

UZAKTAN ALGILAMADA DERİN ÖĞRENME DEEP LEARNING IN REMOTE SENSING

M. E. Yüksel^a, E. Erdem^b, S. E. Yüksel^c

^a Genel Cerrahi Ana Bilim Dalı, Aksaray Üniversitesi Tıp Fakültesi, 68100 Aksaray Türkiye – doctormehmeteren@yahoo.com

^b Bilgisayar Mühendisliği Bölümü, Hacettepe Üniversitesi, 06800 Ankara Türkiye – erkut@cs.hacettepe.edu.tr

^c Elektrik ve Elektronik Mühendisliği Bölümü, Hacettepe Üniversitesi, 06800 Ankara Türkiye – eyuksel@ee.hacettepe.edu.tr

ANAHTAR KELİMELER: Derin Öğrenme, Uzaktan Algılama, Tıp Uygulamaları, Savunma Sanayii Uygulamaları.

KEY WORDS: Deep Learning, Remote Sensing, Applications in Medicine, Applications in Defence and Security.

ÖZ:

Son yıllarda tıptan tarıma, savunma sanayisinden uzay araştırmalarına kadar, uzaktan algılama gerektiren birçok alanda derin öğrenme yöntemleri öne çıkmakta ve bu yöntemler, geleneksel yöntemlere göre çok başarılı sonuçlar vermektedir. Derin öğrenme ile klasik görsel tanıma yöntemleri arasındaki en büyük fark, derin öğrenme yöntemlerinin öznelikleri eldeki verilerden otomatik olarak öğrenmesidir. Bunu yaparken, hem öznelik, hem de sınıflandırıcı öğrenimi, çok büyük veri kümelerinin etkin kullanımı ile uçtan uca bir öğrenme çerçevesinde gerçekleştirilir. Bu çalışmada, derin öğrenmenin hangi uzaktan algılama problemlerinde kullanıldığı anlatılacak; tıp ve savunma sanayii alanlarındaki araştırmalar özel olarak incelenecektir. Bu problemlerde eldeki verilerin özelliklerine göre ne gibi derin öğrenme mimarileri, yöntemleri ve algoritmaları seçilmesi gerektiği detaylandırılacaktır.

ABSTRACT:

In recent years, deep learning methods have come to the forefront in many areas that require remote sensing, from medicine to agriculture, from defense industry to space research; and these methods have given very successful results compared to traditional methods. The major difference between deep learning and classical recognition methods is that deep learning methods automatically learn the attributes from the available data. In doing so, both feature learning and classifier learning are carried out in an end-to-end learning framework with an effective use of very large datasets. In this study, the remote sensing problems that can be solved with deep learning is explained with a particular emphasis on research in the fields of medicine and defense. Then we elaborate on what kind of deep learning architectures, methods and algorithms should be chosen according to the characteristics of the available data.

1. GİRİŞ

Yapay sinir ağlarına dayanan derin öğrenme olarak adlandırılan yapay öğrenme yaklaşımları, geçtiğimiz son 10 yılda bilgisayar gözü de dahil olmak üzere yapay zeka ile ilgili birçok alanda önemli gelişmelerin yaşanmasına yol açmıştır. Derin modellerin bu derecede başarılı olmalarının altında yatan unsurlardan biri bu modellerin gerçekleştirdikleri uçtan uca (*end-to-end*) öğrenmedir. Sığ yapay öğrenme modellerinin öğrenmede kullanageldikleri ham veriden elde edilen ve elle tasarlanmış özneliklerden farklı olarak bu derin modeller içerdikleri uçtan uca yaklaşımı sayesinde ilgili probleme özel bir dizi öznelik ham verinin kendisinden ve farklı soyutlama düzeylerinde öğrenebilmektedirler. Ancak bu özneliklerin ayırt ediciliği ve dolayısıyla ilgili başarı oranları bu modellerin kapasiteleri kadar öğrenmenin üzerinde gerçekleştirildiği veri miktarına da doğrudan bağlıdır. Büyük verilere olan erişimin artmasıyla, bu verileri işlemek için son derece güçlü bir araç olan derin öğrenme, çağımızın çığır açan teknolojilerinden biri olarak listelere girmiştir (MIT Technology Review, 2013).

