

DERİN ÖĞRENME YÖNTEMLERİ İLE SEGMENTASYON ANALİZİNDE GÜNCEL YAKLAŞIMLAR

E. Altınoluk^a, Ö. Akçay^b, E. Ö. Avşar^b, U. Aydar^b

^a Çanakkale Onsekiz Mart Üniversitesi, Fen Bilimleri Enstitüsü, Coğrafi Bilgi Teknolojileri Anabilim Dalı, 17100

Çanakkale/Türkiye - esraltnoluk@gmail.com

^b Çanakkale Onsekiz Mart Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, 17100 Çanakkale/Türkiye – (akçay, ozguravsar, umutaydar)@comu.edu.tr

ANAHTAR KELİMELELER: Uzaktan Algılama, Derin öğrenme, Yapay Sinir Ağları, Semantik Segmentasyon,

ÖZET:

Uzaktan algılama ile elde edilen yüksek çözünürlüklü verilerin segmentasyonu ve sınıflandırılması; doğal afetlerin izlenmesi, kaçak yapılaşmaların belirlenmesi, kentsel planlamanın yapılabilmesi, arazi kullanımının belirlenmesi vb. konularda kullanılmaktadır. Bu amaçlarla kullanılan geleneksel sınıflandırma yöntemlerinin karşılaştığı en önemli zorluk yüksek çözünürlüklü görüntülerin taşıdığı yoğun ve detaylı bilgilerin istenilen düzeyde tespit edilememesidir. Son yıllardaki bilimsel gelişmelere bağlı olarak yüksek çözünürlüklü görüntülerin segmentasyon analizi derin öğrenme yöntemleriyle başarıyla gerçekleştirilebilmektedir. Derin öğrenmede semantik segmentasyon, görüntü içerisindeki bölgeleri veya objeleri belirleyip birbirinden ayırma, etiketleme ve sınıflandırma işlemi olarak tanımlanmaktadır. Sunulan çalışmada segmentasyon konusunda geliştirilen sinir ağı mimarileri ve bu mimarilerin geliştirme platformu olarak derin öğrenme kütüphaneleri incelenmiştir. Bu kapsamda derin öğrenme ile semantik segmentasyon konusunda bilimsel literatür taraması yapılarak kullanılan girdi verileri, performans ve doğruluk analizleri ele alınmıştır. Derin öğrenme ile görüntü analizindeki mevcut gelişmelerin bilim ve teknoloji alanına gelecekteki katkısı irdelenmiştir.

1. GİRİŞ

Uzaktan algılama (UA) sistemleri, yeryüzüne ait güncel bilgilere ulaşmamızı sağlayan önemli bir veri kaynağıdır. Elde edilen bu verilerin anlamlı bilgiye dönüştürülmesi için kullanılan en yaygın yöntem ise sınıflandırma'dır. UA' da sınıflandırma, görüntüdeki her bir pikseli ait olduğu sınıfa etiketleme işlemidir. Piksellerin spektral bilgilerinden yararlanarak sınıflandırma yapan piksel tabanlı yaklaşım, görüntülerin mekânsal çözünürlüklerindeki artış karşısında yetersiz kalmıştır. Bu nedenle benzer özelliklere sahip komşu pikseller gruplandırılarak segment ya da bölüt olarak ifade edilen nesnelere oluşturulmuş ve tekil pikselleri sınıflandırmak yerine oluşturulan nesnelere sınıflandırılması ile nesne tabanlı yaklaşım kullanılmaya başlanmıştır (Blaschke, 2010; Hussain, 2013; Tehrani, 2014).

