

Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme

Abdulkadir ŞEKER^{*a}, Banu DİRİ^b, Hasan Hüseyin BALIK^c

^{a,*} Cumhuriyet Üniversitesi Bilgisayar Mühendisliği Bölümü, SİVAS 58040, TÜRKİYE

^b Yıldız Teknik Üniversitesi Bilgisayar Mühendisliği Bölümü, İSTANBUL 34220, TÜRKİYE

^c Milli Savunma Üniversitesi Hava Harp Okulu, İSTANBUL 34149, TÜRKİYE

MAKALE BİLGİSİ

Alınma: 17.09.2017
Kabul: 15.11.2017

Anahtar Kelimeler:
Derin öğrenme,
Özellik mühendisliği,
Yapay sinir ağları.

***Sorumlu Yazar:**
e-posta:
kadirseker00@
gmail.com

ÖZET

Makine öğrenmesi alanında yapay sinir ağları birçok problemin çözümünde sıklıkla kullanılmıştır. Ancak “Yapay Zeka Kış Uykusu” olarak da adlandırılan dönemde başta donanımsal kısıtlamalar ve diğer problemler sebebiyle bu alandaki çalışmalar durma noktasına gelmiştir. 2000’lerin başında tekrar gözde bir alan olmaya başlayan yapay sinir ağları, GPU gelişmeleriyle birlikte sığ ağlardan derin ağlara geçiş yapmıştır. Bu yaklaşım görüntü işlemeden, doğal dil işlemeye, medikal uygulamalardan aktivite tanımaya kadar oldukça geniş bir yelpazede başarıyla kullanılmaya başlanmıştır. Bu çalışmada, derin öğrenmenin tarihçesi, kullanılan yöntemler ve uygulama alanlarına göre ayrılmış çalışmalar anlatılmıştır. Ayrıca son yıllarda kullanılan kütüphaneler ve derin öğrenme üzerine yoğunlaşan çalışma grupları hakkında da bilgiler verilmiştir. Bu çalışmanın amacı, hem araştırmacılara derin öğrenme konusundaki gelişmeleri anlatmak, hem de derin öğrenme ile çalışılacak muhtemel konuları vermektir.

DOI:

A Review about Deep Learning Methods and Applications

ARTICLE INFO

Received: 17.09.2017
Accepted: 15.11.2017

Keywords:
Deep learning,
Feature engineering,
Artificial neural
networks.

***Corresponding
Authors**
e-mail:
kadirseker00@
gmail.com

ABSTRACT

Artificial neural networks were used in the solution of many problems in the field of machine learning. However, in the period called "AI Winter", studies in this area have come to a halt due to especially hardware limitations and other problem. Artificial neural networks, which started to become a popular area at beginning of the 2000s, have switched from shallow networks to deep networks thanks to GPU developments. This approach has been successfully used in a wide range of fields from image processing to natural language processing, from medical applications to activity identification. In this study, it is described the history of the deep learning, methods and the implementations separated by the application areas. In addition, information has been given to the libraries used in recent years and working groups focused on deep learning. The aim of this study both explains the developments in deep learning to researchers and provides possible fields study with deep learning.

1. Giriş (Introduction)

Doğal dil işleme, makine öğrenmesi alanlarında derin öğrenme yaklaşımları sayesinde 2000'li yıllarda büyük sekteye uğrayan yapay zekaya dayalı yöntemleri tekrar ön plana çıkarmıştır. Yapay sinir ağlarındaki (YSA) gizli katman ve düğüm sayılarının artırılmasına karşın donanımsal gelişmelerin yetersiz kalması sebebiyle yapay zeka yöntemleri 2000'li yılların başında artık kullanılmamaktaydı. Ancak GPU ve diğer donanımsal gelişmeler sayesinde çok sayıda gizli katmandan oluşan yapay sinir ağları hesaplama maliyetleri düştüğünden, tekrar kullanılmaya başlanmıştır [1].