Google, Microsoft, Facebook gibi büyük şirketler başta olmak üzere, birçok şirket ve araştırmacı nesne algılama, hedef tespiti, görüntü bölütleme ve sınıflandırma problemlerinde derin öğrenmeyi aktif olarak kullanmaya başlamıştır. Bunda Google'ın sunduğu Tensorflow, Microsoft'un sunduğu CNTK, Facebook'un sunduğu Torch, ve benzeri Caffé, MXNet,

Theano, Deeplearning4j gibi açık kaynaklı yazılımların kolaylıkla erişilebilir olması da etkin olmuştur (De Felice, M. 2017).

Bu heyecan verici gelişmelerle birlikte, derin öğrenme giderek artan sayıda uygulama alanında tercih edilmeye başlanmıştır. Örneğin, evrişimsel sinir ağlarının (*convolutional neural networks*) (CNN'lerin) evrişimsel ve toparlama (*pooling*) katmanlar sayesinde öznelik haritalarını uzamsal olarak daralttığı, bu sayede de ham verilerden orta ve yüksek seviye soyut özellikleri çıkarmakta iyi olduğu kanıtlanmıştır (Zhu, 2017). Bu sayede, CNN'ler tarafından öğrenilen öznelikler görüntü tanıma, nesne algılama ve semantik bölütleme gibi problemlerde başarıyla kullanılmaktadır. Bir diğer yandan, derin öğrenme ailesinin önemli bir kolu olan yinelemeli sinir ağları (*recurrent neural network*), eylem tanıma, video analizi ve altyazılamaya gibi sıralı veri analizinde önemli başarılar göstermiştir.

Bu başarıların ardından ve artan veri ve hesaplama kaynakları sayesinde, derin öğrenme kullanımı nihayet uzaktan algılamada, tıpta ve savunma sanayiinde de artmaktadır. Tıp ve savunma sanayii uygulamaları, derin öğrenme için bazı yeni zorluklar sunmaktadır. Örneğin, her iki uygulamada da veriler çok kipli (*multi-modal*) olarak karşımıza çıkmaktadır. Savunma sanayiinde lidar, radar, SAR, hiperspektral vb. verilerin toplanması ve birlikte işlenmesi gerekirken; tıpta da genetik

bilgilerin, kan/idrar sonuçlarının MR, ultrason, x-ray vb. görüntülerden gelen bilgilerle birleştirilmesi gerekmektedir. Çok kiplilik, aynı zamanda farklı çözünürlükte, farklı zamanlarda veya uzun bir zaman dilimi boyunca alınmış (*time-series*) verilerin birlikte işlenmesini ve anlamlandırılmasını gerekli kılmaktadır.

Peki derin öğrenme nedir? Kapalı bir kutu gibi doğrudan alınıp kullanılmalı mıdır? Her sorunu çözer mi? Ne gibi alanlarda, hangi çalışmalarda, ne tip başarılar göstermiştir; bu başarıları elde edebilmek için hangi mimariler kullanılmıştır ve ne kadar başarıya ulaşılmıştır? İşte bu çalışmada, bu sorulara bazı cevaplar vermeye çalışacağız ve derin öğrenmenin savunma sanayiinde ve tıp alanındaki uygulamalarına değineceğiz.

2. DERİN ÖĞRENME MODELLERİ

Günümüzde evrimsel sinir ağları ve derin öğrenme tabanlı çözümler, görüntü tanıma, ses tanıma ve doğal dil işleme gibi birçok alanda iyi sonuçlar vermektedir. Özellikle görünür bantta elde edilmiş görüntülerin sınıflandırılmasında kullanılan derin evrimsel sinir ağları, 1998 yılında LeCun ve arkadaşları tarafından önerilen LeNet-5 olarak adlandırılan model ile el yazılarıyla oluşturulmuş rakam ve harflerin sınıflandırılmasının başarıyla gerçekleştirilmesiyle popülerleşmeye başlamıştır (LeCun vd., 1998). Daha sonra, 2012 yılında Krizhevsky ve arkadaşları 1000 farklı sınıfın yer aldığı 1.2 milyon veri kümesini içeren yüksek çözünürlüğe sahip görünür bantta yer alan görüntülerin sınıflandırılması problemiye yönelik olarak mimarisi LeNet'e benzeyen AlexNet adında bir derin yapay sinir ağı modeli önermişlerdir (Krizhevsky vd., 2012), ve bu yapıyla ImageNet Büyük Ölçekli Görsel Tanıma Mücadelesi'ni (ILSVRC) kazanmışlardır. Bu gelişmelerin ardından, artan veri miktarı ile de birlikte, GoogLeNet ve VGGNet ILSVRC 2014 yarışmasında en başarılı iki mimari olarak ilan edilmişlerdir (Szegedy C. vd. 2015).


