

# Derin Öğrenmenin Temel Prensipleri ve Uzaktan Algılama Alanındaki Uygulamaları

## (Basic Principles of Deep Learning and Its Applications in Remote Sensing)

Elif Özlem YILMAZ , Taşkın KAVZOĞLU 

Gebze Teknik Üniversitesi, Harita Mühendisliği Bölümü, Gebze, Kocaeli  
eoyilmaz@gtu.edu.tr, kavzoglu@gtu.edu.tr

Geliş Tarihi (Received): 07.01.2021

Kabul Tarihi (Accepted): 12.07.2021

### ÖZ

Günümüzde, derin öğrenme mimarilerinin uzaktan algılama uygulamalarında kullanımı her geçen gün daha yaygın hale gelmektedir. Geleneksel yöntemlerle karşılaştırıldığında, uzaktan algılanmış verilerin işlenmesinde derin öğrenme modellerinin daha başarılı sonuçlar ürettiği görülmektedir. Bu modeller, bilgisayar donanımlarının gelişimine paralel olarak özellikle görüntü işleme alanında sıklıkla tercih edilmektedir. Derin öğrenme yaklaşımının uygulanması esnasında insan müdahalesinin minimum seviyede olması, nesne tespiti ve sınıflandırma gibi karmaşık problemleri çözebilmesi ve yüksek çözünürlüklü uydu görüntülerinin işlenmesindeki etkinliği gibi önemli avantajları bulunmaktadır. Ancak, derin öğrenme modellerinin eğitimi için etiketlenmiş büyük veri seti ihtiyacı ise önemli bir problem olarak karşımıza çıkmaktadır. Bu veri setlerinin yüksek doğrulukla oluşturulabilmesi zaman ve iş yükü gerektirmektedir. Bu çalışmada, bir derin öğrenme modeli olan evrimsel sinir ağı mimarisine ait evrişim, ortaklama, düzleştirme ve seyreltme katmanları ayrıntılı bir şekilde açıklanmıştır. Ayrıca, derin öğrenme mimarisini etkileyen harekete geçirme ve maliyet fonksiyonlarının çalışma prensipleri detaylı şekilde sunulmuştur. Ayrıca, uzaktan algılamada derin öğrenme mimarilerinin kullanımı; ön işleme, görüntü sınıflandırma, nesne tespiti, görüntü yorumlama ve diğer uygulama alanları başlıkları altında irdelenmiştir. Sonuç olarak, derin öğrenmenin güncel uzaktan algılama literatüründeki yeri ve önemi ortaya koyularak güncel literatür özeti de sunulmuştur.

**Anahtar Kelimeler:** Uzaktan Algılama, Derin Öğrenme, Evrimsel Sinir Ağları, Sınıflandırma, Görüntü İşleme.

### ABSTRACT

Today, the use of deep learning architectures in remote sensing applications is becoming more and more common every day. Compared to traditional methods, deep learning models appear to produce more successful results in the processing of remotely detected data. These models are often preferred, especially in the field of image processing, in parallel with the development of computer hardware. The deep learning approach has important advantages such as the minimum level of human intervention during its implementation, the ability to solve complex problems such as object detection and classification, and its effectiveness in processing high-resolution satellite images. However, the need for a large data set labeled for training deep learning models is a major problem. Creating these data sets with high accuracy requires time and workload. In this study, convolution, pooling,

flattening, and dropout layers, which are main components of convolutional neural networks, a deep learning model, are described in detail. In addition, the principles of activation and cost functions affecting deep learning architecture are presented. In addition, the use of deep learning architectures in remote sensing has been studied under the headings of preprocessing, image classification, object detection, image interpretation and other application areas. As a result, the place and importance of deep learning in the current remote sensing literature is reviewed and the current literature summary is also presented.

**Keywords:** Remote Sensing, Deep Learning, Convolutional Neural Networks, Classification, Image Processing.

### 1. GİRİŞ

Yapay zekanın bir alt kümesi olan makine öğrenme yaklaşımı günümüzde birçok alanda yaygın olarak tercih edilmektedir. Bu yaklaşım, mühendislik alanında görüntü/video işleme, nesne tespiti ve görüntü sınıflandırma uygulamalarının yanında sağlık, ekonomi, savunma ve güvenlik gibi birçok sektörlerde kullanılmaktadır. Makine öğrenmesi yaklaşımı, veriler içindeki ilişkileri öncül bir tanımlamaya gerek duymadan belirlemek için matematiksel yöntemleri kullanan bir sistem olarak tanımlanmaktadır (Schwalbe, 2019). Son yıllarda, makine öğrenmesinin bazı karmaşık problemlere çözüm üretememesi, fazla insan müdahalesi gerektirmesi ve az miktarda veri ile işlem yapamaması gibi zayıf yönlerinin giderilmesi için araştırmalar yapılmaktadır (LeCun, Bengio ve Hinton, 2015; Zhang, Zhang, ve Du, 2016; Ma ve diğerleri, 2019). Derin öğrenme yaklaşımı da belirtilen dezavantajların önüne geçilmesi için birçok uygulamada kullanılmaktadır (Ball, Anderson ve Chan, 2017; Li ve diğerleri, 2018). Uzaktan algılamada kullanılan algılama sistemlerinin çeşitliliği (farklı çözünürlük ve algılayıcı kullanılması) ve anlık veri toplanabilmesi sebebiyle, büyük hacimli veri elde edilmektedir. Bu tür verilerin işlenmesinde derin öğrenme yöntemlerinin kullanılması çoğunlukla diğer yöntemlere göre daha başarılı sonuçlar vermektedir (Ma ve diğerleri, 2015; Zhang, Zhang ve Du, 2016; Sofu, Imamoglu, Kahraman, Cetin ve Aptoula, 2020; Suresh ve diğerleri, 2020). Az sayıda çalışmada ise makine öğrenme algoritmalarının derin öğrenme metotlarından

daha iyi sonuçlar verdiği tespit edilmiştir (örn. Dong ve diğerleri, 2020). Makine öğrenme ve derin öğrenme metodlarının bir arada kullanılması ile çalışmalarda elde edilen doğrulukların arttığı da rapor edilmiştir (Han, Ma, ve Chen, 2019). Bu nedenle, uzaktan algılama uygulamalarında derin öğrenme mimarileri sıklıkla tercih edilmekte ve diğer yöntemlere göre daha yüksek doğruluğa sahip sonuçlar vermektedir.

Derin öğrenme kavramının daha iyi bir şekilde anlaşılması için ilk olarak geçirdiği tarihsel gelişimin incelenmesi gerekmektedir. 1943 yılında McCulloch ve Pitts tarafından insan beyninin çalışma prensibini anlamak için nöronların birbirleri ile olan bağlantıları incelenerek, bir nöronun ilk matematiksel modeli oluşturulmuştur (McCulloch ve Pitts, 1943). Aynı yıl sinir ağının içerdiği parametrelerin değişebileceği üzerine bir çalışma gerçekleştirmiş ve nöronların öğrenme işlemini gerçekleştirebileceğine dair ilk fikri ortaya atmıştır (Hebb, 1943). Rosenblatt (1958)'de ise tek katmanlı algılayıcıyı, doğrusal sınıflandırma amaçlı çalışmalar için kullanılabileceğini gösterilmiştir. Bu çalışma, çok katmanlı algılayıcılara öncül bir çalışma olarak literatürdeki yerini almıştır. Tek katmanlı algılayıcıya göre daha gelişmiş bir öğrenme metoduna sahip bir algılayıcı modeli Windrof ve Hoff (1960) tarafından sunulmuştur. Burada kullanılan öğrenme metodu, nöronlara ait ağırlıkları güncelleyen bir türev (gradyan) iniş yöntemi içermektedir. Bu yaklaşımların ÖZELVEYA (XOR) problemlerinin çözülmesi için yetersiz kaldığı belirlenerek kontrolsüz öğrenmenin temelleri atılmıştır (Minsky ve Papert, 1970). (Fukushima, 1980) ise görsel örüntü tanıma işlemi için çok katmanlı bir sinir ağı kullanmış ve Evrimsel Sinir Ağları fikrini ortaya atmıştır. 1982 yılında ise günümüzde kullanılan tekrarlayan sinir ağlarının atası olan Hopfield Ağı tanıtılmıştır (Hopfield, 1982). LeCunn (1989) tarafından geri yayılım prensibini kullanarak el yazısı ile yazılmış rakamları tahmin edebilen geri yayılım algoritması ile çalışan bir evrimsel sinir ağı modeli tasarlanmıştır. Daha sonra, geri yayılım algoritmasının sinir ağlarını eğitmede yetersiz kalması ve hibrit öğrenme yöntemlerinin kullanılabilmesi amacıyla, yeni sinir ağ türlerini araştırma çalışmaları hız kazanmıştır. Günümüzde ise, derin öğrenmenin problemlerinden biri olan optimizasyon gibi problemlerin yanında, bilgisayar teknolojisinin gelişmesi ile üretilen modellerin içerikleri ve öğrenme hızlarının da geliştiği gösteren çalışmalar gerçekleştirilmiştir (Ghamisi, Chen ve Zhu, 2016; Li, Zhan, Huang, Wang ve Zheng, 2016; Luus, Slamon, Van Den Berg ve Maharaj, 2015). Ayrıca, oluşturulan derin öğrenme

modeline ait ağıncü küçültülmesi üzerine birçok araştırma yapılmaktadır. Bu çalışmalardan biri büyük boyuttaki sinir ağlarının küçültülmesi işlemidir (Sildir, Aydın ve Kavzoglu, 2020). Ağıncü küçültülmesiyle yapılan görüntü sınıflandırma uygulamalarında modelin performansının anlamlı seviyede arttığı belirlenmiştir (Kavzoglu ve Mather, 1998, 1999). Bu alanlarda yapılmış uluslararası çalışmaların yanında, Türkiye'de de uzaktan algılama alanında derin öğrenme yöntemi kullanılarak yapılan çalışmalar bulunmaktadır (Tuna, Ünal, ve Sertel, 2018; Erdem, Bayram, Bakirman, Bayrak ve Akpınar, 2021; Özçelik, Algancı, Sertel, ve Ünal, 2021; Wang, Algancı, ve Sertel, 2021).

Derin öğrenme yaklaşımı, canlılara ait öğrenme mekanizmasını taklit eden bir yapıya sahiptir (Wang ve Raj, 2017). Buradaki öğrenme işlemi, öğrenen modelin belirli bir görevi yerine getirmesi için modele ait parametrelerin tahmin edilmesi yoluyla gerçekleşir. Literatürde farklı derin öğrenme yaklaşımları mevcuttur. Bu yaklaşımlar; kontrollü, kontrolsüz ve hibrit öğrenme çeşitleri olarak adlandırılmaktadır (Schmidhuber, 2015; Salman, Grover, ve Shankar, 2018). Kontrollü öğrenme, etiketli verilerin kullanılması ile gerçekleştirilen bir öğrenme metodu iken, kontrolsüz öğrenme ise veriye ait öncül bir bilgi olmadan yapılan öğrenme yaklaşımıdır. Hibrit öğrenme metodu da kontrollü ve kontrolsüz öğrenme işlemlerinin birlikte kullanılmasıyla uygulanan bir öğrenme yaklaşımıdır (Alom ve diğerleri, 2019). Derin öğrenme yapıları geleneksel yapay sinir ağlarının geliştirilmiş bir versiyonu olarak değerlendirilebilir. Yapay sinir ağlarına ait sinir hücreleri girdi, gizli ve çıktı katmanlarının bir araya gelmesi ile oluşmaktadır. Tahmin edilen çıktı ile olması gereken çıktı arasındaki bağlantı ise geri yayılım metodu ile kurulur. Bu metod, sinir ağına ait parametrelerin türevinin hesaplanmasını sağlar ve ardından çıktı katmanından girdi katmanına doğru türevini hesaplayarak modelin öğrenme işlemine yardımcı olur (Kavzoglu ve Mather, 2003). Derin öğrenme modelinin gizli katman sayısının artması, modelin daha da derinleştiğinin göstergesi olduğu için derinlik kavramı kullanılmaktadır. Üçten fazla katmandan oluşan yapay sinir ağları derin öğrenme yönteminin temelini oluşturmaktadır.