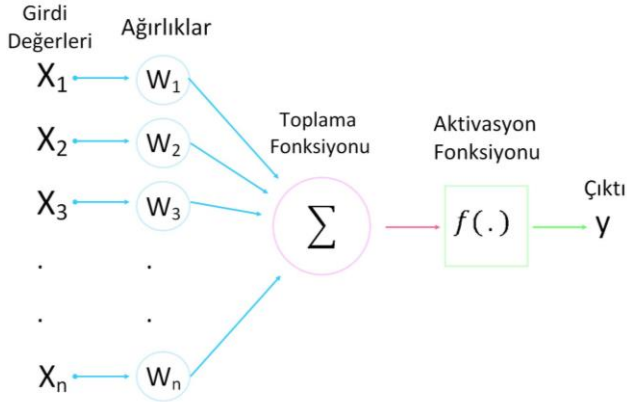
Son yıllarda sınıflandırma performanslarını artırmak amacıyla rastgele orman, destek vektör makineleri ve yapay sinir ağı gibi ileri sınıflandırma teknikleri öne çıkmaktadır. Literatürde yaygın kullanıma sahip tekniklerden biri olan rastgele orman (RO) algoritması, Breiman tarafından öne sürülen ve çok sayıda karar ağacının bir araya gelmesi ile oluşturulan bir sınıflandırıcıdır (Breiman, 2001). RO sınıflandırıcısını oluşturan karar ağaçlarının yapısında; öznitelik bilgilerini içeren düğümler, her bir düğümden rastgele seçilen öznitelik bilgilerini entropi, bilgi kazanımı ve gini indeksi gibi yöntemler kullanarak düğümleri ikiye ayıran dallar ve dallanma işlemi bitiminde sınıf değişkenlerini içeren yapraklar bulunmaktadır. Kullanıcı tarafından belirlenen 'n' adet karar ağacının yaptığı tahminler arasından en fazla tercih edilen sınıf belirlenip ilgili pikselin sınıflandırma işlemi

gerçekleştirilmektedir (Bosch, 2007; Çölkesen, 2015; Nitze, 2015).

Destek vektör makineleri (DVM), görüntü sınıflandırma problemlerinde yoğun ve etkili olarak kullanılan Cortes ve Vapnik tarafından geliştirilmiş bir sınıflandırma algoritmasıdır (Cortes ve Vapnik, 1995). DVM, temel olarak iki sınıfta birbirinden en iyi şekilde ayırabilmek için karar sınırı ya da hiperdüzlem adı verilen optimum sınırı belirlemeyi amaçlamaktadır. En uygun karar sınırı belirlenirken, sınıfların sınır düzlemlerinden yani destek vektörlerinden yararlanılmaktadır. Başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması için ileri sürülen DVM, daha sonra çok sınıflı doğrusal olmayan verilerin sınıflandırılması için geliştirilmiştir (Üstüner, 2013; Foody, 2004; Ayhan ve Erdoğan, 2014).

Makine sınıflandırması olarak da adlandırılan bu tekniklerin kullanılabilmesi için özellik çıkarımı yapmak gerekmektedir. Ancak özellik çıkarımı çok fazla zaman ve uzmanlık gerektiren zor bir işittir. Temelini yapay sinir ağlarının oluşturduğu derin öğrenme, bu sorunu çözerek büyük ilerleme sağlamıştır (Arel, 2010).

Yapay sinir ağı (YSA), insan beynindeki nöronların çalışma prensibinden ilham alınarak geliştirilmiş bir hesaplama ağıdır (Krogh, 2018; Manaswi, 2018). YSA hücre yapısının temelini oluşturan ilk fikir McCulloch ve Pitts tarafından ortaya atılmıştır (McCulloch ve Pitts, 1943). Daha sonra Rosenblatt bu çalışmadan yola çıkarak 1958 yılında ilk öğrenebilen sinir ağı olma özelliğine sahip yapay nöron modelini geliştirmiştir (Rosenblatt, 1958). Şekil 1, YSA'nın temelini oluşturan yapay nöron modelini göstermektedir.



Şekil 1. Yapay nöron modeli

Bir yapay nöron; girdi verileri $[X_1, X_2, X_3, \dots, X_n]$, ağırlıklar $[W_1, W_2, W_3, \dots, W_n]$, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı $[y]$ bölümlerinden oluşmaktadır. Girdi verileri ağırlıklarla çarpılarak toplama fonksiyonuna iletilir. Toplama fonksiyonu ile net girdi hesaplanır. Ardından aktivasyon fonksiyonu net girdiyi işleyerek bir çıktı değeri üretir. Burada amaç en uygun ağırlık değerlerini elde etmektir. Başlangıçta ağırlıklar çıktı değerini üretecek kadar iyi değildir. Bu ağırlıkları ayarlama sürecine öğrenme veya eğitim adı verilir. YSA, eğitim veri kümesi olarak sunulan örneklerle öğrenir ve öğrendikleri bilgileri daha önce görmedikleri veriler için kullanabilir (Gulli ve Kapoor, 2017; Shahin vd., 2001).