AlexNet, VGGNet, GoogLeNet ve benzeri mimariler, her sınıf için etiketli veriye ihtiyaç duyan denetimli derin öğrenme yöntemleridir. Bir diğer önemli konu ise, derin ağların gözetimsiz öğrenme ile öğrenilmesidir. Denetimsiz öğrenmede kullanılan derin üretici ağ modelleri ise, gerçek veriye benzer sentetik veriler üretmekte ve mimarinin çekişmeli olarak veriye en çok benzeyen veriyi üretmesini sağlamaktadır. Denetimli ve denetimsiz derin öğrenme teknikleri, aşağıda daha detaylı olarak anlatılmaktadır.

3. DENETİMLİ DERİN ÖĞRENME

Yukarıda bahsi geçen AlexNet derin bir ağ olmanın yanı sıra, başarısını mümkün kılmış olan aşağıdaki diğer önemli özelliklerle donatılmıştır:

- Doğrusal olmayan fonksiyonlardan geleneksel olarak kullanılan sigmoid veya hiperbolik teğet fonksiyonları yerine, AlexNet'te doğrultucu olmayan lineer birimler (ReLU'lar) kullanılmıştır. ReLU birimleri hem eğitim süresini azaltmış, hem de eğitimin satüre olmasını engellemiştir.
- Bırakma katmanları (*dropout layers*) ile verinin ezberlenmesinin (*overfitting*) önüne geçilmiştir.
- Eğitim kümesinin boyutunu yapay olarak arttırmak için veri büyüme tekniklerini kullanılmıştır.
- ve bütün bu tekniklerin hızlı bir şekilde eğitime dahil edilebilmesi için grafik işleme birimlerinin (GPU) kullanılmıştır.

AlexNet ve benzeri mimarilerde göze çarpan ana elemanlardan olan evrişim, toplama, ve normalizasyon katmanları Şekil 1'de gösterilmektedir.



Şekil 1: AlexNet İlk Evrişim Katmanı ve Toparlama Katmanı Sonrası Girdi Verisi Boyut Değişimi (Salman 2018).

Günümüzde, yukarıda adı geçen AlexNet, VGGNet gibi mimariler direkt olarak kullanılabilceği gibi, bu mimariler tarafından öğrenilen filtreler birçok çalışmada görüntülerden öznelik çıkarma işleminde kullanılmaktadır. Burada da üç ana yöntem önümüze çıkmaktadır:

a. Tam-eğitilmiş (*fully-trained*) Ağlar ile Sınıflandırma:

Bu tarz eğitimde kullanıcı tüm mimariyi en baştan kurmakta ve bir derin ağı başından sonuna kendi verisi üzerinde eğitmektedir. Bir nevi AlexNet, GoogLeNet gibi mimarilerin benzerlerini yeniden öğrenmeye tekabül eden bu yöntemde, idealde milyonlarca veri ve bunları işleyebilecek büyüklükte GPU ve zaman gerekmektedir.

b. Önceden Eğitilmiş (*pre-trained*) Ağları Kullanarak Öznelik Çıkarımı

Bu tür öğrenmede ise AlexNet vb. ağların son katmanları çıkartılır (tamamen bağlı katmanlar ve evrimsel katmanların bazıları) ve geri kalan katmanlar direkt olarak öznelik çıkarımı için kullanılır. Özellikle küçük hacimli veriler üzerinde çalışılacaksa bu yöntem tercih edilmektedir.

c. Önceden Eğitilmiş (*pre-trained*) Ağlara İnce Ayar Yapılması ile Öznelik Çıkarımı

Bu yaklaşımda ise yine bir önceki öğrenmedeki gibi son katmanlar atılır ve ön katmanlar kullanılır; fakat sonrasında sondaki katmanlar istenen probleme göre yeniden eğitilir. Böylece hem eğitim zamanından kazanılmış olur, hem de istenilen probleme has bir derin ağı öğrenilmiş olur.