Her yaklaşımda olduğu gibi derin öğrenme yaklaşımının da üstün ve zayıf yönleri bulunmaktadır. Karmaşık problemleri çözebilmesi, öğrenme işleminde kullanıcı faktörünün en aza indirmesi, büyük veride iyi performans gösterebilmesi, öğrenme işleminin kontrol edilebilmesi ve problemi çözmek için karşısına


çıkan yeni sorunlara karşı adapte olabilmesi bu yaklaşımın en önemli üstün yönleridir (Claesson ve Hansson, 2017; Vali, Comai ve Matteucci, 2020). Öte yandan, derin öğrenme ağları göreceli olarak daha büyük ağlar olduğundan eğitim için daha çok veriye ihtiyaç duyması, kullandığı teknolojinin pahalı olması (özellikle yüksek Graphics Processing Unit (GPU) gereksinimi), kara kutu prensibi ile çalışması ve modele ait mimarinin oluşturulmasının zorlu bir süreç gerektirmesi, olumsuz yönleri olarak ifade edilebilir (Yue, Zhao, Mao ve Liu, 2015; Ball, Anderson ve Chan, 2017; Parvat, Chavan, Kadam, Dev ve Pathak, 2017).

2014 yılından itibaren uzaktan algılama alanında derin öğrenme konusunda yapılan çalışmalarda ciddi bir artış görülmektedir. Bu durumun temel nedeni, farklı algılayıcılarla elde edilmiş veya farklı özelliklere sahip uzaktan algılanmış veri çeşitlerinin artması ile bu verileri değerlendirilebilmesi için derin öğrenme gibi güçlü bir yaklaşıma ihtiyaç duyulmasıdır (Zhu ve diğerleri, 2017; Zhang ve diğerleri, 2016). Bu çalışmada, derin öğrenme yönteminin uzaktan algılama alanındaki kullanımları literatürdeki çalışmalara desteklenerek sunulmuştur. Bu çalışmanın amacı, derin öğrenme yöntemini detaylı şekilde açıklayarak uzaktan algılama alanında derin öğrenme yöntemi kullanılarak yapılmış hem ulusal hem de uluslararası önem arz eden araştırmaların derlenmesidir. Bu çalışmada, derin öğrenmenin uzaktan algılama alanında kullanımı beş başlık altında incelenmiştir.

## 2. EVRİŞİMSSEL SİNİR AĞLARI

Evrışimsel sinir ağları (ESA) görüntü bölütleme ve sınıflandırması, nesne tespiti (araç, gemi, uçak, bulut, bina sel alanları), görüntü birleştirme,

konuşma tanıma ve görüntü/video işleme gibi amaçlarla kullanılan çok katmanlı özel bir sinir ağı türüdür (Abdel-Hamid ve diğerleri, 2014; Ren, He, Girshick, ve Sun, 2017; Qing, Ruan, Xu, Ren ve Zabalza, 2019; Zhang, Zhang ve Li, 2020). Evrışimsel filtre içeren katmanlara sahip olması bu sinir ağını diğer ağ türlerinden ayıran en temel özelliktir (Khan, Rahmani, Shah ve Bennamoun, 2018). Bu sinir ağı yapısı ilk olarak Fukushima tarafından önerilmiştir (Fukushima, 1980). Ancak, sinir ağı yapısının eğitimi için kullanılan hesaplamaların sınırlı olması nedeniyle yaygın olarak kullanılmamıştır. 1990'lı yıllardan ESA'ya türev tabanlı öğrenme algoritması uygulanmış ve bu sinir ağı türüyle yapılan çalışmalarda başarılı sonuçlar elde edilmiştir (LeCunn, 1989). ESA yapısının insana ait görsel işleme sistemine çok fazla benzerlik göstermesinin yanında, 2 boyutlu ve 3 boyutlu görüntüleri işleyebilme kabiliyetinin olması diğer sinir ağlarına göre avantaj sağlamaktadır. ESA modelleri, türev tabanlı bir algoritma ile çalışmaktadır ve yüksek düzeyde optimize edilmiş ağırlıklar üretme kabiliyetine sahiptirler (Alom ve diğerleri, 2019). Evrışimsel sinir ağına kullanılan diğer bir önemli faktör ise üstün parametre (hiperparametre) seçimidir. Derin öğrenme algoritmalarında kullanılan üstün parametre kavramı modelin kendisini ve çalışmasını etkileyen birçok parametreyi içermektedir. Bu parametrelerin modelin eğitiminden önce ayarlanması gerekmektedir. Modelin mimarisi içinde kullanılan üstün parametrelerden başlıca olanlar, gizli katman sayısının belirlenmesi, modelde kullanılan başarımların iyileştirme tekniklerinin uygulanması, yapılacak uygulama için uygun modelin seçimi ve harekete geçirme (aktivasyon) fonksiyonlarının tanımlanmasıdır.



Şekil 1. Evrışimsel sinir ağı modeli.

Modelin eğitimi aşamasında ise öğrenme hızı, sönüm parametresi, iterasyon sayısı, maliyet fonksiyonu, küme boyutunun (batch size) belirlenmesi, epok sayısı gibi modelin optimizasyonunu sağlayan parametreler örnek olarak gösterilebilir (Demyanov, 2015; Koutsoukas, Monaghan, Li, ve Huan, 2017). Bu parametreler eğitim aşamasında ayarlanabilirler ancak güncellenmezler. Derin öğrenme modellerinin çalışabilmesi için modele ait üstün parametrelerin ayarlanması gerekmektedir. Belirlenen optimum üstün parametreler, modelin tüm öğrenme sürecini etkilemektedir. Bu nedenle, bu üstün parametrelerin modelin eğitiminden önce ayarlanması gerekmektedir. Türev tabanlı optimizasyon algoritmaları, özellikle uzaktan algılama uygulamalarında üstün parametrelerin optimizasyonunda yaygın olarak kullanılmaktadır (Yuan ve diğerleri, 2019; He, Zhang, Ren ve Sun, 2016).

ESA modelleri, evrişim katmanı, yoğunlaştırma katmanı, harekete geçirme katmanı dahil olmak üzere temel katmanlardan oluşmaktadır. ESA mimarisi evrişimsel katmanın yanında normalleştirme, ortaklama, seyreltme gibi başka katmanlar da içeren ileri beslemeli sinir ağıdır. Literatürde hâlihazırda kullanılan birçok popüler evrişimsel sinir ağı mimarisi mevcuttur. Bilinen hazır ESA mimarilerine örnek olarak, LeNet (LeCun, Bottou, Bengio ve Haffner, 1998), AlexNet (Krizhevsky, Sutskever ve Hinton, 2017), VGGNet (Simonyan, ve Zisserman, 2015), GoogLeNet (Szegedy ve diğerleri, 2015), ResNet (He, Zhang, Ren, ve Sun, 2016) ve DenseNet (Huang, Liu, Van Der Maaten ve Weinberger, 2017) verilebilir. Yapılacak çalışmanın amacına bağlı olarak farklı türde ESA mimarisi oluşturulması mümkündür. ESA mimarisi genel olarak, özellik çıkartma ve sınıflandırma olmak üzere iki ana bölümden oluşmaktadır. ESA'ların en önemli avantajlarından biri, büyük ölçekte verilere ait özelliklerin çıkartılması aşamasında kullanılmalarıdır (Khan, Sohail, Zahoora ve Qureshi, 2020). Bu mimariler, uzaktan algılamada hem kontrollü hem de kontrolsüz öğrenme algoritmaları ile görüntü sınıflandırma uygulamalarında yaygın olarak tercih edilmektedir (Chen ve diğerleri, 2021).

### a. Evrişimsel Katman

Evrişimsel katman, veriye ait özellik haritasını oluşturmak için kullanılan evrişimsel filtreyi içeren mimarinin en temel katmanıdır. Eğitim sırasında evrişimsel filtrelerin ağırlıkları ilk aşamada rastgele seçilir ve derin öğrenme modelinin içinde matematiksel işlemlerde kullanılır. Bu filtreler tüm

veri boyunca hareket ederek veriye ait bir özellik haritası çıkarır. Şekil 1'de evrişimsel filtrenin girdi verisine nasıl uygulandığı gösterilmiştir.

Evrişimsel katmanın 1 boyutlu, 2 boyutlu ve 3 boyutlu olmak üzere farklı boyutta çeşitleri mevcuttur. Bir boyutlu evrişimsel katman, tek boyutlu veriler veya zamansal verilerin analizi için kullanılan basit bir ağ çeşididir. Bu ağ türü görüntülerde ise spektral analizlerde kullanılır. Bu evrişimsel katmanı içeren modeller, girdi verisi olarak bir boyutlu vektörel yapıları kullanırlar. Bu katman, görüntülerde piksel tabanlı analiz yaparken çok ölçekli bir şekilde çalışarak görüntü bantları arasındaki piksellere ait karşılıklı bilgileri araştırmak için tercih edilmektedir (Song ve diğerleri, 2019). Ayrıca bu katmanı içeren modellerde işlem süresi kısalmaktadır. Örneğin; hiperspektral görüntü kullanan uygulamalarda 1 boyutlu katman, spektral analiz yaparken sadece derinlemesine spektral bilgilere odaklanır (Liu, Li, Li, ve Liu, 2019).

İki boyutlu evrişimsel katman, uydu görüntüleri gibi 2 boyutlu verilerin analizi için kullanılır. Bu katman içindeki evrişimsel filtreler görüntünün hem enine hem de boyuna olacak şekilde hareket eder. İki boyutlu evrişimsel katman, özellikle görüntülerde kullanıldığında görüntüye ait mekânsal-spektral özellikleri öğrenebilen bir katmandır. Bu katman, görüntüdeki piksellerin hem parlaklık değerlerini hem de diğer pikseller ile olan komşuluk ilişkilerini kullanarak mekânsal-spektral özellikleri çıkartmaktadır (Audebert, Le Saux ve Lefevre, 2019). Ayrıca bu filtreler hiperspektral gibi küp veri setlerine (3 boyutlu veri) uygulandığında çıktı olarak 2 boyutlu bir özellik haritası oluşmaktadır (Garcia-Garcia ve diğerleri, 2018). Üç boyutlu evrişimsel katmanlar ise video işleme, hiperspektral görüntüler ve LiDAR nokta bulutu gibi büyük boyutlu verilerin değerlendirilmesinde kullanılmaktadır (Li ve diğerleri, 2019).

Üç boyutlu evrişimsel katman ise genellikle mekânsal-zamansal verilerin ayırt edici özelliklerin analizinde tercih edilmektedir. Bu katman ile özellikle uzaktan algılama uygulamalarında dinamik ve zamansal bilgi çıkarımı yapılabilir (Ji, Zhang, Xu, Shi ve Duan, 2018). Üç boyutlu evrişimsel katman, 2 boyutlu evrişimsel katmanın genişletilmiş halidir. Ancak, bu katman kullanılarak oluşturulmuş derin öğrenme modellerinin eğitim işlemi diğer modellere göre daha maliyetlidir. Aynı zamanda bu modellerin, diğer modellere göre eğitilebilmesi için daha geniş eğitim veri setine ihtiyaç duymaktadır (Yang ve diğerleri, 2019).

## b. Ortaklama Katmanı

Ortaklama katmanı, kendisinden önceki katman çıktısını ölçeklendirir, veriye ait önemli bilgileri saklar ve bu yüzden modelin işlem yükünü azaltır. Ayrıca, ortalama ve maksimum gibi çeşitleri de literatürde özel ortaklama katmanı olarak mevcuttur. Derin öğrenme modelinde, bu katman genellikle evrişimsel katmandan sonra kullanılır. Teknik olarak, ortaklama katmanı özellik haritaları içindeki veriyi azaltarak, bir sonraki katmanda işlenecek olan veri boyutunu azaltır ve böylece modeldeki parametre sayısını düşürür. Diğer bir deyişle, görüntüden elde edilen özellik haritasındaki önemli bilgilerin kullanılmasına olanak sağlar. Ortaklama katmanının çalışma prensibi, 2 boyutlu matris formundaki bir veri üzerinde küçük filtreler kullanılarak, veri üzerindeki küçük filtreyi kapsayan alandaki maksimum veya ortalama değerler alınarak yeni bir matris formunun oluşturulmasına dayandırılır. Böylelikle hem işlem yükü azalırken hem de derin öğrenme modelinin aşırı öğrenme durumu engellenir (Claesson ve Hansson, 2017). Şekil 1'de, 2x2 boyutunda bir ortaklama filtresi gösterilmiştir. 4x4 boyutundaki veri üzerinde bu filtre gezdirilerek en büyük değere sahip özellikler çıktı matrisine yazdırılmıştır.

