


T.C
SAHA İSTANBUL & TÜBİTAK TÜSSİDE
SAHA AKADEMİ MBA YÖNETİCİ GELİŞTİRME PROGRAMI

**Derin Öğrenme Algoritmaları Kullanılarak Tarım ve Orman Alanlarının
Otomatik Segmentasyonu**



Danışman
Dr. Uğur TARÇIN
İstanbul - 2025

1. SAHA İstanbul Yönetim Kurulu kararıyla, 2024-2025 eğitim döneminden itibaren SAHA AKADEMİ MBA katılımcılarına “Araştırma Projesi” hazırlama yükümlülüğü getirilmiştir. Bu uygulama; katılımcıların sektörel bilgi, stratejik düşünme ve akademik üretkenlik yetkinliklerini geliştirmeyi hedeflerken, savunma sanayii ekosistemine bilimsel katkıyı artırmayı amaçlamaktadır. Bu girişim, Türk savunma sanayii ekosisteminde bilimsel katkıyı artırmaya yönelik önemli bir adımdır.

2. SAHA İstanbul-SAHA AKADEMİ tarafından yayımlanan bu çalışma, ilgili yazar tarafından özgün biçimde hazırlanmış ve beyan edilmiştir. Çalışmada yer alan görüşler yazara ait olup, SAHA İstanbul’un kurumsal görüşünü yansıtmamaktadır. İçerikte sunulan bilgi, yorum ve sonuçların doğruluğu sorumlu yazara aittir. SAHA AKADEMİ; benzerlik oran tespiti yapmıştır.

3. Bu çalışma, [Salih BOZKURT] tarafından hazırlanmıştır. Araştırma Projesi danışman tarafından değerlendirilmiş ve sunumu [08 Mayıs 2025] tarihinde yeterli görülerek kabul edilmiştir.

Araştırma Projesi Sunum Jüri Üyeleri

Başkan	Dr. Uğur Tarçın (SAHA AKADEMİ Öğr.Görevlisi)	<i>e-imzalıdır</i>
Üye	Ayşe Çağın (SAHA AKADEMİ Yöneticisi)	<i>e-imzalıdır</i>
Üye	Muzaffer Ünsaldı (Kurumsal İletişim ve Marka Yöneticisi)	<i>e-imzalıdır</i>

(Formun aslı, imzalı olarak ilgili dosyada muhafaza edilmektedir.)

İÇİNDEKİLER

	<u>Sayfa No</u>
1. Özet	3
2. Proje Amacı	5
3. Projenin Kapsamı	5
4. Projenin Hedef Kitlesi	5
5. Projenin Yöntemi ve Çalışma Planı	6
6. Beklenen Sonuçlar.....	6
6.1. Proje Çıktısı.....	6
6.2. Yan Çıktılar	6
6.3. Hizmetler	6
7. Proje Bütçesi	7
8. Riskler ve Önlemler	7
8.1. Kullanılacak Veri Yapısı B Planı:	7
8.2. Algoritma B Planı:	9
9. Proje Süresi	9
10. Kaynaklar	9
11. Değerlendirme Kriterleri	10
12. Sonuç	11
13. Kaynakça	12

DERİN ÖĞRENME ALGORİTMALARI KULLANILARAK TARIM VE ORMAN ALANLARININ OTOMATİK SEGMENTASYONU

(PROJE)