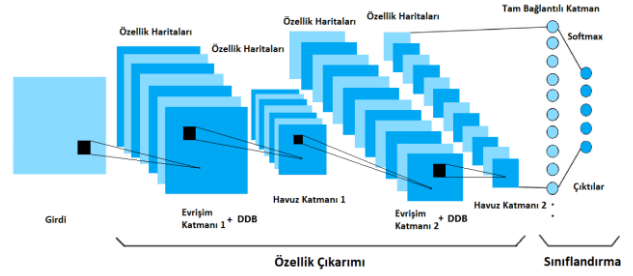
Bu çalışmanın ilk bölümünde geleneksel sınıflandırma yöntemlerinden ve YSA genel yapısından bahsedilmiştir. İkinci bölümde derin öğrenme ve görüntü işlemede yaygın kullanılan evrişimsel sinir ağı mimarisi, üçüncü bölümde ise semantik segmentasyon için tasarlanmış sinir ağları sunulmuştur. Son kısım olan bölüm 4'te ise bu mimarilerin uygulanması için kullanılan kütüphaneler özetlenmiştir.

2. DERİN ÖĞRENME

YSA'nın alt alanı olan derin öğrenme, içinde barındırdığı çok sayıda doğrusal olmayan katman ile verileri basitten karmaşığa doğru çözümlen bir hiyerarşik öğrenme yöntemidir (LeCun vd., 2015). Derin öğrenme, geleneksel sınıflandırma yöntemlerinden farklı olarak girdi verilerinin özelliklerini otomatik olarak öğrenebilmesi sayesinde birçok çalışmada başarısını ortaya koymuştur (LeCun vd., 1998; Krizhevsky vd., 2012; Cireşan vd., 2012; He vd., 2016).


2.1 Evrişimsel Sinir Ağı

Derin öğrenmenin en popüler mimarisi olan Evrişimsel Sinir Ağı (ESA), genel olarak nesne tanıma ve tek etiketli görüntü sınıflandırma gibi çalışmalarda kullanılmaktadır (Krizhevsky vd., 2012). ESA mimarisi; evrişim katmanları, düzleştirilmiş doğrusal birimler (DDB), havuzlama katmanları ve tam bağlantılı katman adı verilen işlemlerin bir araya gelmesiyle oluşmaktadır (Şekil 2). ESA, özellik çıkarımı ve sınıflandırma olmak üzere iki temel aşamadan oluşmaktadır. Özellik çıkarımı, girdi verisine evrişim ve havuzlama işlemlerinin uygulanmasıyla ortaya çıkan anlamsal bilgilerdir, TBK ise bu bilgileri kullanarak ikinci aşama olan sınıflandırma işlemini gerçekleştirmektedir.




Şekil 2. ESA mimarisi örneği

ESA'nın ilk katmanı olan evrişim katmanı, filtrelerin şekil 3'te gösterildiği gibi girdi verisi üzerinde hareket ettirilmesi (adım sayısına göre) esasına dayanır. Kaydırma esnasında görüntü üzerindeki piksel değerleri ile filtredeki değerler çarpılır. Elde edilen değerler toplanarak net sonuç bulunur, bu işlemin tüm görsele uygulanmasıyla özellik haritası olarak adlandırılan yeni bir görsel elde edilir. Evrişim katmanından hemen sonra aktivasyon fonksiyonu olarak bilinen DDB fonksiyonu uygulanır. Girdi verisinin negatif piksel değerlerini sıfır olarak değiştirmekle görevli olan bu fonksiyon, ağırlık daha hızlı öğrenmesini sağlamaktadır (Patterson ve Gibson, 2017; Kızrak ve Bolat, 2018).