## c. Düzleştirme Katmanı

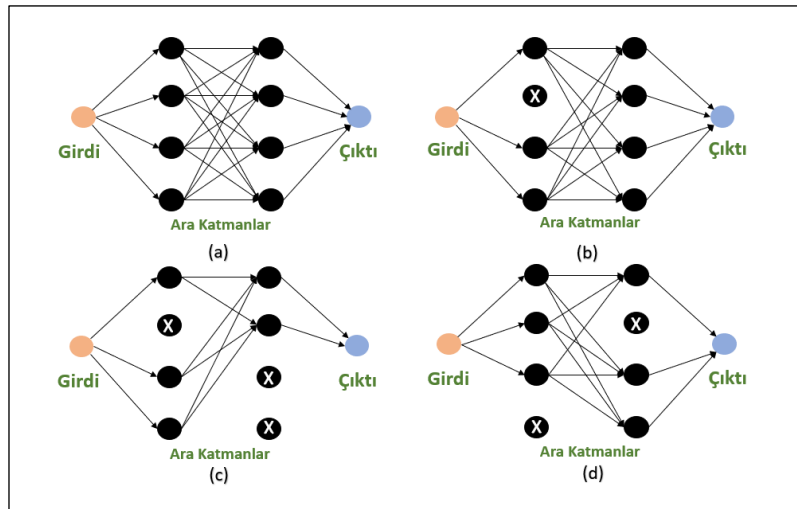
Düzleştirme katmanı, çok boyutlu bir özellik matrisini bir sonraki katmanı beslemek için tek boyutlu bir vektöre dönüştüren özel bir katmandır. Matrisin ilk elemanından başlanarak, matrise ait tüm elemanlar bir boyutlu vektör matrisine dönüştürülür. Bu katmanda kullanılan filtreler tek

boyutludur. Ayrıca düzleştirme katmanı ile oluşturulan derin öğrenme modelinde, model içi parametrelerinin azalması ile öğrenme hızının arttığı görülmüştür (Jin, Dundar ve Culurciello, 2015). Şekil 1'de iki boyutlu bir görüntü matrisine düzleştirme katmanının uygulandığı gösterilmiştir. Böylece tek boyutlu bir görüntüye ait verileri içeren bir vektörel matris oluşturulmuştur

## ç. Seyreltme Katmanı

Derin öğrenme modelleri çok sayıda parametre ile çalışmaktadır. Ancak bu durum, aşırı öğrenme problemini de beraberinde getirmektedir. Özellikle büyük sinir ağlarında çıktının üretilmesi önemli bir zaman almaktadır. Seyreltme katmanı ise derin öğrenme modelinin aşırı öğrenmesini engeller ve öğrenme süresinin kısaltmaya yardımcı olur (Srivastava, Hinton, Krizhevsky, Sutskever ve Salakhutdinov, 2014). Derin öğrenme modelindeki tüm sinir hücreleri birbirlerine düğümlerle bağlıdır. Seyreltme katmanı, modeldeki düğümlerin her iterasyonda belli bir yüzdesel oranda rastgele ve geçici olarak modelin eğitiminde kullanılmamasını sağlamaktadır.

Sonuç olarak, modeldeki tüm düğümlerin aynı anda kullanılması verinin ezberlenmesine neden olurken, her iterasyonda bazı düğümlerin geçici olarak açılıp-kapatılması ile veriye ait diğer özellikler ön plana çıkacağı için modelin veri setini ezberlemesinin önüne geçilir. Seyreltme işlemi çok katmanlı algılayıcıdaki budama ile benzer bir işlemdir. Şekil 2'de derin öğrenme modelinde seyreltme katmanının çalışma prensibi gösterilmiştir.



Şekil 2. Seyreltme katmanı uygulaması. (a) Seyreltme katmanı kullanılmadan oluşturulmuş sinir ağı, (b), (c), (ç) Seyreltme katmanı kullanılarak oluşturulmuş modelin farklı iterasyonlardaki durumu.

#### d. Harekete Geçirme Fonksiyonları

Harekete geçirme fonksiyonları, derin öğrenme modelindeki öğrenme sürecini etkileyen en önemli etmenlerden biridir. Öğrenme işlemi gerçekleştirilirken, bu fonksiyonlar modelin hesaplama yükünü azaltmaktadır. Harekete geçirme fonksiyonları, sinir hücresinden üretilen çıktı üzerinden matematiksel işlem gerçekleştirirler. Derin öğrenme modeli tarafından çözülecek bir problemin türüne bağlı olarak daha karmaşık harekete geçirme fonksiyonları da kullanılabilir. Harekete geçirme fonksiyonları doğrusal bir yapıya sahip değildir. Modeldeki sinir hücresinden gelen çıktı doğası gereği doğrusal bir yapıda olduğundan, harekete geçirme fonksiyonları bu çıktıları doğrusal olmayan çıktılara dönüştürmek için kullanılmaktadır. Harekete geçirme fonksiyonları sistemin doğrusal olmamasını sağlamak için kullanılır. Harekete geçirme fonksiyonları, her bir sinir hücresinin çıktısını 1 ile 0 veya -1 ile 1 arasında normalleştirir. Ayrıca harekete geçirme fonksiyonları türevlenebilir bir yapıda olduğu için geri yayılım algoritması ile uyumlu bir şekilde çalışmaktadır.

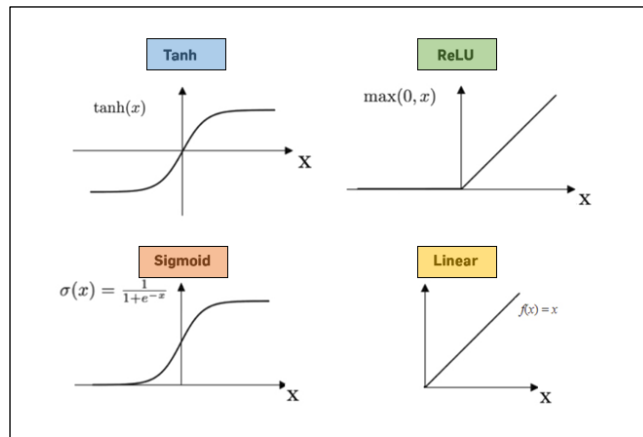
Kullanılan uygulamanın amacına göre farklı harekete geçirme fonksiyonları mevcuttur. Bunlar; hiperbolik tanjant (tanh), eşiksiz en büyük işlev (softmax), sigmoid, doğrultulmuş doğrusal birim (ReLU) ve bu birimin farklı çeşitleridir. Hiperbolik tanjant, aldığı girdi değerini -1 ile 1 arasında normalize eder. Sigmoid fonksiyonu ise hiperbolik tanjant ile çok benzerdir, tek farkı, çıktı değerlerini 0 veya 1 olarak etiketler. Eşiksiz en büyük işlev ise girdilerin hangi sınıflara ait olduğunu belirten olasılık değerlerini 0 ile 1 arasında etiketlemeyi sağlar. Doğrutulmuş doğrusal birim ve çeşitleri ise doğrusal olmayan model çıktıları için kullanılmaktadır. Bu fonksiyon, sigmoid ve hiperbolik tanjant fonksiyonlarına göre

hesaplamalarda daha fazla verim sağlamaktadır (Gu ve diğerleri, 2018; Nwankpa, Ijomah, Gachagan ve Marshall, 2020) (Şekil 3). Tüm bu fonksiyonların birbirlerine göre olumlu veya olumsuz yönleri mevcuttur (Khan ve diğerleri, 2020). Örneğin, ReLU'nun hesaplama yükü sigmoid harekete geçirme fonksiyonuna göre daha azdır ve bu nedenle çok katmanlı derin öğrenme modellerinde çoğunlukla tercih edilmektedir.

#### e. Maliyet Fonksiyonları

Maliyet fonksiyonları, modelin eğitimi esnasında kullanılır ve tahmin edilen çıktı ile gerçek çıktı arasındaki ilişkiyi kurmayı sağlar. Derin öğrenme modelinin eğitim başlangıcında, sinir hücrelerine ait ağırlıklar rastgele olacak şekilde atanır ve ardından model ağırlık tahminlerini oluşturmaya başlar. Derin öğrenme modeline ait ağırlıklar diğer iterasyonlarda değişmeye devam eder. Her bir iterasyonda bu üretilen çıktıları tahminlerin ve doğru çıktılar arasındaki farkların toplamı, maliyet fonksiyonları ile hesaplanır. Ardından optimizasyon problemi yaşamayan bir modele ait ağırlıklar eğitim sırasında güncellendikçe, modelin maliyet fonksiyonunda da bir azalma görülmeye başlanır. Uygun optimizasyon algoritmasının seçilmesi, modelin hem eğitim sürecini hem de eğitim kalitesini etkilemektedir. Bu algoritmalar, maliyet fonksiyonun hesaplanmasında büyük rol oynamaktadır. Bir derin öğrenme modelinin eğitimi sırasında kullanılan maliyet fonksiyon çeşitleri regresyon, ikili sınıflandırma ve çoklu sınıflandırmadır. Maliyet fonksiyonun matematiksel ifadesi Eşitlik (1)'de verilmiştir.

$$J = \sum_{i=1}^n (y^i - \hat{y}^i)^2 \quad (1)$$



Şekil 3. Bazı harekete geçirme fonksiyonlarının grafiksel gösterim.

$y^i$  terimi olması gereken çıktı değerini ifade ederken  $\hat{y}^i$  terimi ise modelin öğrenme işlemi tamamlandıktan sonra model tarafından tahmin edilen değerini gösterir.  $i$  değeri ise veri setindeki  $i$ . veri olarak ifade edilirken  $n$  ise toplam veri sayısı olarak ifade edilmiştir. Eşitlik 1 ile derin öğrenme modeline ait maliyet fonksiyonu ( $J$ ) hesaplanır (Khan, Rahmani, Shah, ve Bennamoun, 2018). Uzaktan algılama uygulamaları özellikle görüntü sınıflandırma işlemlerinde, çapraz entropi maliyet fonksiyonu tercih edilmektedir (Audebert, Le Saux ve Lefevre, 2019).

### 3. UZAKTAN ALGILAMA ALANINDA DERİN ÖĞRENME KULLANIMI

Son yıllarda uydu sayısının artması ile farklı spektral, radyometrik ve geometrik çözünürlüklere sahip görüntülerin kaydedilmesi ile veri çeşitliği, sayısı ve geçmişten günümüze veri hacmi artmaktadır. Uzaktan algılanmış verilerdeki bu artış büyük verinin oluşmasına neden olmaktadır. Üretilen büyük verinin işlenmesi ve analizinde geleneksel yöntemlerin kullanılmasını, derin öğrenme algoritmaları kadar başarılı sonuçlar vermediği birçok çalışmada belirtilmiştir (Li ve diğerleri, 2015; Zhang ve diğerleri, 2016; Liu ve diğerleri, 2017; Yuan ve diğerleri, 2020). Bu gibi durumlarda derin öğrenme algoritmaları tercih edilmektedir. Uzaktan algılama alanında yapılan birçok görüntü sınıflandırma ve bölütleme işlemi, nesne tespiti ve görüntü füzyonu çalışmalarında, derin öğrenme yöntemlerinin, klasik yöntemlere göre daha iyi sonuçlar ürettiği raporlanmıştır (Zhang, Zhang ve Du, 2016; Zhang, Xv, Shen, He ve Du, 2018; Yılmaz, 2020). Uzaktan algılama uygulamalarında radar görüntüleri, yüksek çözünürlüklü uydu görüntüleri ve hiperspektral görüntüler üzerinde derin öğrenme metotları kullanılarak çalışmalar gerçekleştirildiği literatür araştırmasında görülmüştür (Li, Zhang, ve Shen, 2017; Furukawa, 2018; Saha ve diğerleri, 2020).