Dr. Salih BOZKURT

BAYKAR

salih.bozkurt@baykartech.com

1. Özet

Orman alanlarının, ağaç türlerinin otomatik olarak belirlenmesi, doğal kaynakların yönetimi açısından kritik bir öneme sahiptir. Ülkemizde kentsel ve orman haritalarının üretimi 1940' lı yıllardan günümüze dek fotogrametrik yöntemler kullanılarak gerçekleştirilmektedir. Hava fotoğraflarından orman sınırı ve ağaç türlerinin belirlenmesi geleneksel stereo değerlendirme yöntemleri ile yapılmakta olup, bu durum, iş ve zaman açısından yüksek maliyet gerektirmektedir. Sunulan projede önerilen yöntem ile otomatik olarak çay alanlarının sınıflandırılması, derin öğrenme algoritmaları kullanılarak gerçekleştirilmiştir. Derin öğrenme algoritmaları, özellik çıkarımı işlemini veriden otomatik olarak yapan bir makine öğrenme yöntemidir. Son zamanlarda popülerlik kazanan derin öğrenme, ses tanıma, nesne tanıma, el yazısı tanıma ve görüntü sınıflandırma gibi birçok farklı bilgisayar tanı işlemlerinde kullanılmaktadır.

Sunulan proje kapsamında, derin öğrenme temelli bir yaklaşım kullanılarak yüksek çözünürlüklü görüntülerden çay alanlarının otomatik çıkartılması amaçlanmıştır. Bu amaç doğrultusunda, görüntüler içindeki çay alanları ve çay alanları dışında kalan alanları sınıflandırmak için VGG19 ağ yapısına sahip SegNet mimarisi kullanılmıştır. Derin öğrenme temelli algoritmalar, farklı spektral bant kombinasyonları kullanılarak eğitilmiştir. Bu kombinasyonlar içerisinde; RGB (kırmızı-yeşil-mavi), NirRG (yakın kızılötesi-kırmızı-yeşil), NDVI (normalleştirilmiş fark bitki indeksi) ve NDVIRG (NDVI-kırmızı-yeşil) kombinasyonları bulunmaktadır. Multispektral görüntüler, 30x30 cm yer örneklem aralığına sahip bir sayısal hava kamerası kullanılarak elde edilmiştir.

Sunulan proje kapsamında, Trabzon' un Hayrat ilçesinde bulunan çay alanları için Nisan 2013 yılına ait 25 adet 1:5000 ölçekli yüksek çözünürlüklü ortofoto görüntü kullanılmıştır. Kullanılan ortofoto görüntüler, kırmızı, yeşil, mavi ve yakın kızılötesi (RGBNir) olmak üzere 4 banta ve

her bant 8 bitlik radyometrik çözünürlüğe sahiptir. Kullanılan her bir ortofoto görüntünün yeryüzünde kapladığı alan 453.6 hektardır.

Sunulan proje, 15 (%60) görüntü eğitim, 10 (%40) görüntü ise test amaçlı kullanılmıştır. VGG19 ağ yapısına sahip SegNet mimarisi, farklı sayıya ve bant kombinasyonuna sahip eğitim verileri kullanılarak eğitilmiştir. Eğitim verileri 200x200 piksel boyutlarında 15 adet ortofoto görüntüden rastlantısal olarak seçilerek hazırlanmıştır. Sırasıyla 250, 400, 600 ve 1000 adet görüntü seti kullanılarak sistem eğitilmiş ve sonuçlar analiz edilmiştir. Önerilen yöntemin doğruluk analizi, fotogrametri operatörünce stereoskopik sayısallaştırma ile üretilen referans verilerinin, önerilen yöntemden elde edilen sonuçların karşılaştırılmasıyla gerçekleştirilmiştir. Değerlendirme, Sørensen-Dice Benzerlik Katsayısı algoritması kullanılarak yapılmış ve doğruluklar belirlenmiştir. Önerilen yöntem için, RGB, NirRG, NDVIRG ve NDVI için sırasıyla %90.91, %91.16, %91.51 ve %53.39 doğruluk değerlerine ulaşılmıştır. Geleneksel stereo sayısallaştırma ile karşılaştırıldığında, önerilen yöntem hem doğruluk hem işlem süresi bakımından daha etkili sonuçlar üretmektedir. Genel olarak, geleneksel stereoskopik değerlendirme işlemi, bir görüntü için yaklaşık olarak sekiz saat alırken, önerilen yöntem, aynı görüntü için ortalama beş dakikada sınıflandırma işlemini tamamlamaktadır.