4. DENETİMSİZ DERİN ÖĞRENME

Derin öğrenme literatüründe son zamanlarda giderek önem kazanan bir konu, derin ağların gözetimsiz öğrenmede kullanım yollarının araştırılmasıdır ve bu bağlamda literatürde çeşitli derin üretici ağ modelleri önerilmiş durumdadır (Larochelle ve Murray, 2011; Goodfellow vd., 2014; Kingma ve Welling, 2014; Rezende vd., 2014; Gregor vd., 2015; Theis ve Bethge, 2015; Radford vd., 2016; van den Oord vd., 2016a; van den Oord vd., 2016b). Bu derin üretici modeller, sayısal görüntüler gibi yüksek boyutlu örnekler üzerinden bu örneklerin geldiği olasılık dağılımlarını öğrenmeyi amaçlamaktadırlar. Eğitim

sonrasında da öğrenilen bu dağılımlar üzerinden derin üretici ağlar kullanılarak gerçekçi duran sentetik örnekler üretilebilmektedir. Örneklerin sayısal görüntülerden oluştuğu durum için ilgili üretici modellerin amacı pikseller arasındaki bağlantı yakalayarak olabildiğince gerçekçi duran sentetik görüntüler üretebilmektir. Bu bağlar yakın piksellerin renk, parlaklık, doku cinsinden benzer görsel özellikler göstermesi gibi yerel ilişkiler olabileceği gibi, piksellerin bir araya gelip oluşturduğu parçalar üzerinden insan yüzü gibi belli bir nesnenin tanımlanabilmesi de olabilmektedir. Derin üretici ağlar, dayandıkları hesaplamasal yaklaşımlar göz önüne alındığında üç ana gruba ayrılabilir: 1. Otoresif üretici modeller (*autoregressive generative models*), 2. Değişimsel otomatik kodlayıcılar (*variational autoencoders*) ve 3. Çekişmeli üretici ağlar (*generative adversarial networks*).

Birinci grubu oluşturan otoresif üretici modeller (Larochelle ve Murray, 2011; Theis ve Bethge, 2015; van den Oord vd., 2016a; van den Oord vd., 2016b), üretici modeller içinde tamamen gözlemlenen model grubunu ifade etmektedir ve örnek üretimini bir dizi tahmini problemi olarak modellemektedirler. Bu gruptaki modellerin en bilinen örnekleri evrişimsel ve yinelemeli derin ağlar üzerinden pikseller arasındaki ilişkileri kodlayan PixelCNN (van den Oord vd., 2016b) ve PixelRNN (van den Oord vd., 2016a) modelleridir. Bu modellerin görüntü üretimi dizinin ardışık elemanlarını genelde diğer gruptan modellere kıyasla daha yavaş sürmektedir.

İkinci grup modelleri oluşturan değişimsel otomatik kodlayıcılar (Kingma ve Welling, 2014; Rezende vd., 2014; Gregor vd., 2015), ise otoresif üretici modellerden farklı olarak gözlemlenen herbir veri noktası için doğrudan gözlemlenemeyen saklı bir değişken tanımına giderek ilgili örneklerin genelde daha düşük boyutta ifade edildiği dağılımlarını kodlamaya çalışmaktadırlar. Bu yaklaşımın sağladığı en önemli avantaj bu modellere derin ağ yapısı ile hiyerarşinin çok rahat dahil edilebilmesidir. Saklı değişkenlerin sağladığı bir diğer avantaj da düşük boyutlu olmalarından dolayı örneklerin temsil ettiği verinin yapısını düşük boyutlu bir vektörle ifade edebilmeleridir ki bu veri gösteriminde sıkıştırma imkanı da sağlamaktadır. Öte yandan, sayısal görüntüleri örnek olarak işleyen değişimsel otomatik kodlayıcılar, sonraki üretme aşamasında genellikle kısmen bulanık örnekler üretmektedirler ve böylece bu örneklerin fotogerçekçilik seviyesi düşük olabilmektedir.