Şekil 3. Evrişim işlemi

Havuz katmanı, filtreler yardımıyla özellik haritalarının boyutlarını düşürerek ağıdaki parametrelerin miktarını azaltmayı amaçlamaktadır. Evrişim katmanında olduğu gibi filtreler kullanılan bu katmanda, maksimum havuzlama ve ortalama havuzlama isimleri ile ifade edilen iki tür havuzlama katmanı kullanılmaktadır. Gezdiren filtreler piksellerin maksimum değerini alıyorsa maksimum havuz, ortalama değerini alıyorsa ortalama havuz olarak adlandırılır (Pattanayak, 2017; Osinga, 2018). Uygulamalarda daha iyi performans gösterdiği için maksimum havuzlama daha sık tercih edilmektedir. Şekil 4'te 2x2 boyutlu ve 2 adımlı maksimum havuzlama örneği gösterilmektedir.




Şekil 4. Maksimum havuzlama

Son olarak sınıflandırma aşamasında bulunan tam bağlantılı katmanlar, kendinden önceki tüm alanlara bağlı olup her bir pikselin kategorizasyonu için belirlenen fonksiyon ile olasılık değerlerini hesaplamaktadır.

3. SEMANTİK SEGMENTASYON İÇİN GELİŞTİRİLEN SİNİR AĞLARI

3.1 Tam Evrişimsel Ağ

Tam evrişimsel ağ (TEA), anlamsal segmentasyon uygulamalarında kullanılmak üzere Long ve arkadaşları tarafından geliştirilen özel bir ESA mimarisidir (Long vd., 2015). ESA'dan farklı olarak TEA'da tam bağlantılı katmanlar evrişim katmanları ile değiştirilmiştir. Bu katmanların değiştirilmesi mekânsal bilgilerin korunmasını sağlamaktadır. Ayrıca TEA, girdi boyutlarını isteğe bağlı alabilmekte ve şekil 5'de görüldüğü gibi son katmanda ters evrişim işlemi ile yukarı örnekleme yaparak girdi görüntüsü ile eşdeğer boyutta segmentasyon haritaları üretebilmektedir (Tienin, 2018; García-Peraza-Herrera vd., 2016).




Şekil 5. TEA mimarisi örneği

TEA'nın farklı yukarı örnekleme katmanları ile oluşturulmuş TEA-32, TEA-16 ve TEA-8 olmak üzere üç versiyonu bulunmaktadır. Burada 32, 16 ve 8 olarak bahsedilen değerler TEA'ların ters evrişim katmanındaki adım miktarını gösterir. Bu çalışma kapsamında TEA-32 %89.1, TEA-16 %90.0 ve TEA-8 %90.3 başarı sağlamıştır (Long vd., 2015).