Anahtar Kelimeler: Derin öğrenme, makine öğrenmesi, fotogrametri, SegNet, görüntü işleme, sınıflandırma

Abstract

This project presents a deep learning-based method for automatically classifying tea plantations from high-resolution aerial imagery, aiming to reduce the time and cost of traditional photogrammetric mapping used in Turkey since the 1940s. Manual stereo evaluation for identifying forest boundaries and tree species is labor-intensive, often taking up to 8 hours per image.

Using SegNet with a VGG19 backbone, the project classifies tea and non-tea areas from multispectral images (RGB, NirRG, NDVI, NDVIRG) with 30x30 cm resolution. The study was conducted in Hayrat, Trabzon, using 25 orthoimages from April 2013. Of these, 60% were used for training and 40% for testing. Models were trained with varying data sizes and evaluated using the Sørensen-Dice coefficient against stereoscopic reference data.

The proposed method achieved up to 91.51% accuracy (NDVIRG) and reduced processing time from 8 hours to 5 minutes per image, proving more efficient and accurate than traditional methods.

2. Proje Amacı

Sunulan çalışma kapsamında, haritalama ve görüntüden harita üretme işi, bilgisayar ortamına aktarıldığından bu yana, zaman ve maliyet açısından problem teşkil eden segmentasyon (sayısallaştırma) işini, derin öğrenme ve diğer görüntü işleme algoritmalarını kullanarak otomatize etmek amaçlanmıştır.

3. Projenin Kapsamı

Tarım alanlarının önemi, dolayısıyla planlanması ve korunması düşünüldüğünde bu alanlarda ekilecek ekin türü, sonrasında ise elde edilecek hasat miktarının değeri çok büyük önem kazanmıştır. Dolayısıyla tarım alanlarının planlaması yapılırken çok titiz bir çalışma sürdürülmesi gerekmektedir. Bu titiz çalışmada, ilgili tarım alanının ürün miktarı, gerçek coğrafi lokasyon ve doku bilgisi önemli parametrelerden olmaktadır. Sunulan projede çay bahçeleri baz alınarak bu parametrelere odaklanılmıştır. Dünya çapında tarım ve orman alanlarının, gelişen teknoloji ile hızlı bir şekilde işlenmesi ve buradan çıkan sonuçların alınacak kararlara etki etmesi için bilgisayar ortamına, sayısallaştırılarak aktarılması, gerçek hayatla ilişkisinin kurulması gerekmektedir. Bu işlemin manuel olarak el ile yapılması, toplam alan (Dünya 4.911.632 bin hektar (FAO,2014), Türkiye 37992 bin hektar (TÜİK 2017)) düşünüldüğünde hem çok büyük zaman kaybı hem de çok ağır maddi yük anlamına gelmektedir. Tarım alanlarının sayısallaştırılması ve analizi problemine, sunulan projede önerilen yöntem: R-G-B-NIR bantları barındıran ortofoto görüntülerin derin öğrenme algoritmaları temeline dayanarak ve farklı görüntü işleme yöntemlerinin paralel kullanılmasıyla, bilgisayar ortamında otomatik olarak olabildiğince hızlı bir şekilde sayısallaştırılmasını-vektörize edilmesini içermektedir. Proje kapsamında 1:5000 ölçekli, 4 kanallı (RGB-NIR), 8 bit radyometrik çözünürlük ve 30 cm yer örneklem aralığına sahip ortofoto görüntülerin kullanılması planlanmaktadır.

4. Projenin Hedef Kitlesi

Sunulan proje kapsamında üretilecek ürünlerin, işlenen bitki türüne göre konuyla ilgili tüm kamu kurumları ve özel sektör bünyesinde kullanılacağı öngörülmektedir.