Derin öğrenme yaklaşımının uzaktan algılama uygulamaları için uygunluğu üç temel nedene dayandırılabilir. İlk olarak, derin öğrenme yaklaşımının kullanılabilmesi için çok miktarda etiketli veriye ihtiyaç duyulmaktadır. Uzaktan algılama uygulamalarında etiketlenmiş verilerin üretilmesi için hem saha hem de laboratuvar çalışmaları gereklidir. Saha çalışmaları ile yeryüzüne ait referans yer doğrulama veri setleri oluşturulabilir. Aynı zamanda çalışma alanının ait öncül bilgiler mevcut ise etiketlenmiş veri setleri laboratuvar ortamında üretilebilir. Bu veri setlerinin üretimi için insan faktörüne ihtiyaç duyulması ve bu veri setlerinin hazırlanma süresinin zaman

alması bir dezavantaj olarak değerlendirilebilir. Ayrıca, derin öğrenme modelinin eğitimi için optimize edilmiş GPU artık daha kolay ulaşılabilir hale gelmiştir ve bu donanım sayesinde paralel işlem yapma olanağı bulunmaktadır. Ek olarak, derin öğrenme uygulamalarının yaygınlaştırılması için örneğin, Google gibi şirketler bulut üzerinden 12 saatlik ücretsiz GPU ve TPU (Tensor Processing Unit) desteği sağlamaktadır (Google Colab). Bulut platformlar, K80s, T4s, P4s ve P100s GPU desteğine sahip olmasının yanında derin öğrenme uygulamalarında için Python dilinde yazılmış hazır kütüphaneler içermektedir. Aynı zamanda ücretsiz olarak, her bir kullanıcı için 12 GB RAM kullanımına izin verilmektedir. Ancak ücretsiz versiyon, kullanıcılar için sınırlandırılmıştır (Google, 2021). Son olarak da derin öğrenme yaklaşımı, geleneksel yöntemlerle karşılaştırıldığında model mimarisinin hem derinlik hem de çıktı boyutlarına müdahale edilebilmesi durumu derin öğrenme metodunun üstün bir performans sergilemesini sağlamıştır. Uzaktan algılama alanında derin öğrenme mimarilerinin kullanıldığı alanlar görüntü ön işleme, görüntü sınıflandırma, nesne tespiti, görüntü yorumlama ve diğer uygulama alanları olmak üzere beş alt başlıkta incelenmiştir.

#### a. Ön İşlem

Uzaktan algılanmış görüntülerde, algılayıcılarda zamanla bozulmalar veya çevresel faktörlerin etkilerinden kaynaklı hatalar oluşabilmektedir. Bu oluşan bozulmaların yanında görüntü kalitesini iyileştirme işlemleri için ham görüntülere uygulanan tüm teknikler de ön işlem adımları olarak tanımlanmaktadır. Ön işlem adımlarının veri üzerinde yorumlama veya analiz yapılmadan önce gerçekleştirilmesi gerekir. Gürültü giderme ve görüntü füzyonu gibi ön işlem adımları ile verilerin işlenmesi daha kolay hale getirilmektedir. Görüntü kalitesini arttırmak için yapılan ön işlem adımlarında derin öğrenme yaklaşımları kullanılmaktadır. En çok kullanılan yöntemlerden biri görüntü keskinleştirme işlemidir. Uzaktan algılanmış veriler çok bantlı ve siyah-beyaz (pankromatik) bantlardan oluşabilir. Çok bantlı spektral bantların mekânsal çözünürlüğü, siyah-beyaz bantlara göre daha düşüktür. Bu sebeple, çok bantlı spektral verilerin mekânsal çözünürlüğünü arttırmak amacıyla siyah-beyaz bantların çözünürlüğüne örneklenmesi işlemidir (Özdemir, 2017; Meng, Shen, Li, Zhang ve Fu, 2019). Görüntü kalitesini arttırmak için kullanılan görüntü keskinleştirme uygulamasında, girdi ve çıktı verileri arasında bir korelasyon bulunmaktadır (Gu, Wang ve Li, 2019). Eğer bu korelasyon derin öğrenme mimarisi ile

modellenebilirse, algılanan başka bir görüntüye bu mimari uygulanabilir ve görüntü keskinleştirme işlemi uygulanmış bir çıktı verisi elde edilebilir (Zhang, Xia, Wu, Lin ve Tai, 2016).

Meteorolojik koşullara bağlı olarak optik uydu görüntülerinde bulut ve gölgeler görüntünün kalitesini ve analizini olumsuz yönde etkilemektedir. Bu görüntülerin kullanılabilmesi için öncelikle bulutlu alanların belirlenmesi gerekmektedir. Bu konuyla ilgili bir çalışmada GaoFen-1 uydu görüntülerine uygulamak üzere evrimsel sinir ağı içeren bir model üretilmiştir. Bu derin öğrenme modeli, görüntüdeki bulutların tespitini amacıyla kullanılmıştır (Li, Zou ve Shi, 2020). Başka bir çalışmada ise bulut tespit çalışmalarında benzer özellik gösteren kar kaplı alanları ayırt etmek için evrimsel sinir ağı modeli kullanılmış ve başarılı sonuçlar elde edilmiştir (Sun, Li, Xu, Li ve Huang, 2020).

Görüntü füzyonu, birden fazla görüntüde bulunan bilgilerin tek bir görüntüye entegre edilmesi işlemidir. Görüntü füzyon uygulamalarından biri de görüntü keskinleştirme işlemidir. Bu işlem adımında yüksek çözünürlüklü görüntü elde etmek amacıyla düşük çözünürlüklü çok bantlı spektral görüntülerin siyah-beyaz bantlı görüntü ile birleştirilmesi yapılmaktadır. (Zhang, Liu, Sun ve Ou, 2019). Evrimsel sinir ağları kullanarak yapılan bir çalışmada çok bantlı spektral ve siyah-beyaz görüntü füzyonu işlemi gerçekleştirilmiştir. Bu çalışmada, özellikle derin öğrenme metodunun doğrusal bir yapıda olmamasının avantajlı bir durum olduğu belirtilmiştir. Çünkü, bu metot geleneksel uygulamalara göre daha yüksek doğruluk vermiştir (Wei, Yuan, Shen ve Zhang, 2017). Huang ve diğerleri (2015) tarafından yapılan bir çalışmada ise yüksek ve düşük çözünürlüklü iki görüntü arasındaki ilişkiyi modellemek için Otokodlayıcı algoritması önerilmiştir. Bu çalışmada kullanılan derin öğrenme modeli, ön eğitimden sonra geri yayılım algoritması ile tekrardan eğitilmiştir. Böylece görüntü keskinleştirme işlemlerinde derin öğrenme modelinin iyi bir performans gösterdiği belirtilmiştir.

Gürültü, algılayıcının hatalı çalışması ile ortaya çıkabilen ve görüntüde istenmeyen sinyaller olarak adlandırılabilir. Bu gürültüler, görüntü işlemede sorunlar yaratır. Bu nedenle görüntüdeki gürültülerin giderilmesi için çeşitli teknikler kullanılmaktadır. Gürültü giderme, uydu görüntülerinin analizinde yaygın olarak kullanılan bir ön işleme adımıdır (Al-amri, Kalyankar ve Khamitkar, 2010). Bu işlemin geleneksel

yöntemlerle uygulanması özellikle hiperspektral görüntülerde başarısız sonuçlar verebilmektedir (Maffei ve diğerleri, 2020). Hiperspektral görüntüler spektral bilgi açısından zengin bir veri türüdür, ancak spektral bantlar arasındaki korelasyon yüksektir. Bu durumun üstesinden gelmek için evrimsel sinir ağı tabanlı HSI-SDeCNN (Maffei ve diğerleri, 2020), SURE-CNN (Nguyen, Ulfarsson, ve Sveinsson, 2020) ve Decs-Net (Liu ve diğerleri, 2019) gibi derin öğrenme modeli literatürde önerilmiştir. Bu modeller, hiperspektral görüntüye ait hem geometrik hem de spektral özellikleri birlikte kullanmaktadır. Derin öğrenme modellerinin, hiperspektral verilerde gürültü azaltma geleneksel yöntemler arasında iyi bir performansa sahip olduğu belirtilmiştir (Yuan, Zhang, Li, Shen ve Zhang, 2019). Gürültü giderme işlemleri hiperspektral görüntü dışında radar görüntülerine de uygulanmaktadır. Evrimsel sinir ağlarını kullanarak DeepInSAR adında bir derin öğrenme modeli tasarlanmış ve bu model radar görüntüsüne ait faz bilgileri koruyan ve koherens verisinin hem açık hem de keskin yapıda olmasına olanak sağlamıştır (Ghuman ve Cheng, 2020).

Uzaktan algılanmış görüntülerde mekânsal çözünürlükten kaynaklı iki farklı nesne sınıfının sınırları birbirleri ile karışabilmektedir. Bu nedenle, nesne sınırlarının karışmaması için görüntülere ait mekânsal çözünürlüklerin geliştirilmesi için çalışmalar yürütülmüştür (Zhu ve diğerleri, 2017). Düşük mekânsal çözünürlük ile yüksek mekânsal çözünürlüğe ait iki görüntü birbirleri ile birleştirilerek bulanık nesne sınırları ortadan kaldırılabilmektedir (Hao, Wang, Ye, Li, ve Bruzzone, 2018). Bu konuyla ilgili yapılmış bir çalışmada, hiperspektral görüntü kullanılarak görüntüden çeşitli alt ölçekte görüntü parçacıkları çıkarılmıştır. Ardından yukarı örnekleme işlemi içinde 2 ve 3 boyutlu ESA derin öğrenme modelleri kullanılmıştır (Sidorov ve Hardeberg, 2019). Başka bir çalışmada ise okyanus veri setleri kullanarak, bu verilerin çözünürlüklerini arttırmak için süper piksel ESA derin öğrenme modeli önerilmiştir (Ducournau ve Fablet, 2016). Sentinel-1 görüntüleri kullanılarak yapılan bir çalışmada ise düşük çözünürlükteki bantları yüksek çözünürlüğe çıkartmak için ESA tabanlı bir model geliştirilmiştir (Gargiulo ve diğerleri, 2018).

## b. Görüntü Sınıflandırma

Son yıllarda birçok çalışmada, sınıflandırma işlemlerinde klasik yöntemler yerine derin öğrenme yöntemleri kullanılmaktadır. Derin öğrenme yaklaşımı ile görüntüye ait hem spektral hem de geometrik özellikler birlikte



değerlendirilebilmektedir. Böylece görüntüye ait belirgin özellikler içeren bir özellik haritası çıkartılabilmektedir. Görüntü sınıflandırma uygulamalarında kullanılan klasik yöntemler siğ bir yapıdan oluşmaktadır, ancak sınıflandırma işleminde kullanılan derin öğrenme metotları, klasik yöntemlere göre verilerin analizinde daha başarılı olabilmektedir. Spektral ve geometrik özelliklerin birlikte değerlendirilmesi ile daha yüksek doğrulukla tematik haritalar üretebildiğinden derin öğrenme yaklaşımları tercih edilmektedir (Zhao ve Du, 2016).

