüksek performans sergilediği anlaşılmaktadır. Buna karşın gölge sınıfında precision değerinin (%68,45) diğer sınıflara göre daha düşük olması, bu sınıfta yanlış pozitif tahminlerin daha fazla olduğunu göstermektedir. Ancak recall değerinin (%80,37) görece yüksek olması, modelin gölge sınıfını büyük ölçüde doğru tespit edebildiğini ortaya koymaktadır.

Tablo 2. MobileNet sınıflandırma sonuçları (%)


	Ağaç (1)	Toprak (2)	Gölge (3)
Accuracy (%)	97,15	96,32	98,21
Precision (%)	93,44	99,17	68,45
Recall (%)	99,17	96,65	80,37
F1 score (%)	96,27	98,51	82,19
OA (%)	96,36		
AA (%)	87,82		
K (%)	93,14		

OA: Genel doğruluk, AA: Ortalama doğruluk, K: Kappa katsayısı (Tutarlılık ölçütü)

Genel performans ölçütleri incelendiğinde, modelin %96,36 genel doğruluk (OA), %87,82 ortalama doğruluk (AA) ve %93,14 Kappa katsayısı elde ettiği görülmektedir. Bu değerler, modelin hem genel doğruluk hem de sınıflar arası tutarlılık açısından oldukça başarılı olduğunu göstermektedir.


Şekil 4’de verilen yer doğruluğu ve tahmin haritası karşılaştırıldığında, modelin mekânsal dağılımı büyük ölçüde doğru şekilde temsil ettiği görülmektedir.

Özellikle ağaç ve toprak sınıflarının geniş alanlarda doğru sınıflandırıldığı dikkat çekmektedir. Bununla birlikte, sınıf geçiş bölgelerinde ve gölge alanlarında yer yer sınıflandırma hatalarının olduğu gözlemlenmektedir. Bu durum, piksel benzerliğinin yüksek olduğu bölgelerde modelin ayırt etme kapasitesinin sınırlı olabildiğini göstermektedir. Hatalı piksellere tahmin haritası üzerinde siyah kutucuk şeklinde gösterilmiştir.

**Şekil 4.** MobileNet Yer doğruluğu (a), Tahmin haritası (b)


Şekil 5’de sunulan karışıklık matrisi, modelin sınıflar arasındaki karışma durumunu daha ayrıntılı biçimde ortaya koymaktadır. Matris incelendiğinde, en fazla karışmanın gölge ve ağaç sınıfları arasında gerçekleştiği

görülmektedir. Bu durum, özellikle gölge alanlarının ağaç örtüsü ile benzer görsel özellikler taşımasından kaynaklanmaktadır. Toprak sınıfında ise diğer sınıflara kıyasla daha düşük karışma oranları gözlemlenmiştir.



Şekil 5. MobileNet karışıklık matrisi

Şekil 6’da verilen model doğruluğu ve kayıp grafikleri incelendiğinde, eğitim süreci boyunca doğruluğun artarak stabil hale geldiği ve kayıp değerinin azaldığı görülmektedir. Bu durum, modelin eğitim sürecinde başarılı bir öğrenme gerçekleştirdiğini ve aşırı öğrenme (overfitting) probleminin sınırlı düzeyde kaldığını göstermektedir.



Şekil 6. MobileNet model doğruluğu ve model kaybı

Genel olarak değerlendirildiğinde, MobileNet mimarisinin orman veri seti üzerinde yüksek doğruluk ve hesaplama verimliliği ile başarılı sonuçlar ürettiği, ancak özellikle gölge sınıfı gibi ayırt edilmesi zor sınıflarda performansın görece daha düşük kaldığı görülmektedir.

SONUÇ

Bu çalışmada, İHA tabanlı yüksek çözünürlüklü ortofoto görüntüleri kullanılarak orman alanlarının sınıflandırılmasında derin öğrenme tabanlı MobileNet

mimarisinin performansı değerlendirilmiştir. Ağaç, toprak ve gölge olmak üzere üç sınıftan oluşan veri seti üzerinde gerçekleştirilen analizler sonucunda, modelin yüksek doğruluk ve dengeli performans sergilediği belirlenmiştir.

Elde edilen bulgulara göre, MobileNet modeli %96,36 genel doğruluk (OA), %87,82 ortalama doğruluk (AA) ve %93,14 Kappa katsayısı ile başarılı bir sınıflandırma performansı ortaya koymuştur. Sınıf bazlı değerlendirmelerde ise ağaç sınıfı için %97,15, toprak sınıfı için %96,32 ve gölge sınıfı için %98,21 doğruluk değerleri elde edilmiştir. Precision, recall ve F1-score ölçütleri incelendiğinde, modelin özellikle ağaç ve toprak sınıflarında dengeli ve yüksek performans gösterdiği, gölge sınıfında ise precision değerinin (%68,45) görece düşük kalmasına rağmen recall değerinin (%80,37) kabul edilebilir düzeyde olduğu görülmüştür. Bu durum, gölge sınıfında yanlış pozitif tahminlerin arttığını, ancak sınıfın büyük ölçüde doğru tespit edilebildiğini göstermektedir.