5. Projenin Yöntemi ve Çalışma Planı

Sunulan proje, fikir aşamasından öteye taşınarak farklı bant kombinasyonlarında denemeler yapılmış ve klasik yöntemler ile karşılaştırıldığında %85-%92 aralığında doğruluk değerleri elde edilmiştir. 1:5000 ölçekli bir ortofoto görüntü için klasik yöntemler, ~10 saatlik bir işlem zamanı gerektirirken, eğitilmiş bir derin öğrenme ağından sonuçlar, ~5 dakikalık bir süre içerisinde alınmıştır. Diğer bir deyişle, süreç 120 kat hızlandırılmıştır. Sonuç ürün olarak, CBS (coğrafi bilgi sistemleri) ile uyumlu olan ve gerçek coğrafi lokasyon bilgisini barındıran sınırvektör verileri, alan ve doku bilgileri üretilmiştir. Aynı zamanda, üretilen verilerin CBS'ye altlık oluşturmasıyla bilginin sürekliliğinin sağlanacağı öngörülmektedir. Bu ürünlerin tarım alanlarının değişim analizlerinde, rekolte tahmininde, planlanmasında, izlenmesinde, kontrolünde ve zirai ürünlerin vergilendirilmesi ve meşçere haritaların üretimi gibi amaçlar doğrultusunda kullanılabileceği ve iş fikrinin hassas tarım uygulamalarında direkt olarak yer edineceği, büyük bir katkı sağlayacağı öngörülmektedir. Ek olarak, eski tarihli ortofotolardan yola çıkarak geçmiş, günümüz ve gelecek hakkında analizlerin yapılması öngörülmektedir. Sunulan proje kapsamında üretilcek ürünlerin, işlenen bitki türüne göre konuyla ilgili tüm kamu kurumları ve özel sektör bünyesinde kullanılacağı öngörülmektedir.

6. Beklenen Sonuçlar

6.1. Proje Çıktısı

Ortofoto görüntülerden tarım alanlarının otomatik çıkartılması ve sınırlarının belirlenmesi için derin öğrenme algoritmaları temeline dayanan görüntü işleme yazılımı.

6.2. Yan Çıktılar

İlgili tarım alanına dair, otomatik olarak üretilen, coğrafi bilgi sistemleri (CBS) ile uyumlu olan ve gerçek coğrafi lokasyon bilgisini barındıran sınır vektör verileri, alan ve doku bilgileri yan çıktıları oluşturmaktadır. Ek olarak, derin öğrenme ağları için veritabanı (eğitim görüntüleri, eğitilmiş ağ verileri) da yan çıktılar arasında bulunmaktadır.

6.3. Hizmetler

Tarım alanlarının değişim analizi, rekolte tahmini, planlanması, izlenmesi, kontrolü ve zirai ürünlerin vergilendirilmesi ayrıca meşçere haritalarının üretimi gibi alanlarda hizmetlerin verilebileceği öngörülmektedir. Ek olarak, kamu ve özel sektörün elinde bulundurduğu eski tarihli ortofoto görüntüleri için de yazılımın uygun hale getirilmesi öngörülmektedir. Bu sayede, geçmiş, günümüz ve gelecek hakkında analizlerin sağlanabileceği düşünülmektedir.

7. Proje Bütçesi

Personel, ekipman, malzeme, seyahat vb. tüm giderler hesaba katıldığında 267 160 \$ bütçe ile proje tamamlanabilmektedir. Giderlerin detayları Tablo 1 de sunulmuştur.

Tablo 1 Proje gider detayları


Gider Tanımı	Adet	Birim Fiyatı (\$)	Ödeme Sayısı	Toplam Maliyet (\$)
Bilgisayar	5	1920	1	9600
IHA (DJI Matrice 350 RTK)	2	8780	1	17560
Personel Giderleri	5	2500	18	225000
Tanıtım ve Reklam	1	5000	3	15000
Toplam Giderler				267 160

Proje giderlerinin 1507 sanayii iş birliği, KOSGEB desteği veya daha küçük ölçekte 1512 girişim projeleri destekleri ile karşılanması öngörülmektedir.