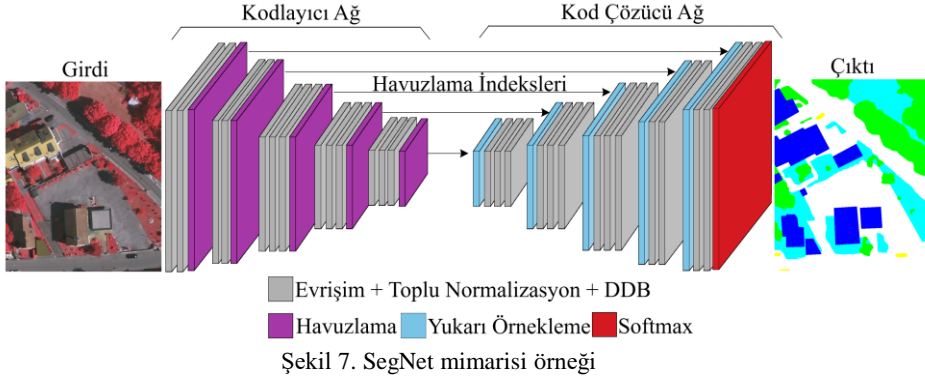
3.2 U-Net

U-net sinir ağı, çeşitli biyomedikal segmentasyon uygulamalarında kullanılmak üzere TEA'dan yararlanılarak geliştirilmiş bir derin öğrenme ağıdır. Simetrik bir yapıya sahip olan U-net adını U şeklinden almaktadır (Şekil 6). Tam bağlantılı katmanı bulunmaması nedeniyle farklı boyutlardaki görüntüler girdi olarak kullanılabilir. Ağın ilk bölümünde, DDB aktivasyon fonksiyonu ile birlikte uygulanan 3x3 filtrelili evrişim katmanı ve ardından 2 adımlı 2x2 boyutunda maksimum havuzlama katmanı kullanılmaktadır. Her alt örnekleme adımında özellik haritalarının sayısı 2 katına çıkmaktadır. Ağın ikinci bölümünde ise özellik haritalarının yukarı örnekleme, ardından yukarı örneklemeyle karşılık gelen kırılmış özellik haritasıyla birleşmesi ve ağın ilk bölümünde olduğu gibi DDB ile birlikte uygulanan 3x3 filtrelili evrişim katmanları bulunmaktadır. U-net sinir ağında birleşen özellik haritalarının boyutları uyuşmadığı için maksimum havuz işlemi yapılmadan önce özellik haritaları kırılır. Bu işlem kaybedilen bazı bilgilerin kurtarılmasına yardımcı olarak görüntülerin daha iyi segmentasyonunu sağlamaktadır. Son katmanda özellik haritasına 1x1 evrişim katmanının uygulanması ile birlikte segmentasyon haritası üretilmektedir (Pattanayak, 2017; Alom vd., 2017).


Ronneberger vd. tarafından yapılan bu çalışmada, elektron ve ışık mikroskobu ile elde edilen 512x512 boyutlarındaki görüntüler ile Caffe kütüphanesinde 3 farklı veri seti kullanarak segmentasyon işlemi gerçekleştirilmiştir. Veri setleri sırasıyla 30 adet elektron mikroskobu, 35 ve 20 adet ışık mikroskobu görüntüsü içermektedir. Uluslararası Biyomedikal Görüntüleme Sempozyumu (UBGS) 2015'i 0.0003529 çözümlenme hatası (warping error) ile kazanmış olmakla birlikte ikinci veri setinde %92 IOU, üçüncü veri setinde ise %77.5 IOU ile başarı elde edilmiştir (Ronneberger vd., 2015).



Şekil 6. U-Net mimarisi



Şekil 7. SegNet mimarisini gösteren bir diagramdır.



Şekil 8. Yukarı örnekleme işlemi gösteren bir diagramdır.

3.3 SegNet

SegNet, bir kodlayıcı ve buna karşılık gelen bir kod çözücü ağına, ardından piksel cinsinden sınıflandırma katmanına sahiptir (Şekil 7). Kodlayıcı ağ bölümünde evrişim katmanı ile özellik haritaları üretilmektedir. Üretilen bu özellik haritalarına toplu normalizasyon ve DDB aktivasyon fonksiyonu uygulandıktan sonra 2 adımlı 2x2 maksimum havuz katmanı ile alt örnekleme gerçekleştirilmektedir. Maksimum havuz katmanına bağlı olarak özellik haritalarının mekânsal çözünürlüğünde kayıplar meydana gelmektedir. Giderek artan kayıp (sınır detayı) semantik piksel etiketleme için önemli bir sorun teşkil etmektedir ve bundan dolayı sınır bilgilerinin depolanması gerekmektedir. Kodlayıcı ağdaki maksimum havuz indeksleri yani her havuz penceresinde maksimum özellik değerlerinin yerleri (Şekil 8), alt örnekleme yapılmadan önce hafızaya alınmaktadır. Kod çözücü ağda ise yukarı örnekleme ile üretilen seyrek özellik haritalarına evrişim ve toplu normalizasyon uygulanarak yoğun özellik haritaları üretilmektedir. Son katmanda ise softmax uygulanarak her bir piksel bağımsız olarak sınıflandırılmaktadır (Badrinarayanan vd., 2015; Badrinarayanan vd., 2017). Bu çalışmada, CamVid ve SUN RGB-D veri setleri kullanılarak 360x480 boyutlarındaki görüntüler ile Caffe kütüphanesinde segmentasyon işlemi gerçekleştirilmiştir. SegNet; 11 sınıfa sahip ve yol sahneleri içeren CamVid veri seti ile maksimum iterasyonda (>80K) %90.40, 37 sınıfa sahip ve iç mekân sahneleri içeren SUN RGB-D veri seti ile maksimum iterasyonda (>140K) %72.63 başarı elde edilmiştir.