Mekânsal analizler sonucunda elde edilen tahmin haritalarının, yer doğruluğu verisi ile büyük ölçüde uyumlu olduğu ve özellikle geniş alanlarda sınıfların doğru temsil edildiği belirlenmiştir. Bununla birlikte, sınıf geçiş bölgelerinde ve piksel benzerliğinin yüksek olduğu alanlarda sınıflandırma hatalarının oluştuğu gözlemlenmiştir.

Genel olarak değerlendirildiğinde, MobileNet mimarisinin düşük parametre sayısı ve hesaplama verimliliği sayesinde İHA tabanlı ortofoto görüntülerinin sınıflandırılmasında etkili bir yöntem olduğu ortaya konulmuştur. Bu çalışma, derin öğrenme yöntemlerinin yüksek çözünürlüklü mekânsal verilerin analizinde güvenilir ve uygulanabilir çözümler sunduğunu göstermektedir. Gelecek çalışmalarda, farklı veri setlerinin kullanılması, çok zamanlı analizlerin gerçekleştirilmesi ve daha gelişmiş model mimarilerinin entegrasyonu ile sınıflandırma performansının daha da artırılabilirliği değerlendirilmektedir.

Etik Onam: Bu çalışma için gerek duyulmamıştır.

Finansal Destek: Yazar(lar), finansal destek olmadığını beyan etmiştir.

KAYNAKLAR

Agarap, A. F. (2017). An architecture combining convolutional neural network (CNN) and support vector machine (SVM) for image

- classification. *arXiv preprint arXiv:1712.03541*.
- Aslan, İ., & Polat, N. (2024). Deep learning-based classification of mature and immature lavender plants using UAV orthophotos and a hybrid CNN approach. *Earth Science Informatics*, 17(2), 1713-1727.
- Aslan, İ., & Polat, N. (2026). Deep Learning-Based Classification of UAV Orthophotos Using MIDNet Architecture. *Turkish Journal of Applied Geoinformation Sciences*, 8(1), 15-27.
- Blaschke, T. (2010). Object-based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 2-16. <https://doi.org/10.1016/j.isprsjprs.2009.06.004>
- Cheng, G., Han, J., & Lu, X. (2024). Remote sensing image scene classification: Benchmark and state of the art. *Proceedings of the IEEE*, 112(4), 1-20.
- Chowdhury, M. E. H., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M. A., Mahbub, Z. B., Islam, M. T., & Reaz, M. B. I. (2021). Can AI help in screening viral and COVID-19 pneumonia? *IEEE Access*, 8, 132665-132676. <https://doi.org/10.1109/ACCESS.2020.3010287>
- Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20(1), 37-46. <https://doi.org/10.1177/001316446002000104>
- Colomina, I., & Molina, P. (2014). Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 92, 79-97. <https://doi.org/10.1016/j.isprsjprs.2014.02.013>
- Congalton, R. G., & Green, K. (2019). *Assessing the accuracy of remotely sensed data: Principles and practices* (3rd ed.). Boca Raton, FL: CRC Press.
- Firat, A., & Hanbay, D. (2023). Derin öğrenme mimarileri ile arazi örtüsü sınıflandırılması. *Journal of Intelligent Systems*, 34(2), 153-166.
- Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80(1), 185-201. [https://doi.org/10.1016/S0034-4257\(01\)00295-](https://doi.org/10.1016/S0034-4257(01)00295-)
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). MobileNets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- Howard, A., Sandler, M., Chu, G., Chen, L. C., Chen, B., Tan, M., Wang, W., Zhu, Y., Pang, R., Vasudevan, V., Le, Q. V., & Adam, H. (2019). Searching for MobileNetV3. In *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)* (pp. 1314-1324).
- James, M. R., & Robson, S. (2012). Straightforward reconstruction of 3D surfaces and topography with a camera: Accuracy and geoscience application. *Journal of Geophysical Research: Earth Surface*, 117(F3), F03017. <https://doi.org/10.1029/2011JF002289>
- Kraus, K. (2007). *Fotogrametri Cilt 1* (O. Altan, S. Külür, G. Toz, H. Demirel, Z. Duran, & M. Çelikoyan, Trans.). İstanbul Teknik Üniversitesi: Nobel Yayın Dağıtım.
- Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33(1), 159-174. <https://doi.org/10.2307/2529310>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- Nex, F., & Remondino, D. (2014). UAV for 3D mapping applications: A review. *Applied Geomatics*, 6(1), 1-15. <https://doi.org/10.1007/s12518-013-0120-x>
- Osco, L. P., Arruda, M. S., Marcato Junior, J., Gonçalves, W. N., Ramos, A. P. M., Li, J., & Junior, J. M. (2021). A review on deep learning in UAV remote sensing. *Remote Sensing*, 13(4), 1-25. <https://doi.org/10.3390/rs13040789>
- Powers, D. M. W. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, 2(1), 37-63
- Richards, J. A., & Jia, X. (2006). *Remote sensing digital image analysis: An introduction* (4th ed.). Berlin, Germany: Springer.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 4510-4520).
- Snaveley, N., Seitz, S. M., & Szeliski, R. (2008). Modeling the world from internet photo collections. *International Journal of Computer Vision*, 80(2), 189-210. <https://doi.org/10.1007/s11263-007-0107-3>