

YNR ile Gömülü Tel Tespiti için Aktarım ve Çok Görevli Öğrenme Yöntemleri

Transfer and Multitask Learning Method for Buried Wire Detection via GPR

Enver AYDIN^{1,2}, Seniha Esen YÜKSEL²

¹ Aselsan, Ankara, Türkiye
enveraydin@aselsan.com.tr

² Elektrik ve Elektronik Mühendisliği Bölümü, Hacettepe Üniversitesi, Ankara, Türkiye
eyuksel@ee.hacettepe.edu.tr

Özetçe—Yere Nüfuz Eden Radar (YNR), gömülü hedef tespiti, sınıflandırması ve tanımlanması uygulamalarında yaygın olarak kullanılan bir araçtır. Aynı şekilde ve farklı materyaldeki hedeflerin sınıflandırılması, özellikle benzer elektriksel iletkenliğe sahip hedeflerde zor bir problemdir. Böyle bir sınıflandırma probleminde öznitelik çıkarımının çok zor olması ve vakit alması nedeniyle, derin öğrenme yöntemi kullanılmıştır. Derin öğrenme, verideki öznitelikleri ve sınıflandırıcıyı otomatik olarak öğrenmesi sayesinde son beş yıldır üstün performans sergileyerek öne çıkan bir yöntemdir. Bu bildirinin amacı, gömülü olarak bulunan hedeflerin yüksek başarımla doğru sınıflandırılmasıdır. Bu amaç doğrultusunda, öncelikle farklı özellikteki 3 çeşit toprağa gömülü hedeflerden oluşan veriler üretilmiştir. Daha sonra bu verilerdeki bakır ve plastik tellerin tespiti ve teşhisi için derin öğrenme, aktarım öğrenmesi ve çok görevli öğrenme yöntemleri önerilmiştir. Aktarım öğrenmesi, önceden çok sayıda veri ile eğitilmiş bir derin öğrenme modelinden kazanılan bilgilerin mevcut modele aktarılması işlemidir. Aktarım öğrenmesinde, derin öğrenme literatüründe çok başarılı sonuçlar veren VGGNet mimarisinin ilk altı katmanı YNR sınıflandırması için kullanılmıştır. Çok görevli öğrenme ise diğer ilgili görevlerin eğitim bilgilerini kullanarak bir göreve yönelik öğrenmeyi iyileştiren bir yaklaşımdır. Bu yöntemde de hedefin hangi tip (kuru, ıslak, nemli) toprakta olduğunu anlayan bir derin öğrenme mimarisi geliştirilmiştir. Önerilen yöntemlerin hedef tespitini iyileştirdiği görülmüştür.

Anahtar Kelimeler — Yere Nüfuz Eden Radar; derin öğrenme; aktarım öğrenmesi; çok görevli öğrenme; gprMax.

Abstract—Ground Penetrating Radar (GPR) is a widely used tool for buried target detection, classification and identification applications. Classification of targets in same shape and different materials is a particularly difficult problem, especially for targets with similar electrical conductivity. In such a classification problem, deep learning is used because it is very difficult to extract features. Deep learning is a method that has demonstrated state-of-art performance over the last five years thanks to automatic learning of the features and classifier. The purpose of this research is to correctly classify buried targets with high performance. For this purpose, firstly, data, composed of targets

buried in 3 types of soil, is produced. Then, deep learning, transfer learning and multitask learning methods were proposed for detection and identification of copper and plastic wires in this dataset. Transfer learning is the process of transferring information acquired from a deep learning model previously trained with a large number of data to the current model. For transfer learning, the first six layer of the VGGNet architecture, which yields very successful results in the deep learning literature, is used for GPR classification. Multitask learning is an approach that improves learning of a task, by using training information from other related tasks. For multitask learning, a deep learning architecture that detects the type of soil (dry, wet, damp) was developed. It has been shown that the proposed methods improve target detection.

Keywords — Ground Penetrating Radar, deep learning, transfer learning, multitask learning, gprMax.