8. Riskler ve Önlemler

8.1. Kullanılacak Veri Yapısı B Planı:

Sunulan çalışmada, kırmızı-yeşil-mavi, yakın kızılötesi-kırmızı-yeşil bant kombinasyonları ve NDVI (normalized difference vegetation index) (normalleştirilmiş fark bitki indeksi), NDVIkırmızı-yeşil yapay görüntüleri kullanılacağından dolayı veri yapısı için 3 tane B planı bulunmaktadır. Kullanılması planlanan görüntü verilerinin örnek görselleri; Şekil 1, segmente edilmiş objeleri barındıran örnek görsel Şekil 2 ve nihai ürün görseli de Şekil 3 de sunulmuştur.



Şekil 1 Eğitim ve test süreçlerinde kullanılan örnek görüntüler, a) RGB görüntü, b) NIRRG görüntü, c) NDVIRG görüntü, d) NDVI görüntü



Şekil 2 Segmente edilmiş obje görüntü örneği



Şekil 3 Nihai coğrafi sınırları belirlenmiş tarım alanı örnek görseli

8.2. Algoritma B Planı:

Derin öğrenmenin tarım alanlarının sayısallaştırılması işinde kullanılabileceğine dair test aşamasını hâlihazırda yapmış olmamıza ve %92 oranında doğruluk elde etmiş olmamıza rağmen, herhangi bir problem çıkması durumunda sürecin yapay sinir ağları ya da farklı bir makine öğrenme algoritması ile devam ettirilmesi planlanmaktadır.

9. Proje Süresi

Projenin tüm iş akışlarının, prototip ve pilot üretimlerin test süreçleri ile beraber tamamlanması için 18 aylık bir zamana ihtiyaç duyulmaktadır.

10. Kaynaklar

Tarım alanlarının analizi ve planlanması dünyanın her yerinde büyük önem taşıdığından, planlama ve analiz üzerine birçok çalışma gerçekleştirilmiştir. Tabb ve Medeiros (2017), süperpiksel tabanlı bir yaklaşımla, elma ağacı çiçeğinden yola çıkarak tarım alanlarının segmentasyonunu gerçekleştirmişlerdir [1]. Joycy ve Prabavathy (2012), bulanık kümeleme ve eşik değer mantığını benimseyerek tarım alanlarının doku analizi üzerine çalışmalar gerçekleştirmiştir. [2]. Ünal vd. (2010), Giresun ilinde fındık ağaçlarının otomatik sınıflandırılması için IKONOS ve QUICKBIRD uydu görüntüleri kullanarak, kontrollü sınıflandırma ile fındık ağaçlarını sınıflandırmışlardır [3]. Rahimzade (2015), yüksek çözünürlüklü uydu görüntüleri üzerinde otsu eşik değer algoritması temeline dayanan bir yaklaşımla, tarım alanlarının alan bazlı sınıflandırması üzerine çalışmalar gerçekleştirmiştir [4]. Guijarro vd. (2011), tarım alanlarındaki dokuları, yoğunluk değişimi, eşik değer ve bulanık kümeleme yöntemleri ile sınıflandırmışlardır. [5]. Wang vd. (2010) yapmış oldukları çalışmada, K ortalamalar yöntemi temeline dayanan, nesne tabanlı yeni bir sınıflandırma algoritması sunmuşlardır. SPOT5 ve QUICKBIRD uydu görüntüleri kullanılan çalışmada, Güney Afrika’daki arazi örtüsünün sınıflandırma işlemi hem sunulan algoritmaya göre hem de eCognition programına göre yapılmış ve sonuçlar analiz edilmiştir [6].