Son grubu oluşturan çekişmeli üretici ağlar (Goodfellow vd., 2014; Radford vd., 2016) ise dönüşüm tabanlı modellerdir ve gerçek örneklerin geldiği dağılımını öğrenme sürecini bir minimum-maksimum oyunu şeklinde modellemektedirler. Bu oyun kendi içinde üretici ve ayırt edici olmak üzere birbirleriyle yarışan iki ağdan oluşmaktadır. Üretici ağ gürültü vektörlerinden ayırt edici ağı kandırarak sentetik örnekler yaratmaya çalışırken; ayırt edici ağ ise eğitim verilerinden alınan gerçek örnekler ile üretici ağın ürettiği sentetik örnekleri ayırmaya çabalamaktadır. Bu şekilde, oynanan oyun sayesinde hem üretici ağ, hem de ayırt edici ağ çözmeye çalıştıkları problemlerde daha ustalaşmakta ve bunun sonucunda da üretici ağ gerçekçi duran, gerçeğinden ayırt edilemeyecek örnekler üretmeye başlamaktadır. Çekişmeli üretici ağların dayandıkları oyun teorisi tabanlı yaklaşım nedeniyle eğitimleri o derceden kolay değildir ancak üretilen sentetik görüntülerin kalitesi genelde otomatik kodlayıcıların çıktıklarına göre çok daha keskin ve doğal gözükmektedir.

5. DERİN ÖĞRENMENİN TIP ALANINDA UYGULAMALARI

Tıpta makine öğrenmesi hem tanı koymada, hem hastaların aciliyetlerine göre sıralanmasında ve hastalıkların ilerlemesinden önlenmesi amacıyla geliştirilmektedir.

Derin öğrenme ile radyolojik teşhislere çarpıcı bir örnek, 2018 yılında Rajpurkar ve arkadaşlarının yayınladığı çalışmadır (Rajpurkar vd., 2018). Bu çalışmada geliştirilen CheXNeXt adlı yazılım, önden görünüşlü akciğer grafilerinde pnömoni, plevral efüzyon, pulmoner kitleler ve nodüller dahil olmak üzere klinik olarak önemli 14 patolojiyi saptamak için derin bir öğrenme algoritması kullanmıştır. Ulusal Sağlık Enstitüleri (NIH) ChestX-ray8 veri kümesindeki yaklaşık 31.000 hastadan gelen 100.000'den fazla göğüs radyografisi üzerinde eğitilen bu yazılım, test için ayrılmış 420 görüntü üzerinde test edilmiş ve sonuçları 9 radyolog ile karşılaştırılmıştır. Bu görüntüler üzerinde CheXNeXt algoritması hem radyologlarla karşılaştırılabilir bir başarı göstermiş, hem de radyologların ortalama 240 dakikada inceledikleri bu veriyi 1.5dk gibi kısa bir sürede incelemiştir. Radyolojik görüntüler üzerinde geliştirilen bu gibi yazılımların, radyologların bulunmadığı veya yetersiz olduğu bölgelerde kullanabilecekleri; radyologların uzmanlık eksikliğine veya yorgunluğa bağlı olarak yanlış tanı koymalarını azaltabilecekleri düşünülmektedir (Saria vd., 2018).

Derin öğrenmenin önleyici olarak kullanılmasına çarpıcı bir örnek de Corey ve meslektaşlarının cerrahi ameliyatlardan sonrasındaki 30 gün içinde oluşabilecek komplikasyonları tespit etmeye yönelik çalışmalarıdır (Corey vd., 2018). Yaklaşık 88.000 hastadan elde edilen verilerle, hastaların yaşını, ırkını, cinsiyetini, kullandığı ilaçları ve komorbidite öyküsünü dikkate alan Pythia adlı bir yazılım geliştirilmiştir; ve bu yazılımın özellikle yüksek riskteki hastaları yüksek hassasiyetle tespit edebildiği görülmüştür. Bu tür önleyici destek sistemlerinin amacı, yüksek risk hastalarını tayin edebilmek, operasyon öncesi veya sonrası alınacak tedbirlerle bu hastalarda oluşabilecek komplikasyonları en aza indirmektir.