I. GİRİŞ

Gömülü bir hedefin doğru olarak tespit edilebilmesi zor bir problemdir. Günümüzde, özellikle insan hayatını tehdit eden gömülü cisimler genelde plastikten yapılmakta veya çok az metal bileşen içermektedirler. Metal içermeyen veya az miktarda metal içeriğe sahip olan gömülü cisimlerin tespiti için YNR (Yere Nüfuz Eden Radar) sıklıkla kullanılmaktadır. YNR, görevi yeraltındaki nesnelere tespit etmek ve belirlemek olan bir radar olarak tanımlanmaktadır [1]. YNR, literatürdeki karşılaştırmalarda gömülü hedefleri tespit etmek için iyi performanslar elde eden bir uzaktan algılama teknolojisidir [2]–[5]. Gömülü hedef tespiti konusunda en iyi yöntem olarak gösterilmesine rağmen dezavantajları bulunmaktadır. YNR sisteminin gömülü cisim algılaması için gömülü hedefin gömülü olduğu toprak ile arasında dielektrik farklılık bulunması gerekmektedir. YNR sistemi açısından en önemli sorun bu farklılığın yeterince olmadığı durumlardan kaynaklanmaktadır. Bu soruna bağlı olarak dielektrik farklılık çok fazla değilse bu cisimlerin tespiti zorlaşmaktadır [6]. Büyük ve metalik nesnelere toprak yüzeyine daha yakın gömüldüklerinde tespit edilmeleri daha kolay olsa da; daha küçük, daha derine gömülmüş ve

dielektrik malzemelerden yapılmış nesnelere fark edilememektedir [7]. Ayrıca, hava-toprak geçişi ve hedef dışı yansımaların gömülü cisim imzalarına göre daha belirgin olması gömülü cisimlerin görünmemesine neden olmaktadır [8]. Derin öğrenme modeli, öznelikleri otomatik olarak öğrenmek için çok sayıda veriye ihtiyaç duymaktadır. Gerçek veri üretmenin maliyetli ve zor olması nedeniyle bu bildiride YNR benzetimi yapan gprMax programı ile sentetik YNR verisi üretilmiştir. Bu veriler, kuru/nemli/ıslak topraklara yerleştirilmiş bakır ve plastik tel hedefleri ile başka materyallerden yapılmış teller ve parazit cisimlerdir. Üretilen bu veriler sınıflandırma algoritmalarına girdi oluşturmuştur. Üretilen verilerin sayısal olarak az olması sebebiyle aktarım öğrenmesi yöntemi kullanılmıştır. Aktarım öğrenmesi, önceden çok sayıda veri ile eğitilmiş bir derin öğrenme modelinden kazanılan bilgilerin mevcut modele aktarılması işlemidir. Bu sayede önceden eğitilmiş modelin (VGGNet) çok sayıda veriden (~1,4M resim) kazandığı genel öznelikler (ör. renk ve kenar algılama), mevcut derin öğrenme modeline aktarılarak veri sayısının az olması problemi çözülmüştür. Aktarım öğrenmesi ile hedef tespit başarımında artış sağlanmıştır. Fakat farklı toprak türlerinde hedef tespitinin zorlaştığı görülmüştür. Bu nedenle hedef tespit başarımını daha da yükseltmek için çok görevli öğrenme yöntemi kullanılmıştır. Çok görevli öğrenme, diğer ilgili görevlerin eğitim bilgilerini kullanarak bir göreve yönelik öğrenmeyi iyileştiren bir yaklaşımdır. Bu çalışmada çok görevli öğrenmenin birincil görevi, hedefler ile hedef olmayan cisimlerin ayrılmasıdır. İkinci görevi ise toprak türünün tespitidir. Her görev için öğrenilenler, diğer görevlerin daha iyi öğrenilmesine yardımcı olabilir. Bu sayede, toprağın çeşidine göre hedef tespiti yapan, daha özelleştirilmiş bir sınıflandırıcı eğitilmiştir.