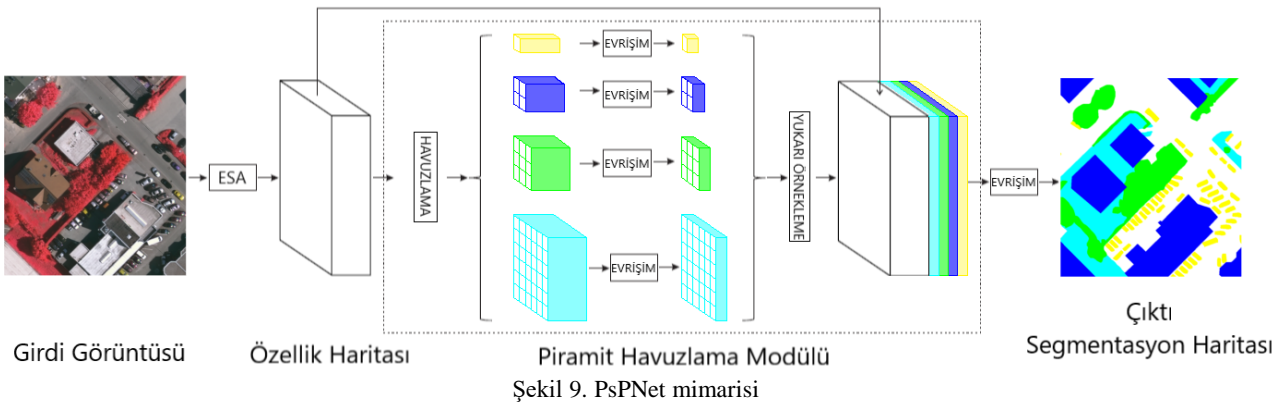
3.4 Piramit Sahne Ayrıştırma Ağı

Piramit sahne ayrıştırma ağı (PsPNet), nesne tespiti ve anlamsal segmentasyon uygulamalarında kullanılan ve ağ

yapısında bulundurduğu piramit havuzlama modülü sayesinde bağlamsal bilgileri öğrenme yeteneğine sahip bir derin öğrenme mimarisidir. Piramit havuzlaması, ESA'ların sabit boyutlu girdi görüntüsü kısıtlamasını ortadan kaldırmayı ve farklı ölçeklere sahip özellik haritalarını kullanarak nesnelere arasındaki bağlam bilgisi kaybını azaltmayı amaçlamaktadır (Chang ve Chen, 2018; Yu vd., 2018). Şekil 9'da mimarisini gösteren PsPNet, özellik haritalarını oluşturmak için standart bir ESA mimarisini (ResNet, DenseNet vb.) kullanmaktadır. Bu haritalar oluşturulduktan sonra 1x1, 2x2, 3x3 ve 6x6 boyutlarında 4 farklı seviyede ortalama ya da maksimum piramit havuzlama ve 1x1 filtrelili evrişim katmanı uygulanmaktadır. Farklı seviyede olan bu özellik haritalarına bilinear entropolasyon yöntemi uygulanarak yukarı örnekleme yapılır ve orijinal özellik haritası da dâhil hepsi birleştirilir. Son olarak evrişim katmanı uygulanarak semantik segmentasyon haritası üretilmektedir. ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nı 2016 yılında kazanan PsPNet mimarisini, PASCAL VOC 2012 veri setinde %85.4, Cityscapes veri setinde ise %80.2 mIoU başarı elde etmiştir (Zhao vd., 2017).

4. DERİN ÖĞRENME KÜTÜPHANELERİ

Derin öğrenmenin popülerlik kazanmasının en önemli sebeplerinden biri donanımsal sıkıntılarının giderilmiş olmasıdır. Grafik işlemci birimlerinin (GPU) üretimi, karmaşık yapıya sahip ağ eğitimlerinin daha hızlı gerçekleşmesini sağlamaktadır. Derin öğrenme uygulamaları için geliştirilen çeşitli özelliklere sahip kütüphaneler bulunmaktadır. En yaygın kullanılan bu kütüphaneler hakkında bilgiler Tablo 1'de özetlenmiştir.