Genel olarak uzaktan algılamada derin öğrenme ile yapılmış sınıflandırma uygulamaları spektral bilgi, mekânsal bilgi veya spektral-mekânsal bilgileri kullanılarak üç farklı biçimde gerçekleştirilir. Derin öğrenme yaklaşımı kullanılarak bir hiperspektral görüntü sınıflandırması yapılmış ve Otokodlayıcılar kullanılarak farklı katman sayısına sahip iki adet mimari oluşturulmuştur. Az katman içeren mimari spektral özellikleri kullanarak sınıflandırma işlemi yaparken çok katman içeren mimari ise mekânsal özellikleri kullanarak sınıflandırma yapmıştır. Ardından daha yüksek sınıflandırma doğruluğu için bu iki özelliği de kullanan başka bir derin öğrenme modeli geliştirilmiştir (Chen, Lin, Zhao, Wang, Gu, 2014). Derin inanç ağları kullanılarak yapılan diğer bir çalışmada hem spektral hem de mekânsal bilgiler kullanılmıştır. En uygun katman sayısı gibi parametrelerin seçimi tüm kombinasyonlarının kapsamlı bir şekilde kullanılması ile belirlenmiştir. Çalışmada önerilen modelin ürettiği doğruluğunun, destek vektör makineleri ile üretilen doğruluğa göre daha yüksek olduğu belirtilmiştir (Chen, Zhao ve Jia, 2015). Bir başka uygulamada sadece görüntüye ait piksel tabanlı bir uygulama yapılmıştır. Yapılan bu çalışmada önerilen model mimarisinde evrişimsel sinir ağları kullanılarak manuel olarak etiketlenmiş veri ile OpenStreetMap verisi sınıflandırılmıştır (Maggiori, Tarabalka, Charpiat ve Alliez 2017). RapidEye optik görüntüsü ile derin öğrenme modeli kullanılarak yapılan bir çalışmayla sulak alan içeren bölge sınıflandırılmıştır. Bu çalışmada derin öğrenmedeki DenseNet121, InceptionV3, VGG16, VGG19, Xception, ResNet50 ve InceptionResNetV2 gibi hazır mimariler kullanılarak sınıflandırma kapasiteleri incelenmiştir. Ayrıca bu yöntemlerin yanında rastgele orman ve destek vektör makinesi metotları kullanılarak da sınıflandırma işlemi gerçekleştirilmiştir. Derin öğrenme mimarileri arasında en iyi performansı %96,17 genel doğrulukla InceptionResNetV2 modeli üretmiştir (Mahdianpari, Salehi, Rezaee, Mohammadimanesh ve Zhang, 2018). Diğer bir

çalışmada, hem hiperspektral görüntüler hem de LİDAR verileri birlikte kullanılarak sınıflandırma işlemi yapılmıştır. Burada önerilen sinir ağı modeli iki kollu yapıda olup hem 1 boyutlu hem de 2, boyutlu evrişimsel sinir ağı şeklindedir. Oluşturulan modelin geleneksel yöntemlere göre daha iyi sonuç verdiği ortaya koyulmuştur (Xu ve diğerleri, 2018). Sınırlı miktarda eğitim verisi kullanılarak yapılan çalışmada 11 katmanlı bir evrişimsel sinir ağı ile Pavia, Indian Pines ve Salinas hiperspektral görüntüleri %96 üzeri bir doğrulukla sınıflandırılmıştır (Feng, Wang, Wang ve Zhang, 2019).

Görüntü sınıflandırmada güncel yaklaşımlardan biri de sınıflandırmanın görüntü bölümleri üzerinden yapılmasıdır. Görüntü bölütleme, görüntüdeki nesnelere ait mekânsal-spektral özelliklerini kullanarak nesnelere ait bölümlere yani bölgelere ayrılmasıdır. Derin öğrenme modelleri, anlamlı nesnelere oluşturmak için görüntü üzerinde bölütlemeler yapıp nesnelere anlamsal bütünlüğüne göre birleştirme işlemleri uygulamaktadır (Kaiser ve diğerleri, 2017). Görüntü bölütleme sadece şehir alanları için değil atmosferik araştırmalarda da kullanılmaktadır. Bu konu ile ilgili bulut bölütlemesi yapan bir ESA modeli önerilmiştir (Rusyn, Korniy, Lutsyk ve Kosarevych, 2019). Önerilen bu model bölütleme yapan diğer modellere göre daha hızlı ve daha kaliteli bulut bölütleri oluşturduğu gösterilmiştir. Görüntü bölütlemesi yapılan başka bir çalışmada ise çok bantlı spektral görüntülerden oluşturulmuş Gaofen-2 veri seti kullanılmıştır. Bölütleme işlemi için hazır bir mimari olan U-net modeli kullanılmış ve sonuç olarak %80 üzeri bir genel doğruluk elde edilmiştir (Zheng ve Chen, 2020). Görüntü bölütlemesine ait başka bir uygulama alanı ise uzaktan algılanmış görüntülerde su kütlelerinin tespit edilmesidir. Bu konuyla ilgili yapılmış bir uygulamada çok ölçekli bir ESA tabanlı hazır mimari (DeepLabV3) kullanılmış ve bu mimarinin yapısı iyileştirilmiştir. Su kütlelerinin ayrıntılı sınırlarının tespiti için Koşullu Rastgele Alan algoritması tercih edilmiştir. Yapılan bu çalışmada su kütlelerinin tespitinde %95 üzeri doğruluğa ulaşılmıştır (Li, Wang, Zhang, Hu, ve Meng, 2019).

### c. Nesne Tespiti

Nesne tespiti uygulamaları, görüntü işleme uygulamalarında son dönemde yaygın olarak kullanılmaktadır. Bu uygulamalarda hem nesnelere tespit edip hem de nesnelere hangi sınıfa ait olduğunu gösterilebilmektedir. Bu durum yapılan çalışmaların amacına göre şekillenmektedir (Jiao ve diğerleri, 2019). Uydu görüntülerinde yer alan

gemi, yol, bina, uçak gibi nesnelerin tespiti yüksek doğrulukla yapılabilmektedir (Cheng ve Han, 2016). Ancak bu nesnelerin büyüklüğü, yönü, sayısı, çevresindeki cisimlerle karışması gibi problemlerle karşılaşmaktadır. Bu problemler de nesnenin yanlış algılanmasına veya hedefin tespit edilmesinde olumsuzluklara neden olmaktadır. Nesne tespiti uygulamalarında nesneye ait spektral, mekânsal ve doku özelliklerini kullanarak sınıflandırma işlemi gerçekleştirilir ve diğer nesnelere ayırt edilmesi sağlanır. Nesne tespiti uygulamaları radar, hiperspektral veya çok bantlı spektral görüntüler kullanılarak gerçekleştirilebilir.

Nesne tespitiyle ilgili yapılan bir çalışmada binalar gibi insan yapımı nesnelerin tespiti için yüksek çözünürlüklü çok bantlı spektral uydu görüntüleri kullanılmıştır. Eğitim esnasında, ImageNet derin öğrenme modeline spektral bilgilerde eklenmiş ve yüksek doğrulukla bina tespiti gerçekleştirilmiştir (Vakalopoulou, Karantzalos, Komodakis ve Paragios, 2015). Bina tespiti yapılan başka bir çalışmada ise genelleme yapabilen bir ESA modeli oluşturulmuştur. Böylelikle, binaların şekilsel-boyutsal farklılıkların, bina tespiti uygulamalarındaki olumsuzlukların giderilmesi hedeflenmiştir (Chen ve diğerleri, 2017). Radar görüntüsü kullanılarak gemi tespitinin yapıldığı bir çalışmada ise görüntüye uygulanan Sabit Yanlış Alarm Oranı algoritmasının eksik kaldığı yönler, hızlı evrimsel sinir ağı ile tekrar değerlendirilmiştir (Kang, Lin, Xiangguang ve Ji, 2017). Bölge tabanlı evrimsel sinir ağı araçları algılayan bir derin öğrenme modeli olarak kullanılmıştır (Deng, Sun, Zhou, Zhao ve Zou, 2017). Özellikle, bu çalışmada aşırı öğrenmeyi engellemek için eğitim verisi artırma uygulaması yapılmıştır. Önerilen yöntemin doğruluğunun %70 üzeri olduğu ve diğer metotlara göre daha iyi performans gösterdiği raporlanmıştır. Gemi tespiti yapılan başka bir çalışmada ise 20 adet yapay açığı radar görüntüsü kullanılmıştır. Bu görüntüler Radarsat-2, TerraSAR ve Sentinel-1 uydularına aittir. Bu çalışmada gemilerin tespit edilebilmesi için çok ölçekli derin öğrenme modelleri kullanılmıştır. Nesnelere ait alt ve üst ölçekli özellik haritaları çıkarılmıştır (Jiao ve diğerleri, 2018). Uçak tespiti yapılan bir çalışmada yüksek çözünürlüklü (0,11 ile 2 metre arasında) Jilin-1 ve Gaofen-2 uydularına ait görüntüleri kullanılarak uçak tespiti ESA tabanlı YOLO, SSD ve Hızlı ESA (Faster R-CNN) modellerini içeren üç farklı yöntem ile yapılmıştır. Sinir ağlarını eğitmek için sınırlı sayıda kullanılacak görüntülere, kırpma, yeniden ölçeklendirme gibi işlemler yapılarak etiketli veri sayısı artırılmıştır. Bu modellerin

performanslarının değerlendirilebilmesi için farklı çözünürlüğe sahip görüntüler eğitim aşamasında kullanılmıştır. Bu yöntemler arasında en yüksek doğruluk hızlı ESA modeliyle elde edilmiştir (Alganci, Soydas ve Sertel, 2020). Aynı zamanda araç tespiti yapılmış başka bir çalışmada da hızlı ESA algoritması kullanılmıştır. Bu çalışmanın diğer çalışmalardan farkı ise; hızlı giden araçların tespit edilmesi, yol durumu ve trafik akış bilgilerinin elde etmesidir (Tan, Ling, Hu, Qin, ve Hu, 2020). İnsansız hava araçları (İHA) ile uzaktan algılanmış veriler toplanabilmekte ve bu veriler üzerinden de nesne tespit uygulamaları yapılabilmektedir. Özel bir ağaç türünün tespiti uygulamasını gerçekleştiren bir çalışmada İHA ile toplanmış üç bantlı veri kullanılmıştır. Tespit işlemi için ESA mimari kullanılarak oluşturulmuş Faster R-CNN, YOLOv3 ve RetinaNet sinir ağı mimarileri test edilmiş ve RetinaNet mimarisi %92,64 ortalama doğruluk ile en yüksek doğruluğu üretmiştir (dos Santos ve diğerleri, 2019). Diğer bir çalışmada gerçek zamanlı İHA verileri kullanılarak elde edilmiş görüntülerden, boru hatlarına zarar vermemesi için kazı çalışmalarını kontrol eden ESA tabanlı YOLOv3 mimarisi kullanılmıştır (Meng ve diğerleri, 2020).

#### ç. Görüntü Yorumlama

Uzaktan algılanmış görüntüler, bir veya birden fazla nesnenin birleşimi ve bu nesnelerin çevresel etkileşimleri ile oluşmaktadır. Görüntüdeki nesnelere ise birden fazla pikselin bir araya gelmesi ile tanımlanır. Uzaktan algılamada son yıllarda gelişen teknolojinin eşlik etmesiyle görüntüye ait mekânsal çözünürlük artmıştır. Görüntü çözünürlüğünün artması, görüntünün içerdiği bilginin de artması anlamına gelmektedir. Böylelikle görüntü içindeki nesnelerin, çevresindeki nesnelere ile arasında anlamsal bir bütün oluşmaktadır. Bu kapsamda değerlendirildiğinde görüntü içinde yorumlanacak veri miktarı artması ile derin öğrenme modeli ile veriye ait anlamsal bütünlüğün çıkartılması esnasında yorumlama işlemi, görüntünün yorumlanmasındaki zorluğu artıran bir faktördür. Derin öğrenme modelleri, doğrusal olmayan işlemleri kullanarak görüntü tanıma uygulamaları yapılabilmektedir. Görüntü yorumlama uygulaması için arazi kullanım haritasının üretildiği bir çalışmada hem derin öğrenme yöntemiyle hem de diğer öğrenme yöntemlerinin bir arada kullanılması ile gerçekleştirilmiştir. Bu konuyla ilgili bir çalışmada, önceden eğitilmiş bir evrimsel sinir ağı, verilere ait özellikleri öğrenmek için kullanılmıştır. Ardından daha iyi doğruluk elde etmek için aşırı öğrenen makineler (extreme learning machine) kullanılarak, öğrenilen

özellikleri eğiten bir sınıflandırıcı tercih edilmiştir. Genel olarak bu çalışmada önerilen ESA tabanlı model ile %95 üzerinde bir doğruluk elde edilmiştir. Ayrıca farklı özelliklere sahip görüntülerin bu model ile değerlendirilebilmesi için model içindeki parametrelerin değiştirilmesinin gerektiği ortaya konulmuştur (Weng, Mao, Lin ve Guo, 2017).

Görüntü yorumlamasının yapılabilmesi için öncelikle görüntünün sınıflandırması gerekmektedir. Genel olarak, bu uygulamaların çalışma prensibi, görüntüdeki nesnelere diğer nesnelere veya çevre ile arasındaki ilişkinin kurulmasına dayanmaktadır. Böylelikle uzaktan algılanmış görüntülerden arazi örtüsü bilgisi çıkartılabilir. Sanayi ve yerleşim yeri gibi farklı bölgelerde benzer nesnelere olan görüntülerin yorumlanması açısından zorluk meydana getirmektedir. GoogleNet bu zorlukların üstesinden gelmek üzere kurulmuş bir derin öğrenme modeli olarak literatürde yer almaktadır (Li, Peng, Tao, Chen ve Deng, 2017). Zhao ve diğerleri (2019) çalışmalarında, yüksek çözünürlüklü görüntüler kullanılarak karmaşık kentsel bölgelerin tespit edilmesi için bir evrimsel sinir ağı modeli geliştirilmiştir. Coğrafi nesnelere ait anlamsal bilgiler için OpenStreetMap veri seti sinir ağının eğitimi esnasında kullanılmıştır. Kent içindeki bölgelerin tespitinde %88,5 sınıflandırma doğruluğu elde edilmiştir. .