II. VERİ KÜMESİ

Bu çalışma kapsamında 2 farklı veri kümesi ile çalışılmıştır. Bu kümeler içerdikleri veriler aynı olmakla birlikte farklı sınıflara ayrılmışlardır. Veri kümelerinden ilkinde 2 sınıf oluşturulmuştur. Bunlardan ilkinde plastikten gömülü tel yerleştirilmiş ve bu sınıfa hedef sınıfı adı verilmiştir. Diğer sınıfa ise yine aynı şekildeki cisimler asfalt olarak gömülmüş ve ilave olarak bozuk yüzeyli cisimler eklenerek hedef-dışı sınıfı olarak adlandırılmıştır. Hedef tespit görevi için veri kümesinin eğitim, doğrulama ve test verilerinin dağılımı Çizelge 1’de gösterilmiştir.

ÇİZELGE 1. HEDEF TESPİT GÖREVİ İÇİN VERİ KÜMESİ

Gömülen Malzeme	HEDEF			HEDEF-DIŞI					
	Tel (Plastik)			Tel (Asfalt)			Bozuk yüzeyli cisimler		
Toprak Türü	Kuru	Nemli	Islak	Kuru	Nemli	Islak	Kuru	Nemli	Islak
Eğitim	34	33	33	34	33	33	7	7	6
Doğrulama	17	17	16	17	17	16	7	7	6
Test	17	17	16	17	17	16	7	7	6
Toplam	200			200			60		

Toprak türü görevi veri kümesinde ise farklı toprak türlerinde 3 ayrı sınıf oluşturulmuştur. Bu sınıflar kuru, nemli ve ıslak olarak ayrılmıştır. Bu veri kümesinde gömülü cismin hedef

olup olmamasından bağımsız bir şekilde, veriler gömülü oldukları toprak türlerine göre ayrılmıştır. Toprak türü görevi için veri kümesinin eğitim, doğrulama ve test verilerinin dağılımı Çizelge 2’de bulunmaktadır. Gömülen malzemeler bakır, plastik, mükemmel iletken (PEC-Perfect Electric Conductor), beton, asfalt türlerinden herhangi birinden olabilmektedir.

ÇİZELGE 2. TOPRAK TÜRÜ GÖREVİ İÇİN VERİ KÜMESİ

Gömülen Malzeme	KURU TOPRAK		NEMLİ TOPRAK		ISLAK TOPRAK	
	Tel	Bozuk yüzeyli	Tel	Bozuk yüzeyli	Tel	Bozuk yüzeyli
Eğitim	150	50	150	50	150	50
Doğrulama	40	10	40	10	40	10
Test	70	30	63	47	42	34
Toplam	350		360		326	


III. EVRİŞİMSEL SINIR AĞI

Evrışimsel sınır ağları (ESA) özelleştirilmiş bir derin öğrenme modelidir. Sınır ağları girdi olarak verilen görüntüde oluşacak olan bozulma ve kaymalarla başa çıkamamaktadır. Bu sorunla başa çıkmak için LeCun tarafından ESA geliştirilmiştir. ESA’lar içerdikleri evrışimsel katman sayesinde bölgesel olarak öznelikleri öğrenerek girdide oluşacak olan bozulmalara dayanıklı hale gelmektedir [9]. Şekil. 1’de önerilen ESA yapısı ve temel katmanları gösterilmiştir. Bu yapı, temel olarak evrışimsel, aktivasyon, toparlama ve tamamen bağlı katmanlarından oluşmaktadır. Son katmanda sınıflandırıcı olarak softmax kullanılmıştır. Bu katman sınıf değerlerini olasılıksal olarak tekrar düzenlemektedir. Bu katmanlardan evrışimsel ve tamamen bağlı katmanlarında öğrenilebilen parametreleri mevcuttur. Bu parametreler, ağırlık parametresi olarak isimlendirilmektedir. Farklı özneliklerin öğrenimi için bir ESA birkaç evrışimsel katmandan oluşmalıdır. İlk katman köşe algılama, renk ayrımı gibi daha genel öznelikler öğrenirken sonraki katmanlar o probleme özel öznelikleri öğrenmektedir.