Benzer şekilde, piyasada satılan bir ürün olan MedAware yazılımı, hastanın geçmiş verilerini takip ederek, potansiyel ilaç hatalarını makine öğrenmesi yöntemleriyle tespit etmekte ve uyarıda bulunmaktadır.

6. DERİN ÖĞRENMENİN SAVUNMA ALANINDA UYGULAMALARI

Savunma sanayiinde derin öğrenme, hem görüntü ve sinyal işleme gerektiren hedef tespiti uygulamalarında, hem de iş yönetimine destek olacak şekilde karşımıza çıkmaktadır. İş yönetiminde makine öğrenmesine dinamik envanter optimizasyonu veya öngörücü bakım ve servisler gibi uygulamalarda ihtiyaç duyulmaktadır. Örneğin, sistemin kullanılan araçların ne zaman ömrünü dolduracağını veya arıza vereceğini tahmin etmesi ve buna göre sipariş vermesi; pili bitmekte olan bir araç için acilen pil tedariki yapılmasını sağlaması; tek bir görüntüden kullanılan cihazın neresinin bozulduğunu söylemesi istenmektedir (Lennon, 2018).

Hedef tespiti uygulamalarında ise hedeflerin uydulardan, İHA, uçak, drone gibi uçan sistemlerden, veya kara araçları ile sabit karargahlardan toplanan sinyal veya verilerden hızlı bir şekilde tespit edilebilmesi amaçlanmaktadır. Bu amaçla veriler, radar, SAR, lidar, hiperspektral, termal, elektro-optik, X-ray, mm-Dalga, terahertz gibi sensörlerden elde edilen sinyal veya görüntüler olabilmektedir. Derin öğrenme teknikleri ile bu

görüntüleri anlık olarak yorumlamanın yanısıra, hava koşullarını toplayacak, düşman davranışlarını tahmin edecek, dar boğaz noktalarını tespit edecek, kısacası görülmeyeni görecek, duyulmayı duyacak sistemler elde edilmesi hedeflenmektedir.

Çevresel koşulların derin öğrenme ile tahmin edilmesine örnek olarak, Dronner ve arkadaşları (Dronner, 2018) hem hava tahmininde bulunabilmek, hem de güneş enerjisini efektif bir şekilde dağıtabilmek için derin evrimsel sinir ağları ile bulut tahmini yapmışlardır. Ouala vd. (Ouala, 2018) ise UK Met Office tarafından sağlanan 7 senelik uydu verisini kullanarak, deniz yüzeyinin sıcaklığını ölçecek bir sistem geliştirmişlerdir.

Hedef tespit problemlerinde gemi algılama, hem ölçek farkından dolayı, hem de arkaplanın çeşitlilik göstermesinden dolayı önemli bir askeri problem olarak öne çıkmaktadır. Gemilerin tespit edilebilmesi amacıyla Fu vd. ve Yang vd. (Fu, 2018) (Yang, 2018) Quick Bird uydusundan elde edilen Google Earth görüntülerinden, Rainey ve arkadaşları (Rainey, 2016) DigitalGlobe uyduları WorldView-1 and WorldView-2 görüntülerinden; Khellal ve arkadaşları (Khellal, 2018) infrared görüntülerden; Wang ve arkadaşları (Wang, 2017) ise SAR görüntülerinden derin öğrenme yöntemleri ile gemi tespiti yapmışlardır.

Özel olarak hedef tespit problemlerinden biri olan mayın, tel ve el yapımı patlayıcı tespiti konusunda derin öğrenme ciddi rol oynamaktadır. Yere Nüfuz Eden Radar (YNR), gömülü hedef tespitinde yaygın olarak kullanılan bir araçtır. Aydın ve Yüksel ilgili çalışmalarında (Aydın ve Yüksel, 2017) (Aydın ve Yüksel, 2018) (Aydın ve Yüksel, 2019), benzer elektriksel iletkenliğe sahip hedeflerin sınıflandırmasında öznelik çıkarımının çok zor olması ve vakit alması nedeniyle, aktarım öğrenmesi ile derin öğrenme yöntemi kullanmışlar. Aktarım öğrenmesinde, AlexNet mimarisinin ilk iki katmanını alıp, son katmanını YNR sınıflandırması için eğitmişlerdir. Daha sonra, bir toprak tipinde öğrenilen modelin başka bir toprak tipine göre eğitilebilmesi için de çok görevli öğrenmeyi kullanmışlardır. Bu yöntemde de hedefin hangi tip (kuru, ıslak, nemli) toprakta olduğunu anlayan bir derin öğrenme mimarisi geliştirmişlerdir.