Şekil 9. PsPNet mimarisini gösteren bir diagramdır.

Kütüphane	Geliştirici	Programlandığı Dil	Özellikleri
Tensorflow	Google	Python	-Açık kaynaklı bir kütüphane -Tensorboard ile ağ performansı görselleştirme -Birden fazla CPU ve GPU
Pytorch	Facebook	Python, C++, CUDA	-Kullanımı kolay ve hızlı -Önceden eğitilen modellere ulaşılabilirlik -GPU desteği
Matlab - Derin Öğrenme Araç Kuruşu	Mathworks	C, C++, Java, Matlab	-ONNX dönüştürücü sayesinde diğer derin öğrenme çerçeveleri (Tensorflow-Keras, Caffe) ile birlikte çalışabilirlik -GPU ile hızı hesaplama -Tasarlanan ağ topolojisini görselleştirme
Keras	Francois Chollet-Google	Python	-Tensorflow, Theano, Microsoft Cognitive Toolkit veya PlaidML üzerinde çalışabilirlik -GPU ile sorunsuz çalışabilme -Hızlı ve kolay kullanıma sahip
Caffe	Berkeley Vision and Learning Center (BVLC)	C++	-Model Zoo adında eğitimli modellerin olduğu kütüphaneye sahip -Python arayüzü ile kullanım -Görüntü işleme uygulamalarında hızlı
Theano	Montreal Institute for Learning Algorithms (MILA) Lab.	Python	-Yoshua Bengio, Eylül 2017'de geliştirilmeye devam edilmeyeceğini ilan etti.

Tablo 1. Derin öğrenme kütüphaneleri ve özellikleri

5. SONUÇ

Uzaktan algılama ile elde edilen yüksek çözünürlüklü görüntülerin doğru bir şekilde sınıflandırılması, arazi örtüsü ve kullanımı, afet izleme, hasar değerlendirme ve kentsel planlama vb. gibi uygulamalarda kullanılmak üzere birçok bilimsel çalışmaya araştırma konusu olmuştur. Bu nedenle kullanılacak sınıflandırma yönteminin seçimi ve geliştirilmesi oldukça önemlidir.

Bu çalışma kapsamında semantik segmentasyon alanında kullanılan klasik sınıflandırma yöntemleri, sinir ağı mimarileri ve bu mimarilerin geliştirme platformu olarak derin öğrenme kütüphaneleri incelenmiştir. Sonuç olarak, segmentasyon konusunda geliştirilen sinir ağı mimarilerinin oldukça başarılı olduğu gözlemlenmiştir.

KAYNAKLAR

Alom, M. Z., Hasan, M., Yakopcic, C., Taha, T. M., & Asari, V. K. (2018). Recurrent residual convolutional neural network based on u-net (r2u-net) for medical image segmentation. arXiv preprint arXiv:1802.06955.

Arel, I., Rose, D. C., & Karnowski, T. P. (2010). Deep machine learning-a new frontier in artificial intelligence research. IEEE computational intelligence magazine, 5(4), 13-18.

Ayhan, S., & Erdoğan, Ş. (2014). Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi, 9(1), 175-201.

Badrinarayanan, V., Handa, A., & Cipolla, R. (2015). Segnet: A deep convolutional encoder-decoder architecture for robust semantic pixel-wise labelling. arXiv preprint arXiv:1505.07293.

Badrinarayanan, V., Kendall, A., & Cipolla, R. (2017). Segnet: A deep convolutional encoder-decoder architecture for image segmentation. IEEE transactions on pattern analysis and machine intelligence, 39(12), 2481-2495.

Blaschke, T. 2010. Object based image analysis for remote sensing. ISPRS journal of photogrammetry and remote sensing, 65(1), 2-16.

Bosch, A., Zisserman, A., & Munoz, X. (2007, October). Image classification using random forests and ferns. In 2007 IEEE 11th international conference on computer vision (pp. 1-8). Ieee.

Breiman, L. (2001). Random forests. Machine learning, 45(1), 5-32.

Chang, J. R., & Chen, Y. S. (2018). Pyramid stereo matching network. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 5410-5418).