A. Aktarım Öğrenmesi

Derin öğrenmede çok büyük veri kümeleri ile sıfırdan bir sınıflandırıcı eğitmek çok yüksek işlem gücü gerektirmektedir. Bunun yerine büyük bir veri kümesi ile önceden eğitilmiş olan bir derin öğrenme sınıflandırıcısının öznelik çıkarıcı ve bazı sınıflandırıcı katmanları kullanarak ilgili ağırlık verileri veya katmanlarda ayarlama yapılarak yeni veri kümemize uygun hale getirme işlemine “Aktarım Öğrenmesi” denmektedir. Aktarım öğrenmesi senaryolarından temel olan “Sabit Öznelik Çıkarıcı” ve “Hassas Ayar” yöntemi sırasıyla anlatılmıştır [10], [11].

Sabit öznelik çıkarıcı yöntemi, daha önce eğitilmiş olan bir evrışimsel sınır ağının son tamamen bağlı katmanı yani sınıflandırıcı katmanı çıkarılarak diğer tüm katmanlar olduğu gibi alınması işlemidir. Sadece son sınıflandırıcı katmanı yeni veri kümesine göre eğitilir. Aktarım öğrenmesi senaryolarının ikincisi olarak hassas ayar yöntemi ele alınmıştır. Sabit öznelik çıkarıcı yöntemden farklı olarak tamamen bağlı katmanından önceki katmanlarda da ağırlık verileri eğitilmektedir. Tüm katmanlardaki ağırlık verilerinde düzeltme yapılabileceği gibi ilk katmanlardaki parametreler sabit tutulabilir. Bunun nedeni ilk katmanlarda öğrenilen öznelik çıkarımının çok genel (ör.



E: Evrişim katmanı, T: Toparlama katmanı, TB: Tamamen bağlı katmanı, SM: Softmax katmanı

Şekil 1. Örnek bir evrişimsel sinir ağı yapısı

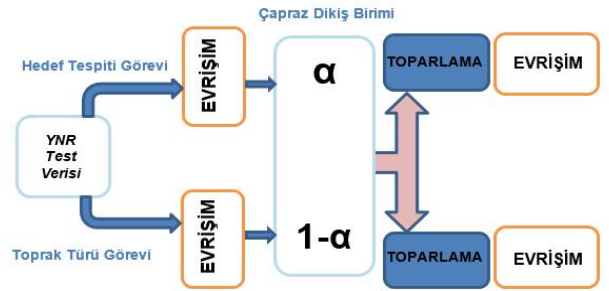
köşe algılama, renk ayırt etme vs.) olmasıdır. Sonraki katmanlar ise daha özel öznelikleri öğrenmektedir. Bu sebeple son seviyelerdeki katmanlarda hassas ayar yapmak tercih edilmektedir. ESA literatüründe son zamanlarda bulunan bir bulgu ise ağıın erken safhalarında öğrendiği filtrelerin genellikle çok genel (ör. kenarlar veya renkler) olmasıdır. Simonyan vd. [12] ve Bralich vd. [13]'ün çalışmasında bulunan bir ağıın filtreleri, farklı bir görevdeki bir ağıın eğitim başlatılması için kullanılmış ve performansın yükselmesine fayda sağladığı gözlenmiştir.

B. Çok Görevli Öğrenme

Çok görevli öğrenme, makine öğrenmesinin farklı uygulama alanlarında başarıyla kullanılmaktadır. Doğal dil işleme [14], konuşma tanıma [15] bilgisayarla görü [16] bunlardan bazılarıdır. Bu öğrenme yöntemi kaynaklarda farklı isimlerle de bulunmakta; katımlı öğrenme ve yardımcı görev ile öğrenme, çok görevli öğrenmenin farklı deyişleridir. Çok görevli öğrenme, birden fazla görev modelinin aynı anda eğitildiği bir sınıflandırma yöntemidir. Bu yöntem ile sınıflandırma başarımının, görevlerin ayrı olarak eğitilmesine göre arttığı görülmüştür [17], [18]. Çok görevli öğrenmenin temel amacı ilişkili görevlerde alana özel bilgileri kullanarak sınıflandırma başarımını arttırmaktır [18]. Çok görevli öğrenme, ilişkili iki farklı görevin öğrendiği parametreleri birbirleriyle belirli şekillerde paylaşarak başarı oranını yükseltmeyi amaçlamaktadır. Mevcut temel görev modelimizin başarımını geliştirmesi için ek olarak yazılacak bir kayıp fonksiyonu ile farklı iki görevin birbirine yardımcı olması sağlanabilir [19].