Günümüze dek, derin öğrenme algoritmaları kullanılarak yapılan çalışmalar incelendiğinde, algoritmanın, daha çok obje tanıma amaçlı uygulamalarda kullanıldığı gözlemlenmiştir. Buna örnek verilecek olursa, Krizhevsky vd., (2012), derin konvolüsyonel nöral ağlar ile ImageNet verileri içerisinde sınıflandırma çalışmalarını gerçekleştirmiş ve %15.3’lük hata yüzdesiyle çalışmalarını tamamlamışlardır [7]. Bir başka çalışma olan, Eitel vd. (2015), derin öğrenme algoritmalarının eğitimi ve analizi için büyük bir sıkıntı olan 3 bant veri seti sınırlamasını aşmaya çalışmış ve 4. veri olarak yoğunluk verisini kullanmıştır. Daha sonra eğitilen ağı nesne

tanıma için farklı yapılarda denemiş ve %84.7' lere varan doğruluklara ulaşmıştır [8]. Zhou vd. (2014)' te yapılan çalışmada, görüntü veri kümelerinin yoğunluğu ve çeşitliliğini karşılaştırmak için konvolüsyonel nöral ağları kullanmışlardır. Ağın eğitimi için ilgilendikleri alanların 7 milyondan fazla etiketli verilerini kullanmış ve bu eğitim sonucuna göre mekanların tahmin edilmesi üzerine çalışmalar gerçekleştirmişlerdir [9]. Obje tanımadan farklı olarak, semantik segmentasyon için, daha seyrekte olsa, derin öğrenme algoritmalarının kullanıldığı çalışmalar da saptanmıştır. Bu çalışmalara örnek olarak, Long vd. (2015), derin öğrenme algoritmalarında, tam konvolüsyonlu ağ yapısını (Fully Convolutioanal Network), AlexNet, Vgg net, GoogLeNet gibi sınıflandırma ağlarına adapte ederek tam konvolüsyonlu ağların semantik segmentasyon için nasıl sonuçlar verdiğini, farklı yapılar ve programlardan gelen sonuçların karşılaştırılmasıyla analiz etmişlerdir [10]. Fu vd. (2017) ise çalışmalarında, tam konvolüsyonlu ağ yapısına dayanan yüksek çözünürlüklü uzaktan algılama görüntüleri için kesin bir sınıflandırma yaklaşımı önermişlerdir. Çalışmalarında ilk olarak, Atrous konvolüsyonunu kullanarak çıktı haritalarının yoğunluğu iyileştirilmiş ve ikinci olarak ise çok çözünürlüklü görüntü sınıflandırması yapabilmek için bir atlama katmanı yapısı ekleyerek çok ölçekli bir ağ mimarisi tasarlamışlardır. Son olarak, çıktı sınıf haritasına, Şartlı Rastgele Alanlar (CRFs) algoritmasını kullanarak son işleme adımını gerçekleştirmişlerdir ve ortalama doğruluk, hatırlama ve kappa katsayısını sırasıyla 0.81, 0.78, 0.83 bulmuşlardır [11]. Shi vd. (2017)' nin yapmış oldukları çalışmada, deniz ve kara segmentasyonunda karşılaşılan yüksek korelasyondan kaynaklanan problemleri aşmak ve bunun yanında denizdeki gemileri (limandakiler de dahil olmak üzere) de segmente etmek için deniz, kara ve gemileri kapsayacak şekilde semantik bir etiketleme kullanarak eğitilen yeni bir tam konvolüsyonlu ağ yapısı önerilmektedir. [12]. Son olarak ise sunulan proje kapsamında kullanılan SegNet mimarisini direkt baz alan Kendall vd. (2015)' nin yaptığı çalışmada, CamVid' den sağlanan sokak ve iç mekân SUN RGB-D görüntüleri kullanılarak semantik segmentasyon işlemi gerçekleştirilmiştir. Buradan elde edilen sonuçlar derin öğrenme algoritmalarında çok yaygın olarak kullanılan tam konvolüsyonlu ağlar (FCN), DeepLab-LargeFOV ve DeconvNet mimarileriyle karşılaştırılmıştır. Yapılan nicel gözlemler, SegNet mimarisinin diğer mimarilere kıyasla rekabetçi çıkarım süresine ve en etkili çıkarımlara sahip olduğunu göstermiştir [13].