#### d. Diğer Uygulama Alanları

Uzaktan algılanmış görüntülerde derin öğrenme yaklaşımının kullanımı, nesne tespiti, görüntü sınıflandırma, ön işleme ve görüntü yorumlama dışında da birçok uygulama alanına sahiptir. Bu alanlardan önemlilerinden bir tanesi değişim analizidir. İki farklı periyotta alınmış görüntülerin zamansal değişimleri derin öğrenme modelleri ile incelenmektedir. Aynı zamanda bu tip çalışmalar da kontrollü ve kontrolsüz öğrenme yöntemleri bir arada kullanılabilir (Khelifi ve Mignotte, 2020). Bu alanda yapılan bir çalışmada, WorldView-2 görüntüleri kullanılarak 2017 ve 2018 yılları arasında değişim incelenmiştir. İki görüntü arasındaki tüm değişimleri algılayabilen bir derin öğrenme modeli geliştirilmiştir ve bu model değişim alanlarını %80 F-skor doğruluk seviyesinde tespit etmiştir (Yang, Gu, Han ve Li, 2020). Değişim analizi yapılan başka bir çalışmada ise hiperspektral görüntüler üzerinden 2 Boyutlu ESA mimarisi (GETNET) kullanılmıştır. Bu çalışmanın sonucunda %97 üzerinde genel doğruluk ile değişim analizi yapılmıştır (Wang, Yuan, Du, ve Li, 2019).

Değişim analizi dışında 3 boyutlu yapılandırma işlemlerinde de derin öğrenme mimari kullanılmaktadır. Uzaktan algılanmış stereo verilerin kullanılması ile iki adımda 3 boyutlu veriler üretilmektedir. İlk olarak, algılayıcının konumu hesaplanarak, görüntülerin oryantasyonu belirlenir. Diğer adım da ise görüntüler üzerinden ortak noktalar belirlenerek üçgenleme metodu ile 3 boyutlu veriler yapılandırılmaktadır (Zhu ve diğerleri, 2017). Bu alanda yapılmış bir çalışmada tek bir radar görüntüsünden elde edilmiş 3 boyutlu nokta bulutu verisi ile optik görüntüler Çekişmeli Üretici Ağ modellerinde eğitilerek, nesneye ait yapısal özelliklerin çıkartılması hedeflenmiştir (Peng, Qiu, Ding, ve Tie, 2019).

Derin öğrenme yaklaşımları tahmin uygulamalarında da kullanılmaktadır. Özellikle, tarımsal verimlilik üzerine yapılan çalışmalarda derin öğrenme yaklaşımı bir yol gösterici olmaktadır. Tarımsal verimliliği etkileyen meteorolojik parametreler, topografik etmenler, bitkisel hastalıklar (uzaktan algılanmış görüntü üzerinden bitki indekslerin kullanılması) gibi faktörlerin derin öğrenme modeli için girdi verisi olarak kullanılmaktadır (Yuan ve diğerleri, 2020). Tarımsal üretimin incelenmesi ve üretim tahmininin yapılabilmesi için derin öğrenme yaklaşımı kullanılmıştır. İlgili çalışmada, Sentinel-2 uydu görüntüsünün yanında yardımcı veri olarak MODIS (Moderate Resolution Imaging Spectroradiometer) uydusuna ait sıcaklık ve buharlaşma verileri kullanılmıştır. Bu veriler, ESA ve tekrarlayan yapay sinir ağı modelinde kullanılmıştır. Çalışmanın sonucunda, önerilen derin öğrenme modeli ile verim tahmini yapmanın mümkün olduğu belirtilmiştir (Ghazaryan ve diğerleri, 2020). Son olarak, bahsedilen uygulama alanlarının yanında görüntüden özellik çıkartma, yağış-sıcaklık tahmini, volkan, sel, deprem gibi doğa olaylarının izlenmesi ve takibinde de derin öğrenme yaklaşımları kullanılmaktadır (Zhang ve diğerleri, 2016; Ma ve diğerleri, 2019; Yuan ve diğerleri, 2020)

#### 4. SONUÇ VE ÖNERİLER

Derin öğrenme yaklaşımı, uzaktan algılama çalışmalarında özellikle nesne tespiti, özellik çıkarımı ve sınıflandırma gibi uygulamalarda yaygın olarak kullanılmaktadır. Derin öğrenme kullanılarak yapılan çalışmalarda diğer metotlara göre önemli bir başarı gözlenmektedir. Özellikle, büyük veri kategorisine giren hiperspektral, çok bantlı görüntüler ve radar görüntülerinin analizinde geleneksel yöntemlere göre derin öğrenme yaklaşımı daha iyi performans göstermektedir. Büyük verilerin, objektif bir şekilde

değerlendirilmesinin yanında, bu verileri içeren karmaşık problemlerin çözülebilmesi, derin öğrenme mimarilerinin en önemli avantajlarıdır. Derin öğrenme yönteminin yaygın olarak kullanılması diğer sebeplerinden bir de, bilgisayar donanımlarının gelişmesi ve Google gibi şirketlerin kullanıcılara ücretsiz GPU servisi sağlamasıdır.

Bu makalede, derin öğrenme modellerinden biri olan ESA katmanlarının çalışma prensibinden ve bu modelin eğitimi esnasında ESA katmanlarının sağladığı avantajlar açıklanmıştır. Bunların yanında derin öğrenme mimarisinin eğitimi etkileyen harekete geçirme ve maliyet fonksiyonları üzerinde durulmuştur. Uzaktan algılama uygulamalarından ön işlem, görüntü sınıflandırma, nesne tespiti, görüntü yorumlama ve diğer uygulama alanları için literatür taraması yapılmıştır. Ön işlem uygulamalarında, derin öğrenme yaklaşımı görüntü zenginleştirme veya görüntüden bulut çıkartma işlemleri için kullanıldığı görülmüştür. Görüntü sınıflandırma çalışmalarında ise genellikle hiperspektral veya yüksek çözünürlük görüntülerin sınıflandırma işlemi yapıldığı ve derin öğrenme yöntemiyle başarılı sonuçlar elde edildiği raporlanmıştır. Nesne tespiti uygulamalarında ise radar veya çok bantlı görüntüler kullanılarak bina, araç ve gemi gibi nesnelerin tespiti için derin öğrenme mimarileri kullanılmıştır. Son olarak, uydu görüntülerindeki nesnelere arasındaki hem semantik hem de mekânsal ilişkilerin kurulabilmesi için derin öğrenme mimarileri ile görüntü yorumlama uygulamalarının yapıldığı gösterilmiştir.

Derin öğrenme modelleri kara kutu prensibi ile çalıştığı için gerçekleşen matematiksel işlemler hakkında bilgi edinme bir problem olarak karşımıza çıkmaktadır. Bu nedenle, modelin eğitimi etkileyen iç faktörler bilinmediği için bunlar üzerine çalışılmaktadır. Eğitimde kullanılan örneklem sayısının veya örneklem boyutundaki değişimlerin eğitimi nasıl etkileyeceği üzerinde yapılan çalışmaların yanında, görüntü sınıflandırması için oluşturulan derin öğrenme modelinin nasıl bir mimariye sahip olması gerektiği ve bu mimaride kullanılan parametrelerin nasıl seçilmesi gerektiği ile ilgili optimizasyon çalışmalarının yoğun olarak devam ettiği görülmüştür.

#### ORCID

Elif Özlem YILMAZ  <https://orcid.org/0000-0002-6853-2148>

Taşkın KAVZOĞLU  <https://orcid.org/0000-0002-9779-3443>

#### KAYNAKLAR

- Abdel-Hamid, O., Mohamed, A.R., Jiang, H., Deng, L., Penn, G. ve Yu, D. (2014). Convolutional neural networks for speech recognition. *IEEE Transactions on Audio, Speech and Language Processing*, 22(10), 1533-1545. doi:10.1109/TASLP.2014.2339736
- Al-amri, S.S., Kalyankar, N.V. ve Khamitkar, S.D. (2010). A comparative Study of Removal Noise from Remote Sensing Image. *International Journal of Computer Science Issues*, 7(1), 32–36. arXiv:1002.1148
- Alganci, U., Soydas, M. ve Sertel, E. (2020). Comparative research on deep learning approaches for airplane detection from very high-resolution satellite images. *Remote Sensing*, 12(3), 458. doi:10.3390/rs12030458
- Alom, M.Z., Taha, T.M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M.S., ... Asari, V.K. (2019). A state-of-the-art survey on deep learning theory and architectures. *Electronics*, 8(3), 292. doi:10.3390/electronics8030292
- Audebert, N., Le Saux, B. ve Lefevre, S. (2019). Deep learning for classification of hyperspectral data: A comparative review. *IEEE Geoscience and Remote Sensing Magazine*, 7(2), 159-173. doi:10.1109/MGRS.2019.2912563
- Ball, J.E., Anderson, D.T. ve Chan, C.S. (2017). Comprehensive survey of deep learning in remote sensing: theories, tools, and challenges for the community. *Journal of Applied Remote Sensing*, 11(04), 042609. doi:10.1117/1.jrs.11.042609
- Chen, K., Fu, K., Gao, X., Yan, M., Sun, X. ve Zhang, H. (2017, Aralık). *Building extraction from remote sensing images with deep learning in a supervised manner*. 2017 IEEE International Geoscience and Remote Sensing Symposium, Teksas, ABD.
- Chen, J., Huang, H., Peng, J., Zhu, J., Chen, L., Tao, C. ve Li, H. (2021). Contextual Information-Preserved Architecture Learning for Remote-Sensing Scene Classification. *IEEE Transactions on Geoscience and Remote Sensing (Early Access)*. doi: 10.1109/TGRS.2021.3063287

- Chen, Y., Lin, Z., Zhao, X., Wang, G. ve Gu, Y. (2014). Deep learning-based classification of hyperspectral data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6), 2094-2107. doi: 10.1109/JSTARS.2014.2329330
- Chen, Y., Zhao, X. ve Jia, X. (2015). Spectral-spatial classification of hyperspectral data based on deep belief network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(6), 2381-2392. doi:10.1109/JSTARS.2015.2388577
- Cheng, G. ve Han, J. (2016). A survey on object detection in optical remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 117, 11–28. doi:10.1016/j.isprsjrs.2016.03.014
- Claesson, L. ve Hansson, B. (2017). *Deep learning methods and applications* (Yüksek Lisans Tezi). Chalmers University of Technology, İsveç.
- Demyanov, S. (2015). *Regularization methods for neural networks and related models* (Doktora Tezi). The University of Melbourne, Avustralya.
- Deng, Z., Sun, H., Zhou, S., Zhao, J. ve Zou, H. (2017). Toward fast and accurate vehicle detection in aerial images using coupled region-based convolutional neural networks. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(8), 3652-3664. doi:10.1109/JSTARS.2017.2694890
- dos Santos, A.A., Marcato Junior, J., Araújo, M.S., Di Martini, D.R., Tetila, E.C., Siqueira, H.L., ... Gonçalves, W.N. (2019). Assessment of CNN-based methods for individual tree detection on images captured by RGB cameras attached to UAVS. *Sensors*, 19(16), 3595. doi:10.3390/s19163595
- Dong, L., Du, H., Mao, F., Han, N., Li, X., Zhou, G., ... Liu, T. (2020). Very high resolution remote sensing imagery classification using a fusion of random forest and deep learning technique—Subtropical area for example. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 113–128. doi:10.1109/JSTARS.2019.2953234
- Ducournau, A. ve Fablet, R. (2016, Mart). *Deep learning for ocean remote sensing: An application of convolutional neural networks for super-resolution on satellite-derived SST data*. 9th IAPR Workshop on Pattern Recognition in Remote Sensing, Cancun, Meksika.
- Erdem, F., Bayram, B., Bakirman, T., Bayrak, O.C., Akpınar, B. (2021). An ensemble deep learning based shoreline segmentation approach (WaterNet) from Landsat 8 OLI images. *Advances in Space Research*, 67(3) 964-974, doi:10.1016/j.asr.2020.10.043.
- Feng, F., Wang, S., Wang, C. ve Zhang, J. (2019). Learning deep hierarchical spatial–spectral features for hyperspectral image classification based on residual 3D-2D CNN. *Sensors*, 19(23), 5276. doi:10.3390/s19235276
- Fukushima, K. (1980). Neocognitron: a self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biol. Cybernetics* 36, 193-202. doi:10.1007/BF00344251
- Furukawa, H. (2018). *Deep Learning for End-to-End Automatic Target Recognition from Synthetic Aperture Radar Imagery*. (SANE2017-92), Japonya: The Institute of Electronics, Information and Communication Engineers.
- Garcia-Garcia, A., Orts-Escolano, S., Oprea, S., Villena-Martinez, V., Martinez-Gonzalez, P. ve Garcia-Rodriguez, J. (2018). A survey on deep learning techniques for image and video semantic segmentation. *Applied Soft Computing*, 70, 41-65. doi: 10.1016/j.asoc.2018.05.018
- Gargiulo, M., Mazza, A., Gaetano, R., Ruello, G. ve Scarpa, G. (2018, Kasım). *A CNN-Based fusion method for super-resolution of Sentinel-2 data*. IEEE International Geoscience and Remote Sensing Symposium, Valensiya, İspanya.
- Ghamisi, P., Chen, Y. ve Zhu, X.X. (2016). A self-improving convolution neural network for the classification of hyperspectral data. *IEEE Geoscience and Remote Sensing Letters*, 13(10), 1537-1541. doi:10.1109/LGRS.2016.2595108