Bu çalışma, YNR verileri üzerinde çok görevli öğrenme yöntemini uygulaması ile öne çıkmaktadır. Derin öğrenme modelleri üzerinde şimdiye kadar uygulanmış olan yöntemlerden bazıları sırasıyla anlatılmıştır. Long vd. [20], evrişimsel katmanların birleşik olarak paylaşılmasını ve sadece tamamen bağlı katmanların göreve özel olarak atanmasını önermektedir. Bu yöntem, derin ilişkili ağı olarak isimlendirilmektedir. Bu sayede model başarımında iyileşme sağlandığı görülmüştür. Tam uyumlu öznelik paylaşımı yöntemi farklı katmanlarda benzer görevler arasında paylaşım yapmayı önermekte ve dinamik olarak sırayla daha genel katmanlara giderken benzer görevler arası ortak katmanlar oluşturmaktadır. Benzerlik oranları düşük olan görevler arasında karmaşık parametre paylaşımına sebep olup başarımı düşürmesini engellemektedir. Farklı görevler için tek bir ilk katman bulunmaktadır. Birbirine ilişkili olan görevlere göre ikinci katmanda ayırım başlamaktadır. Daha özel özneliklerin

öğrenildiği son katmanlara doğru bütün görevler ayrışmaktadır. Her katmanda farklı görev kümeleri arasında parametre paylaşımı yaptığı için bu yapıya dinamik çok görevli paylaşım denilmektedir [21]. Misra vd. [22]'nin çalışmasında, mevcut çok görevli öğrenme mimarilerinin birden fazla görevin olduğu modeli ortak olarak eğittiği ve genelleme yapmadığını söylemektedir. Çarpaz dikiş yöntemi yaklaşımı, görevlerin ne olduğundan bağımsız, iki farklı eğitilmiş modelin en uygun kombinasyonunu vermektedir. Böylece görevlerin tek olarak mı daha iyi eğitildiği ya da paylaşımlı olarak mı daha iyi eğitildiğinden bağımsız olarak en iyi sonucu vermektedir. Bu yöntem iki ayrı görev modeli kullanılarak uygulanmaktadır. İki farklı görev parametreleri belli lineer katsayılarla birbirleri ile toplanarak ara bir katman oluşturulmaktadır.



Şekil 2. Önerilen çok görevli öğrenme yöntemi

Her evrişimsel katman sonrası eklenen bu çarpaz dikiş birimleri, hedef tespit görevini α katsayısı (0 ve 1 arasında olmalı) ile ve toprak türü görevini $(1 - \alpha)$ katsayısı ile çarparak toplamaktadır. Çıkan sonuç bir sonraki katman olan toparlama katmanına ya da modelde bulunan gizli katmanlardan birine girer. Buradaki mantığı matematiksel bir işlem olarak göstermek adına A (hedef tespit görevi) ve B (toprak türü belirleme görevi) olarak iki farklı görev tanımlayalım. Bu iki görev ayrı ayrı eğitilmiş ve modelleri oluşturulmuştur. Bu iki farklı görevi birleştirecek bir ara birim önerilmiştir. Bu birim her evrişimsel katman sonrası oluşan çıktıların lineer bir birleşimini sağlamaktadır. Bu ifade denklem (1)'de gösterilmiştir. Bu denklemde bulunan x_A ifadesi çarpaz dikiş birimi öncesi A görevinin evrişimsel katman sonucunu ve \tilde{x} ifadesi ise bu çarpaz dikiş birim işlemi sonucu çıktıyı göstermektedir.

$$[\tilde{x}] = [\alpha \quad (1 - \alpha)] \begin{bmatrix} x_A \\ x_B \end{bmatrix} \quad (1)$$