Benzer bir mimariyi ise Salman ve Yüksel (Salman ve Yüksel 2018) hiperspektral ve lidar verilerin füzyonu için kullanmışlardır. Fakat hiperspektral ve lidar verilerin boyutları klasik AlexNet görüntülerinden çok farklı olduğundan, bu boyutları eşitleyebilmek için çeşitli ön işleme yöntemleri önermişlerdir. Çıkan sonuçların geleneksel yöntemlere göre çok daha başarılı sonuçlar verdiğini göstermişlerdir.

SONUÇ

Bu çalışmada, günümüzde iyice popüler hale gelen derin öğrenme olarak adlandırılan yapay sinir ağları yaklaşımları ve onların genel özellikleri anlatılmıştır. Ayrıca, derin öğrenmenin uzaktan algılama, tıp ve savunma sanayii alanlarındaki uygulamalarına çeşitli örnekler verilmiştir. Bu çalışmaların elde ettikleri başarılar düşünüldüğünde derin öğrenmenin bu alanlarda önümüzdeki yıllarda da artan bir ivme ile kullanılacağını değerlendirmekteyiz.

TEŞEKKÜR

E. Erdem Türkiye Bilimler Akademisi Genç Bilim İnsanlarını Ödüllendirme Programı (TÜBA-GEBİP 2018) tarafından desteklenmektedir.

KAYNAKÇA

Aydın, E.; Yüksel, S.E. 2019. Transfer and Multitask Learning using Convolutional Neural Networks for Buried Wire Detection from Ground Penetrating Radar Data. *SPIE Detection and Sensing of Mines, Explosive Objects, and Obscured Targets XXIV*, Baltimore.

Aydın, E.; Yüksel, S.E. 2018. Transfer and Multitask Learning Method for Buried Wire Detection via GPR. *IEEE Signal Processing and Communications Applications Conference (SIU)*, Çeşme, 2-5 Mayıs, 2018.

Aydın, E.; Yüksel, S.E. 2017. Buried target detection with ground penetrating radar using deep learning method. *IEEE Signal Processing and Communications Applications Conference (SIU)*, Antalya.

Corey KM, Kashyap S, Lorenzi E, Lagoo-Deenadayalan SA, Heller K, Whalen K, et al. 2018. Development and validation of machine learning models to identify high-risk surgical patients using automatically curated electronic health record data (Pythia): A retrospective, single-site study. *PLoS Med* 15(11): e1002701.

De Felice, M. 2017. Which deep learning network is best for you? *IDG Communications*. [Online]. Available: <http://www.cio.com/article/3193689/artificial-intelligence/which-deep-learning-network-is-best-for-you.html>

Dronner, J.; Korfhage, N.; Egli, S.; Muhling, M.; Thies, B.; Bendix, J.; Freisleben, B.; Seeger, B. 2018. Fast Cloud Segmentation Using Convolutional Neural Networks. *Remote Sens.*, 10, 1782.

Fu, K.; Li, Y.; Sun, H.; Yang, X.; Xu, G.; Li, Y.; Sun, X. A. 2018. Ship Rotation Detection Model in Remote Sensing Images Based on Feature Fusion Pyramid Network and Deep Reinforcement Learning. *Remote Sens.*, 10, 1922.

Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. C., Bengio, Y. 2014. Generative Adversarial Nets. *NIPS*, 2672–2680.

Gregor, K., Danihelka, I., Graves, A., Rezende, D. J., Wierstra, D. 2015. DRAW: A Recurrent Neural Network for Image Generation, *ICML*, 1462–1471.

Khellal, A.; Ma, H.; Fei, Q. 2018. Convolutional Neural Network Based on Extreme Learning Machine for Maritime Ships Recognition in Infrared Images. *Sensors* 18(5): 1490.

Kingma, D. P., Welling M. 2014. Auto-encoding Variational Bayes. *ICLR*.