11. Değerlendirme Kriterleri

Klasik yöntemler ile derin öğrenme açısından elde edilen sonuç ürünlerin ortalama minimum %85 oranında sınır, alan ve genel benzerlik göstermesi beklenmektedir. Ek olarak, vektörize

etme ve analiz sürecinin, klasik / operatör bazlı gerçekleştirilen sayısallaştırma / vektörize etme işlemlerinden ~120 kat daha hızlı bir şekilde ~5 dakika içinde tamamlanması ve dolayısıyla, maliyetin de %90 oranında azalması beklenmektedir.

12. Sonuç

Tarım ve orman alanlarının otomatik segmentasyonu çevresel şartlar, iklim değişikliği, süreç yönetimi ve kaynak kullanımı açısından önemlidir.



13. Kaynakça

- [1] Tabb, A. ve Medeiros, H., (2017). “Automatic Segmentation of Objects in Dynamic Outdoor Environments”, arXiv:1702.07611v2 [cs.CV] 16 Oct 2017
- [2] Joycy, S. ve Prabavathy, K., (2012). “Survey on Automatic Segmentation of Relevant Textures in Agricultural Images”, IEEE, 978-81-909042-2-3 [3] Ünal, E., Aydoğdu, M., Ceylan, N., Sezer, A., Özenç, N. ve Duyar, Ö., (2010). “Giresun İlinde Fındık Alanlarının Uzaktan Algılama ile Tespit Edilmesinde Arazi Topoğrafyasının Etkisinin İncelenmesi ve Alternatif Tarım Ürünlerinde Uygunluğunun Belirlenmesi”, Tarla Bitkileri Merkez Araştırma Enstitüsü Dergisi, 2010, 19 (1-2):1-10
- [4] Rahimzadeganasi, A., (2015). An Approach for the Automatic Segmentation of High Resolution Satellite Images into Agricultural Fields. Yüksek Lisans Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- [5] Guijarro, M., Pajares, G., Riomoros, I., Herrera, P.J., Artizzu, X.P.B. ve Ribeiro, A., (2011). “Automatic Segmentation of Relevant Textures in Agricultural Images”, Computers and Electronics in Agriculture 75(1):75–83
- [6] Wang, Z., Jensen, J.R. ve Im, J., (2010). “An Automatic Region-Based Image Segmentation Algorithm for Remote Sensing Applications”, Environmental Modelling & Software, 25 (10): 1149-1165
- [7] Krizhevsky, A., Sutskever, I. ve Hinton, G. E. (2012). “Imagenet classification with deep convolutional neural networks”, In Advances in neural information processing systems (pp. 1097-1105).
- [8] Eitel A, Springenberg J. T., Spinello L., Riedmiller M. ve Burgard W. (2015). “Multimodal Deep Learning for Robust RGB-D Object Recognition”, 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Congress Center Hamburg, Sept 28 - Oct 2, 2015. Hamburg, Germany
- [9] Zhou, B., Lapedriza, A., Xiao, J., Toralba, A. ve Oliva, A., (2014). “Learning Deep Features for Scene Recognition using Places Database”, Neural Information Processing Systems Conference,
- [10] Long J., Shelmaer E. ve Darrell T., (2015). “Fully Convolutional Networks for Semantic Segmentation”, The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015, pp. 3431-3440
- [11] Fu, G., Liu, C., Zhou, R., Sun, T. ve Zhang, Q., (2017). “Classification for High Resolution Remote Sensing Imagery Using a Fully Convolutional Network”, Remote Sensing. Remote Sens. 2017, 9, 498; doi:10.3390/rs9050498
- [12] Lin, H., Shi, Z. ve Zou, Z., (2017). “Maritime Semantic Labeling of Optical Remote Sensing Images with Multi-Scale Fully Convolutional Network”, Remote Sensing. Remote Sens. 2017, 9, 480; doi:10.3390/rs9050480

- [13] Badrinarayan, V., Kendall, A. ve Cipolla, R., (2015). “SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation”, arXiv preprint arXiv:1511.00561, 2015.