IV. SONUÇLAR VE GELECEK ÇALIŞMALAR

Bu çalışma kapsamında, sentetik YNR verileri gprMax programı ile üretilmiştir. Bu veriler iki farklı görev modeli için sınıflara ayrılmıştır. İlk görev modeli hedef ve hedef-dışı olarak iki sınıfa ayrılmış ve temel görev modelini oluşturmuştur. Temel görev modeli, hedef tespit görevi olarak adlandırılmıştır. İkinci görev modeli ise toprak türü tespiti görevi olarak isimlendirilmiş ve kuru, nemli ve ıslak toprak olarak üç ayrı sınıfa ayrılmıştır. Bu verilerle 3 evrişim, 3 toparlama ve 1 tamamen bağlı katmana sahip bir ESA eğitilmiştir. Her eğitim sonucu başarımlar değerleri farklı çıktığından dolayı her görev için eğitim 25 kere tekrarlanmıştır. Hedef tespit görevi için 25 tekrar denemenin ortalama başarımları %74,08 çıkmıştır. Toprak türü görevi için ise sınıflandırma başarımları %58,60 çıkmıştır. Bir ESA'nın eğitimi için mevcut veri kümesinin boyutu yeterli olmamaktadır. Bu zafiyeti ortadan kaldırmak amacıyla, önceden eğitilmiş bir model, mevcut ESA'ya entegre edilerek aktarım öğrenmesi yapılmış ve hedef tespit görevindeki başarımları %77,44'e çıkmıştır. Toprak türü görevi için ise başarımları %76,92 seviyesine çıkmıştır. Aktarım öğrenmesiyle daha önceden çok sayıda veri ile eğitilen bir modelin öznelilik çıkarımının daha başarılı olduğu, hedef ve toprak türü modele entegre edilerek görülmüştür. Aktarım öğrenmesi ile iyileşen model başarımlarını yükseltmek için çok görevli öğrenme kullanılmıştır. Hedef tespit görevinin, dielektrik farklılıklardan faydalandığı ve gömülü bulunan cismin materyaline bağlı olarak bazı toprak türlerinde hedef tespitinin zorlaştığı görülmüştür. Toprak türü görevinin öğrendiği özneliliklerin, hedef tespitine yardımcı olması amacıyla çok görevli öğrenme yöntemi uygulanmış ve hedef tespit görevinde başarımların artışı görülmüştür. Bu başarımların artışı alınan kaynak modellere göre farklılık göstermektedir. 3 farklı denemede; aktarım öğrenmesi sonucu %77,50 olan başarımlar α değeri 0,7682 seçilerek %79,17'ye çıkmış, %80 olan başarımlar α değeri '1' seçilerek aynı kalmış, %75 olan başarımlar ise α değeri 0,8705 seçilerek %76,67'ye çıkmıştır. Çok görevli öğrenmeye girdi oluşturan kaynak modellere göre başarımların değiştiği görülmüştür.

Gelecek çalışmalarda, anlatılan yöntemlerin gerçek YNR verileri kullanılarak geliştirilmesi ve gerçek bir veri kümesinin getireceği farklılıklar incelenebilir. Bu yöntemlere ek olarak saha ortamında alınacak olan yani elimizde mevcut olmayan bir yeryüzü ortamından birkaç YNR verisinin eğitim verilerimize eklenerek modelimizde iyileştirme yapıp yapmadığı konusu değerlendirilebilir. Bu yöntem literatürde alan uyumlaması olarak geçmektedir.