Ciresan, D., Giusti, A., Gambardella, L. M., & Schmidhuber, J. (2012). Deep neural networks segment neuronal membranes in electron microscopy images. In Advances in neural information processing systems (pp. 2843-2851).

Cortes, C., & Vapnik, V. (1995). Support-vector networks. Machine learning, 20(3), 273-297

- Çolkesen, İ. (2015). Yüksek Çözünürlüklü Uydu Görüntüleri Kullanarak Benzer Spektral Özelliklere Sahip Doğal Nesnelerin Ayırt Edilmesine Yönelik Bir Metodoloji Geliştirme (Doctoral dissertation, Fen Bilimleri Enstitüsü).
- Foody, G. M., & Mathur, A. (2004). A relative evaluation of multiclass image classification by support vector machines. *IEEE Transactions on geoscience and remote sensing*, 42(6), 1335-1343.
- García-Peraza-Herrera, L. C., Li, W., Gruijthuisen, C., Devreker, A., Attilakos, G., Deprest, J., ... & Ourselin, S. (2016, October). Real-time segmentation of non-rigid surgical tools based on deep learning and tracking. In *International Workshop on Computer-Assisted and Robotic Endoscopy* (pp. 84-95). Springer, Cham.
- Gulli, A., & Kapoor, A. (2017). *TensorFlow 1. x Deep Learning Cookbook: Over 90 unique recipes to solve artificial-intelligence driven problems with Python*. Packt Publishing Ltd.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Hussain, M., Chen, D., Cheng, A., Wei, H., & Stanley, D. (2013). Change detection from remotely sensed images: From pixel-based to object-based approaches. *ISPRS Journal of photogrammetry and remote sensing*, 80, 91-106.
- Kızrak, M. A., & Bolat, B. (2018). Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma. *Bilişim Teknolojileri Dergisi*, 11(3), 263-286.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (pp. 1097-1105).
- Krogh, A. (2008). What are artificial neural networks?. *Nature biotechnology*, 26(2), 195.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Long, J., Shelhamer, E., & Darrell, T. (2015). Fully convolutional networks for semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3431-3440).
- Manaswi, N. K. (2018). Developing Chatbots. In *Deep Learning with Applications Using Python* (pp. 145-170). Apress, Berkeley, CA.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133.
- Nitze, I., Barrett, B., & Cawkwell, F. (2015). Temporal optimisation of image acquisition for land cover classification with Random Forest and MODIS time-series. *International Journal of Applied Earth Observation and Geoinformation*, 34, 136-146.
- Osinga, D. (2018). *Deep Learning Cookbook*. United States of America.
- Pattanayak, S. 2017. *Pro Deep Learning with TensorFlow*. Bangalore, Karnataka, India
- Patterson, J., & Gibson, A. 2017. *Deep Learning A Practitioner's Approach (First Edition)*. United States of America.
- Ronneberger, O., Fischer, P., & Brox, T. (2015, October). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention* (pp. 234-241). Springer, Cham.
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Shahin, M. A., Jaksa, M. B., & Maier, H. R. (2001). Artificial neural network applications in geotechnical engineering. *Australian geomechanics*, 36(1), 49-62.
- Tehrany, M. S., Pradhan, B., & Jebuv, M. N. (2014). A comparative assessment between object and pixel-based classification approaches for land use/land cover mapping using SPOT 5 imagery. *Geocarto International*, 29(4), 351-369.
- TIENIN, B. W. 2018. *Cloud Coverage Prediction With Deep Learning Methods*. Master Thesis, Çukurova University Institute of Natural and Applied Sciences Department of Computer Eengineering, Adana
- Üstüner, M. (2013). Destek vektör makineleri yöntemi ile arazi kullanımı sınıflandırılmasında kernel fonksiyonlarına ait karşılaştırmalı parametre duyarlık analizi: Rapideye ve spot örneği. Yüksek Lisans Tezi. Fen Bilimleri Enstitüsü.
- Yu, B., Yang, L., & Chen, F. (2018). Semantic segmentation for high spatial resolution remote sensing images based on convolution neural network and pyramid pooling module. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, (99), 1-10.
- Zhao, H., Shi, J., Qi, X., Wang, X., & Jia, J. (2017). Pyramid scene parsing network. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2881-2890).