Krizhevsky A., Sutskever I., Hinton G. E.. 2012. ImageNet Classification with Deep Convolutional Neural Networks. *Neural Information Processing Systems (NIPS)*. 25. pp. 1097–1115.

Larochelle, H., Murray, I. 2011. The Neural Autoregressive Distribution Estimator. *AISTATS*.

Lecun Y., Bottou L., Bengio Y. and Haffner P., 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324.

- Lennon M. 2018. A Soldier's Load: Machine Learning In Defense And Other Industries. Digitalist Magazine.
- MIT Technology Review. 2013. 10 breakthrough technologies 2013. [Online]. Available: <https://www.technologyreview.com/lists/technologies/2013/>
- Ouala, S.; Fablet, R.; Herzet, C.; Chapron, B.; Pascual, A.; Collard, F.; Gaultier, L. 2018. Neural Network Based Kalman Filters for the Spatio-Temporal Interpolation of Satellite-Derived Sea Surface Temperature. *Remote Sens.*, 10, 1864.
- Radford, A., Metz, L., Chintala, S. 2016. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. *ICLR*.
- Rainey, K; Reeder, J.; and Corelli, G.A. 2016. Convolution neural networks for ship type recognition. *Proc. SPIE* 9844, Automatic Target Recognition XXVI, 984409.
- Rajpurkar P, Irvin J, Ball RL, Zhu K, Yang B, Mehta H, et al. 2018. Deep learning for chest radiograph diagnosis: A retrospective comparison of the CheXNeXt algorithm to practicing radiologists. *PLoS Med* 15(11): e1002686.
- Rezende, D. J., Mohamed, S., Wierstra, D. 2014. Stochastic Backpropagation and Approximate Inference in Deep Generative Models. *ICML*, 1278–1286.
- Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A. 2015. Going deeper with convolutions. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, pp. 1-9.
- Salman M. 2018. Hiperspektral ve Lidar Verilerinin Öznitelik ve Karar Seviyelerinde Tümlleştirilmesi ve Derin Evrişimli Sinir Ağlarıyla Sınıflandırılması. Hacettepe Üniversitesi Elektrik ve Elektronik Mühendisliği Yüksek Lisans Tezi.
- Salman M.; Yuksel, S.E. 2018. Fusion of hyperspectral image and LiDAR data and classification using deep convolutional neural networks. *IEEE Signal Processing and Communications Applications Conference (SIU)*, Izmir, Turkey, 2-5 May.
- Saria, S., Butte, A., & Sheikh, A. 2018. Better medicine through machine learning: What's real, and what's artificial?. *PLoS medicine*, 15(12), e1002721.
- Schiff GD, Volk LA, Volodarskaya M, Williams DH, Walsh L, Myers SG, et al. 2017. Screening for medication errors using an outlier detection system. *J Am Med Inform Assoc.* 2017 Mar 1;24(2):281-287.
- Theis, L., Bethge, M. 2015. Generative Image Modeling Using Spatial LSTMs, *NIPS*.
- van den Oord, A., Kalchbrenner, N., Kavukcuoglu, K. 2016a. Pixel Recurrent Neural Networks, *ICML*, 1747–1756.
- van den Oord, A., Kalchbrenner, N., Vinyals, O., Espeholt, L., Graves, A., Kavukcuoglu, K. 2016b. Conditional Image Generation with PixelCNN Decoders, *NIPS*.
- Wang, C., Zhang, H., Wu, F., Zhang, B., Tian, S. 2017. Ship classification with deep learning using COSMO-SkyMed SAR data. *Geoscience and Remote Sensing Symposium (IGARSS) 2017 IEEE International*, pp. 558-561.
- Yang, X.; Sun, H.; Fu, K.; Yang, J.; Sun, X.; Yan, M.; Guo, Z. Automatic Ship Detection in Remote Sensing Images from Google Earth of Complex Scenes Based on Multiscale Rotation Dense Feature Pyramid Networks. *Remote Sens.* 2018, 10, 132.
- Zhu, X.; Tuia, D.; Mou, L.; Xia, G.; Zhang, L.; Xu, F.; Fraundorfer, F. 2017. Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources. *IEEE Geoscience and Remote Sensing Magazine.* 5. 8-36.