- Ghazaryan, G., Skakun, S., Konig, S., Rezaei, E. E., Siebert, S. ve Dubovyk, O. (2020, Şubat). *Crop yield estimation using multi-source satellite image series and deep learning*. IEEE International Geoscience and Remote Sensing Symposium, Waikoloa, USA.
- Ghuman, P. ve Cheng, I. (2020). DeepInSAR-a deep learning framework for sar interferometric phase restoration and coherence estimation. *Remote Sensing*, 12(14), 2340. doi:10.3390/rs12142340
- Google. (2021) Colaboratory. Erişim Adresi: <https://research.google.com/colaboratory/faq.html>
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., ... Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern Recognition*, 77, 354–377. doi:10.1016/j.patcog.2017.10.013
- Gu, Y., Wang, Y. ve Li, Y. (2019). A survey on deep learning-driven remote sensing image scene understanding: scene classification, scene retrieval and scene-guided object detection. *Applied Sciences*, 9(10), 2110. doi:10.3390/app9102110
- Han, Z., Ma, L. ve Chen, H. (2019, Kasım). *Optimization of ship target detection algorithm based on random forest and regional convolutional network*. International Conference on Electronic Engineering and Informatics, Nanjing, Çin.
- Hao, S., Wang, W., Ye, Y., Li, E. ve Bruzzone, L. (2018). A deep network architecture for super-resolution-aided hyperspectral image classification with classwise loss. *IEEE Transactions on Geoscience and Remote Sensing*, 56(8), 4650–4663. doi:10.1109/TGRS.2018.2832228
- He, K., Zhang, X., Ren, S. ve Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016(12), 770–778. doi:10.1109/CVPR.2016.90
- Hebb, D. (1943). *The organization of behavior: a neuropsychological theory* (2. baskı). London: Lawrence Erlbaum Associates.
- Hopfield, J.J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Biophysica*, 79(8), 2554-2558. doi:10.1073/pnas.79.8.2554
- Huang, W., Xiao, L., Wei, Z., Liu, H. ve Tang, S. (2015). A new pan-sharpening method with deep neural networks. *IEEE Geoscience and Remote Sensing Letters*, 12(5), 1037-1041. doi:10.1109/LGRS.2014.2376034
- Huang, G., Liu, Z., Van Der Maaten, L. ve Weinberger, K.Q. (2017, Haziran). *Densely connected convolutional networks*. IEEE Conference on Computer Vision and Pattern Recognition, HI, USA.
- Ji, S., Zhang, C., Xu, A., Shi, Y. ve Duan, Y. (2018). 3D convolutional neural networks for crop classification with multi-temporal remote sensing images. *Remote Sensing*, 10(1), 75. doi:10.3390/rs10010075
- Jiao, J., Zhang, Y., Sun, H., Yang, X., Gao, X., Hong, W., ... Sun, X. (2018). A densely connected end-to-end neural network for multiscale and multiscale SAR ship detection. *IEEE Access*, 6, 20881-20892. doi:10.1109/ACCESS.2018.2825376
- Jiao, L., Zhang, F., Liu, F., Yang, S., Li, L., Feng, Z. ve Qu, R. (2019). A survey of deep learning-based object detection. *IEEE Access*, 7, 128837-128868. doi:10.1109/ACCESS.2019.2939201
- Jin, J., Dundar, A. ve Culurciello, E. (2015, Aralık). *Flattened convolutional neural networks for feedforward acceleration*. International Conference on Learning Representations, San Diego, ABD.
- Kaiser, P., Wegner, J. D., Lucchi, A., Jaggi, M., Hofmann, T. ve Schindler, K. (2017). Learning aerial image segmentation from online maps. *IEEE Transactions on Geoscience and Remote Sensing*, 55(11), 6054-6068. doi:10.1109/TGRS.2017.2719738
- Kang, M., Lin, Z., Xiangguang, L. ve Ji, K. (2017, Mayıs). *A modified faster R-CNN based on CFAR algorithm for SAR ship detection*. International Workshop on Remote Sensing with Intelligent Processing, Shanghai, Çin.

- Kavzoglu, T. ve Mather, P.M. (1998, Eylül). *Assessing artificial neural network pruning algorithms*. Proceedings of the 24th Annual Conference and Exhibition of the Remote Sensing Society, Greenwich, Birleşik Krallık.
- Kavzoglu, T. ve Mather, P.M. (1999). Pruning artificial neural networks: an example using land cover classification of multi-sensor images. *International Journal of Remote Sensing*, 20(14), 2787-2803. doi:10.1080/014311699211796
- Kavzoglu, T. ve Mather, P.M. (2003). The use of backpropagating artificial neural networks in land cover classification. *International Journal of Remote Sensing*, 24(23), 4907-4938. doi:10.1080/0143116031000114851
- Khelifi, L. ve Mignotte, M. (2020). Deep learning for change detection in remote sensing images: Comprehensive review and meta-analysis. *IEEE Access*, 8, 126385–126400. doi:10.1109/ACCESS.2020.3008036
- Khan, A., Sohail, A., Zahoora, U. ve Qureshi, A.S. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, 53(8), 5455-5516. doi:10.1007/s10462-020-09825-6
- Khan, S., Rahmani, H., Shah, S.A.A. ve Bennamoun, M. (2018). A guide to convolutional neural networks for computer vision (1. baskı). *Avustralya: Morgan & Claypool*
- Koutsoukas, A., Monaghan, K.J., Li, X. ve Huan, J. (2017). Deep-learning: Investigating deep neural networks hyper-parameters and comparison of performance to shallow methods for modeling bioactivity data. *Journal of Cheminformatics*, 9(1), 42. doi:10.1186/s13321-017-0226-y
- Krizhevsky, A., Sutskever, I. ve Hinton, G.E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90. doi:10.1145/3065386
- LeCun, Y. (1989). *Generalization and network design strategies* (CRGTR-89-4), University of Toronto.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2323. doi:10.1109/5.726791
- LeCun, Y., Bengio, Y. ve Hinton, G. (2015). Deep Learning. *Nature*, 521, 436-444. doi:10.1038/nature14539
- Li, H., Peng, J., Tao, C., Chen, J.J. ve Deng, M. (2017). What do we learn by semantic scene understanding for remote sensing imagery in CNN framework? Erişim Adresi: <https://arxiv.org/abs/1705.07077>
- Li, S., Song, W., Fang, L., Chen, Y., Ghamisi, P. ve Benediktsson, J.A. (2019). Deep learning for hyperspectral image classification: an overview. *IEEE Transactions on Geoscience and Remote Sensing*, 57(9), 6690-6709. doi:10.1109/TGRS.2019.2907932
- Li, S., Dragicevic, S., Anton, F., Sester, M., Winter, S., Coltekin, A., ... Cheng, T. (2015). Geospatial big data handling theory and methods: a review and research challenges. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115(2016), 119-133. doi:10.3390/ijgi5050055.
- Li, Z., Wang, R., Zhang, W., Hu, F. ve Meng, L. (2019). Multiscale features supported Deeplabv3+ optimization scheme for accurate water semantic segmentation. *IEEE Access*, 7, 155787-155804. doi:10.1109/ACCESS.2019.2949635
- Li, W., Zou, Z. ve Shi, Z. (2020). Deep matting for cloud detection in remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 58(12), 8490-8502. doi:10.1109/tgrs.2020.2988265
- Li, X., Zhan, G., Huang, H.H., Wang, Z. ve Zheng, W. (2016, Ağustos). *Performance analysis of GPU-based convolutional neural networks*. Proceedings of the International Conference on Parallel Processing, PA, USA.
- Li, Y., Zhang, H. ve Shen, Q. (2017). Spectral – spatial classification of hyperspectral imagery with 3D Convolutional Neural Network. *Remote Sensing*, 9(1), 67. doi:10.3390/rs9010067

- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y. ve Alsaadi, F.E. (2017). A survey of deep neural network architectures and their applications. *Neurocomputing*, 234, 11–26. doi:10.1016/j.neucom.2016.12.038
- Liu, B., Li, Y., Li, G. ve Liu, A. (2019). A Spectral feature based convolutional neural network for classification of sea surface oil spill. *ISPRS International Journal of Geo-Information*, 8(4), 160. doi:10.3390/ijgi8040160
- Liu, X., Mei, S., Zhang, Z., Zhang, Y., Ji, J. ve Du, Q. (2019, Kasım). *Decs-Net: Convolutional Self-Encoding network for hyperspectral image denoising*. IEEE International Geoscience and Remote Sensing Symposium, Yokohama, Japonya.
- Luus, F.P.S., Salmon, B.P., Van Den Bergh, F. ve Maharaj, B.T.J. (2015). Multiview deep learning for land-use classification. *IEEE Geoscience and Remote Sensing Letters*, 12(12), 2448-2452. doi:10.1109/LGRS.2015.2483680
- Ma, Y., Wu, H., Wang, L., Huang, B., Ranjan, R., Zomaya, A. ve Jie, W. (2015). Remote sensing big data computing: challenges and opportunities. *Future Generation Computer Systems*, 51, 47-60. doi:10.1016/j.future.2014.10.029
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G. ve Johnson, B.A. (2019). Deep learning in remote sensing applications: a meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 152, 166-177. doi:10.1016/j.isprs.2019.04.01
- Maffei, A., Haut, J.M., Paoletti, M.E., Plaza, J., Bruzzone, L. ve Plaza, A. (2020). A single model CNN for hyperspectral image denoising. *IEEE Transactions on Geoscience and Remote Sensing*, 58(4), 2516-2529. doi:10.1109/TGRS.2019.295206
- Mahdianpari, M., Salehi, B., Rezaee, M., Mohammadimanesh, F. ve Zhang, Y. (2018). Very deep convolutional neural networks for complex land cover mapping using multispectral remote sensing imagery. *Remote Sensing*, 10(7), 1119. doi:10.3390/rs10071119
- Maggiori, E., Tarabalka, Y., Charpiat, G. ve Alliez, P. (2017). Convolutional neural networks for large-scale remote sensing image classification. *IEEE Transactions On Geoscience And Remote Sensing*, 55(2), 645-657. doi:10.1109/TGRS.2016.2612821
- McCulloch, W.S. ve Pitts, W. (1943). A logical calculus of the ideas immanent innervous activity. *Bulletin of Mathematical Biophysics*, 5, 115-133. doi:10.1007/BF02478259
- Meng, X., Shen, H., Li, H., Zhang, L. ve Fu, R. (2019). Review of the pansharpening methods for remote sensing images based on the idea of meta-analysis: Practical discussion and challenges. *Information Fusion*, 46(June), 102–113. doi:10.1016/j.inffus.2018.05.006
- Meng, L., Peng, Z., Zhou, J., Zhang, J., Lu, Z., Baumann, A. ve Du, Y. (2020). Real-time detection of ground objects based on unmanned aerial vehicle remote sensing with deep learning: application in excavator detection for dipeline safety. *Remote Sensing*, 12(1), 182. doi:10.3390/RS12010182
- Minsky, M. ve Papert, S. (1970). A review of perceptrons : an introduction to computational geometry. *Information and Control*, 17, 501-522. doi:10.1016/S0019-9958(70)90409-2
- Nguyen, H.V., Ulfarsson, M.O. ve Sveinsson, J.R. (2020, Ekim). Sure based Convolutional Neural Networks for hyperspectral image denoising. *International Geoscience and Remote Sensing Symposium*, HI, ABD.
- Nwankpa, C., Ijomah, W., Gachagan, A. ve Marshall, S. (2020, Aralık). *Activation functions: comparison of trends in practice and research for deep learning*. 2nd International Conference on Computational Sciences and Technologies, Jamshoro, Pakistan.
- Özçelik, F., Algancı, U., Sertel, E. ve Ünal, G., (2021). Rethinking CNN-Based pansharpening: guided colorization of panchromatic images via GANs. *IEEE Transactions on Geoscience And Remote Sensing*, 59(4), 3486-3501. doi:10.1109/TGRS.2020.3010441.
- Özdemir, M. (2017). Görüntü Keskinleştirme Yöntemlerinin Nesne-Yönelimli Sınıflandırma Açısından Değerlendirilmesi. *Harita Dergisi*, Temmuz(158), 26–34.