KAYNAKLAR

- [1] L. P. Leon, J. D. Young, and J. J. Daniels, "Ground Penetrating Radar as a Subsurface Environmental Sensing Tool," *Proceedings IEEE*, vol. 82, no. 12, pp. 1802–1822, 1994.
- [2] J. N. Wilson, P. Gader, S. Member, W.-H. Lee, H. Frigui, and K. C. Ho, "A Large-Scale Systematic Evaluation of Algorithms Using Ground-Penetrating Radar for Landmine Detection and Discrimination," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 45, no. 8, pp. 2560–2572, 2007.
- [3] Q. Zhu and L. M. Collins, "Application of feature extraction methods for landmine detection using the Wichmann/Niitek ground-penetrating radar," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, no. 1, pp. 81–85, 2005.
- [4] S. E. Yuksel, J. Bolton, and P. D. Gader, "Landmine Detection With Multiple Instance Hidden Markov Models," *IEEE International Workshop on Machine Learning for Signal Processing*, Santander, pp. 1–6, 2012.
- [5] R. J. Stanley, P. D. Gader, and K. C. Ho, "Feature and decision level sensor fusion of electromagnetic induction and ground penetrating radar sensors for landmine detection with hand-held units," *Information Fusion*, vol. 3, no. 3, pp. 215–223, 2002.
- [6] S. Vitebskiy and L. Carin, "Resonances of perfectly conducting wires and bodies of revolution buried in a lossy dispersive half-space," *IEEE Transactions Antennas Propagation*, vol. 44, no. 12, pp. 1575–1583, 1996.
- [7] M. Dogan, S. Gumus, and G. Turhan-Sayan, "Detection of conducting and dielectric objects buried under a layer of asphalt or concrete using simulated ground penetrating radar signals," *International Conference on Electromagnetics in Advanced Applications (ICEAA)*, pp. 1535–1538, 2017.
- [8] E. Aydin and S. E. Yuksel, "Buried target detection with ground penetrating radar using deep learning method," *25th Signal Processing and Communications Applications Conference (SIU)*, pp. 1–4, 2017.
- [9] P. D. Gader, M. Mystkowski, and Y. Z. Y. Zhao, "Landmine detection with ground penetrating radar using hidden Markov models," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 39, no. 6, pp. 1231–1244, 2001.
- [10] A. Karpathy, "Convolutional Neural Networks for Visual Recognition," Stanford CS class CS231n notes, [Online]. Available: <http://cs231n.github.io/transfer-learning/>. [Accessed: 01-Oct-2017], 2017.
- [11] J. Yosinski, J. Clune, Y. Bengio, and H. Lipson, "How transferable are features in deep neural networks?" *Advances in Neural Information Processing Systems 27*, pp. 3320–3328, 2014.
- [12] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," *International Conference on Learning Representations*, pp. 1–14, 2015.
- [13] J. Bralich, D. Reichman, L. M. Collins, and J. M. Malof, "Improving convolutional neural networks for buried target detection in ground penetrating radar using transfer learning via pretraining," *Proc. SPIE 10182, Detecting and Sensing of Mines, Explosive Objects and Obscured Targets XXII*, 2017.
- [14] R. Collobert and J. Weston, "A unified architecture for natural language processing," in *Proceedings of the 25th international conference on Machine learning - ICML '08*, pp. 160–167, 2008.
- [15] L. Deng, G. Hinton, and B. Kingsbury, "New types of deep neural network learning for speech recognition and related applications: an overview," *IEEE International Conference on Acoustics, Speech and Signal Processing*, pp. 8599–8603, 2013.
- [16] R. Girshick, "Fast R-CNN," in *Proceedings of the IEEE International Conference on Computer Vision*, vol. 2015 International, pp. 1440–1448, 2015.
- [17] J. Baxter, "A Model of Inductive Bias Learning," *Journal of Artificial Intelligence Research*, vol. 12, p. 149, 2000.
- [18] R. Caruana, "Multitask Learning," *Machine Learning*, vol. 28, no. 1, pp. 41–75, 1997.
- [19] S. Ruder, "An Overview of Multi-Task Learning in Deep Neural Networks," *arXiv: 1706.05098*, 2017.
- [20] M. Long and J. Wang, "Learning Multiple Tasks with Deep Relationship Networks," *arXiv: 1506.02117*, pp. 1–9, 2015.
- [21] Y. U. Lu San Diego, A. Kumar, S. Zhai, Y. Cheng, T. Javidi, and R. Feris, "Fully-adaptive Feature Sharing in Multi-Task Networks with Applications in Person Attribute Classification," *arXiv: 1611.05377*, 2016.
- [22] I. Misra, A. Shrivastava, A. Gupta, and M. Hebert, "Cross-stitch Networks for Multi-task Learning," *arXiv: 1604.03539*, 2016.