- Parvat, A., Chavan, J., Kadam, S., Dev, S. ve Pathak, V. (2017, Ocak). *A survey of deep-learning frameworks*. International Conference on Inventive Systems and Control, Coimbatore, Hindistan.
- Peng, L., Qiu, X., Ding, C. ve Tie, W. (2019, Kasım). *Generating 3d point clouds from a single SAR image using 3d reconstruction network*. IEEE International Geoscience and Remote Sensing Symposium, Yokohama, Japan.
- Ren, S., He, K., Girshick, R. ve Sun, J. (2017). *Faster R-CNN: towards real-time object detection with region proposal networks*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137–1149. doi:10.1109/TAMI.2016.2577031
- Qing, C., Ruan, J., Xu, X., Ren, J. ve Zabalza, J. (2019). *Spatial-spectral classification of hyperspectral images: A deep learning framework with Markov Random fields-based modelling*. *IET Image Processing*, 13(2), 235–245. doi:10.1049/ietipr.2018.5727
- Rosenblatt, F. (1958). *The perceptron: a probabilistic model for information storage and organization in the brain*. *Psychological Review*, 65(6), 386–408. doi:10.1037/h0042519
- Rusyn, B., Korniy, V., Lutsyk, O. ve Kosarevych, R. (2019, Eylül). *Deep learning for atmospheric cloud image segmentation*. *International Scientific and Practical Conference on Electronics and Information Technologies*, Lviv, Ukraine.
- Saha, S., Mou, L., Qiu, C., Zhu, X. X., Bovolo, F., ve Bruzzone, L. (2020, Ekim). *A novel approach to unsupervised segmentation of multitemporal VHR images based on deep learning*. International Geoscience and Remote Sensing Symposium, Waikoloa, ABD.
- Salman, H., Grover, J. ve Shankar, T. (2018). *Hierarchical Reinforcement Learning for Sequencing Behaviors*. *Neural Computation*, 27(3), 2709–2733. doi:10.1162/NECO\_a\_00990
- Schmidhuber, J. (2015). *Deep Learning in neural networks: An overview*. *Neural Networks*, 61, 85–117. doi:10.1016/j.neunet.201409.003
- Schwalbe, U. (2019). *Algorithms, machine learning, and collusion*. *Journal of Competition Law & Economics*. 14(4), 568–607. doi:10.1093/joclec/nhz004
- Sidorov, O. ve Hardeberg, J. Y. (2019, Ekim). *Deep hyperspectral prior: Single-image denoising, inpainting, super-resolution*. International Conference on Computer Vision Workshop, Seoul, Kore.
- Simonyan, K. ve Zisserman, A. (2015, Mayıs). *Very deep convolutional networks for large-scale image recognition*. 3rd International Conference on Learning Representations, CA, ABD.
- Sildir, H., Aydin, E. ve Kavzoglu, T. (2020). *Design of feedforward neural networks in the classification of hyperspectral imagery using superstructural optimization*. *Remote Sensing*, 12(6), 956. doi:10.3390/rs12060956
- Sofu, A. M., Imamoglu, M., Kahraman, F., Cetin, G.B. ve Aptoula, E. (2020, Ekim). *Fine-Grained Urban land use and land cover classification through multi-temporal and multispectral remote sensing images*. Signal Processing and Communications Applications Conference, Gaziantep, Türkiye.
- Song, Y., Zhang, Z., Baghbaderani, R. K., Wang, F., Qu, Y., Stutts, C. ve Qi, H. (2019, Eylül). *Land cover classification for satellite images through 1D CNN*. 10th Workshop on Hyperspectral Imaging and Signal Processing: Evolution in Remote Sensing, Amsterdam, Hollanda.
- Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R. (2014). *Dropout: a simple way to prevent neural networks from overfitting*. *Journal of Machine Learning Research*, 15, 399–421. doi:10.1016/B978-1-4832-1446-7.50035-2
- Suresh Kumar, M., Keerthi, V., Anjnai, R. N., Manju Sarma, M. ve Bothale, V. (2020, Şubat). *Evaluation of machine learning methods for hyperspectral image classification*. IEEE India Geoscience and Remote Sensing Symposium, Gujarat, Hindistan.
- Sun, H., Li, L., Xu, M., Li, Q. ve Huang, Z. (2020). *Using minimum component and CNN for satellite remote sensing image cloud detection*. *IEEE Geoscience and Remote Sensing Letters*, 1–5. doi:10.1109/lgrs.2020.3014358

- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... Rabinovich, A. (2015). *Going deeper with convolutions*. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Boston, ABD.
- Tan, Q., Ling, J., Hu, J., Qin, X., ve Hu, J. (2020). Vehicle detection in high resolution satellite remote sensing images based on deep learning. *IEEE Access*, 8, 153394-153402. doi:10.1109/ACCESS.2020.301789
- Tuna, C., Ünal, G. ve Sertel, E., (2018). Single-frame super resolution of remote-sensing images by convolutional neural networks. *International Journal of Remote Sensing*, 39(8), 2463-2479. doi:10.1080/01431161.2018.1425561.
- Vakalopoulou, M., Karantzalos, K., Komodakis, N. ve Paragios, N. (2015, Temmuz). *Building detection in very high resolution multispektral data with deep learning features*. IEEE International Geoscience and Remote Sensing Symposium, Milano, İtalya.
- Vali, A., Comai, S. ve Matteucci, M. (2020). Deep learning for land use and land cover classification based on hyperspectral and multispectral earth observation data: A review. *Remote Sensing*, 12(15), 2495. doi:10.3390/rs12152495
- Wang, P., Alganci, U. ve Sertel, E. (2021). Comparative analysis on deep learning based pan-sharpening of very high-resolution satellite images. *International Journal of Environment and Geoinformatics*, 8(2), 150-165. doi:10.30897/ijegeo. 834760
- Wang, H. ve Raj, B. (2017). On the origin of deep learning. Erişim Adresi: <http://arxiv.org/abs/1702.07800>
- Wei, Y., Yuan, Q., Shen, H. ve Zhang, L. (2017). Boosting the accuracy of multi-spectral image pan-sharpening by learning a deep residual network. *IEEE Geoscience and Remote Sensing Letters*, 14(10), 1795-1799. doi:10.1109/LGRS.2017.2736020
- Wang, Q., Yuan, Z., Du, Q. ve Li, X. (2019). GETNET: a general end-to-end 2-d CNN framework for hyperspectral image change detection. *IEEE Transactions on Geoscience and Remote Sensing*, 57(1), 3–13. doi:10.1109/TGRS.2018.2849692
- Weng, Q., Mao, Z., Lin, J. ve Guo, W. (2017). Land-use classification via extreme learning classifier based on deep convolutional features. *IEEE Geoscience and Remote Sensing Letters*, 14(5), 704-708. doi:10.1109/LGRS.2017.2672643
- Widrow, B. ve Hoff, M.E. (1960, Ağustos). *Adaptive switching circuits*. 1960 IRE WESCON Convention Record, CA, ABD.
- Xu, X., Li, W., Ran, Q., Du, Q., Gao, L. ve Zhang, B. (2018). Multisource remote sensing data classification based on convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 56(2), 937-949. doi:10.1109/TGRS.2017.2756851
- Yang, Y., Gu, H., Han, Y. ve Li, H. (2020, Ekim). An end-to-end deep learning change detection framework for remote sensing images. *IEEE International Geoscience and Remote Sensing Symposium, HI, ABD*.
- Yang, H., Yuan, C., Li, B., Du, Y., Xing, J., Hu, W. ve Maybank, S.J. (2019). Asymmetric 3D Convolutional Neural Networks for action recognition. *Pattern Recognition*, 85(6), 1–12. doi:10.1016/j.patcog.2018.07.028
- Yılmaz, E.Ö. (2020). Uzaktan algılanmış verilerin derin öğrenme yöntemiyle sınıflandırılması (Yüksek Lisans Tezi). GTÜ, Fen Bilimleri Enstitüsü, Kocaeli.
- Yuan, M., Liu, Z., Wang, F., Yuan, M., Liu, Z. ve Wang, F. (2019). Evaluation of pre-training impact on fine-tuning for remote sensing scene classification. *Remote Sensing Letters*, 10(1), 49-58. doi:10.1080/2150704X.2018.1526423
- Yuan, Q., Shen, H., Li, T., Li, Z., Li, S., Jiang, Y., ... Zhang, L. (2020). Deep learning in environmental remote sensing: achievements and challenges. *Remote Sensing of Environment*, 241, 111716. doi:10.1016/j.rse.2020.111716
- Yuan, Q., Zhang, Q., Li, J., Shen, H. ve Zhang, L. (2019). Hyperspectral image denoising employing a spatial-spectral deep residual convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 57(2), 1205-1218. doi:10.1109/TGRS.2018.2865197

- Yue, J., Zhao, W., Mao, S. ve Liu, H. (2015). Spectral-spatial classification of hyperspectral images using deep convolutional neural networks. *Remote Sensing Letters*, 6(6), 468-477. doi:10.1080/2150704X.2015.1047045
- Zhang, L., Zhang, L. ve Du, B. (2016). Deep learning for remote sensing data: a technical tutorial on the state of the art. *IEEE Geoscience and Remote Sensing Magazine*, 4(2), 22-40. doi:10.1109/MGRS.2016.2540798
- Zhang, X., Xv, C., Shen, M., He, X. ve Du, W. (2018). Survey of convolutional neural network. *Advances in Intelligent Systems Research*, 147, 93-97. doi:10.2991/ncce18.2018.16
- Zhang, Y., Liu, C., Sun, M. ve Ou, Y. (2019). Pan-sharpening using an efficient bidirectional pyramid network. *IEEE Transactions on Geoscience and Remote Sensing*, 57(8), 5549-5563. doi:10.1109/TGRS.2019.2900419
- Zhang, Z., Zhang, C. ve Li, W. (2020, Ekim). Semantic segmentation of urban buildings from VHR remotely sensed imagery using attention-based CNN. *IEEE International Geoscience and Remote Sensing Symposium, HI, ABD*.
- Zhao, W. ve Du, S. (2016). Learning multiscale and deep representations for classifying remotely sensed imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 113(March), 155-165. doi:10.1016/j.isprsjprs.2016.01.004
- Zhao, W., Bo, Y., Chen, J., Tiede, D., Blaschke, T. ve Emery W.J. (2019). Exploring semantic elements for urban scene recognition: deep integration of high-resolution imagery and OpenStreetMap. *ISPRS Journal of Photogrammetry and Remote Sensing*, 151(2019), 237-250. doi:10.1016/j.isprsjprs.2019.03.019
- Zheng, X. ve Chen, T. (2020, Ekim). Segmentation of high spatial resolution remote sensing image based on U-Net Convolutional Networks. *2020 IEEE International Geoscience and Remote Sensing Symposium, HI, ABD*.
- Zhu, X.X., Tuia, D., Mou, L., Xia, G.S., Zhang, L., Xu, F. ve 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. doi:10.1109/MGRS.2017.2762307