Derin öğrenme yaklaşımı çoklu soyutlama yapısı ile verinin temsillerini öğrenmek için bir araya getirilmiş çoklu işleme katmanlarında oluşur [2] Makine öğrenmesi yaklaşımlarının kalitesi doğru özelliklerin seçimine bağlıdır [3]. Bu özellikleri ortaya çıkarmak için çeşitli ön işlemler, boyut indirgeme, özellik seçme vb. işlemler yapılmaktadır. Bu aşamadaki maliyeti azaltmak için özelliklere olan bağımlılıktan kurtulmak gerekmektedir. Sınıflandırıcılar ve diğer tahmin sistemlerini tasarlarlarken, yapay zeka ile veriden faydalı bilgiyi (özellik) çıkarmak daha kolay ve az maliyetli olacaktır [4]. Bu bağlamda derin öğrenme konusu temsili öğrenme ile çok sıkı ilişkilidir. Derin öğrenme algoritmaları özellikle 2005 yıllarından sonra birçok farklı alana uygulanmıştır. Bu çalışmalar ayrıntılarıyla sonraki bölümlerde anlatılacaktır.

Çalışmada, son yıllarda oldukça popüler bir makine öğrenmesi yaklaşımı olan derin öğrenme kavramını her yönüyle araştırılmıştır. 2. Bölümde derin öğrenmenin temeli olan yapay sinir ağları konusuna değinilmiş, tarihçesi ve uygulama alanları anlatılmıştır. 3. Bölümde yaygın kullanıma sahip derin öğrenme algoritmaları, öne çıkan uygulama alanları, derin öğrenme hakkında araştırmalar yapan ulusal ve uluslararası çalışma grupları, derin öğrenme için kullanılabilecek olan kütüphane ve çerçeveler (framework) anlatılmıştır. 4. Bölümde ise konu ile ilgili genel bir sonuç verilerek, alandaki çalışmaların ne yöne doğru gittiği ve muhtemel çalışma alanları hakkında bilgi sunulmuştur.

2. Derin Öğrenme (Deep Learning)


2.1. Tanım

Derin öğrenme bir makine öğrenmesi sınıfıdır. Derin öğrenme, özellik çıkarma ve dönüştürme için birçok doğrusal olmayan işlem birimi katmanını kullanır. Her ardışık katman, önceki katmandaki çıktıyı girdi olarak alır [5]. Algoritmalar denetimli (sınıflandırma gibi) veya denetimsiz (desen analizi gibi) olabilir.

Derin öğrenmede, verilerin birden fazla özellik seviyesinin veya temsillerinin öğrenilmesine dayanan bir yapı söz konusudur. Üst düzey özellikler, alt düzey özelliklerden türetilerek hiyerarşik bir temsil oluşturur. Bu temsil, soyutlamanın farklı seviyelerine karşılık gelen birden çok temsil seviyesini öğrenmektedir [6]. Derin öğrenme temel olarak verinin temsilden öğrenmeye dayalıdır. Bir görüntü için temsil denildiğinde; piksel başına yoğunluk değerlerinin bir vektörü veya kenar kümeleri, özel şekiller gibi özellikler düşünülebilir. Bu özelliklerin içinden bazıları veriyi daha iyi temsil etmektedir. Bu aşamada yine bir avantaj olarak, derin öğrenme yöntemleri, elle çıkarılan özellikler (handcrafted features) yerine veriyi en iyi temsil eden hiyerarşik özellik çıkarımı için etkin algoritmalar kullanmaktadır [7].

2.2. Tarihçe

Denetimli derin beslemeli çok katmanlı perceptronlar için ilk genel, öğrenme algoritması Ivakhnenko ve Lapa tarafından 1965 yılında yayınlanmıştır [8]. Bu çalışmada, her katmanda, en iyi özellikler istatistiksel yöntemlerle seçilip bir sonraki katmana iletilmektedir. Ağlarını uçtan uca eğitmek için geri yayılımı (backpropagation) kullanılmamış, önceki katmanlardan sonraki katmanlara en küçük kareler yöntemi kullanılmıştır (Şekil 1).



Şekil 1. Ivakhnenko A. tarafından eğitilen bilinen ilk derin ağı mimarisini [9].

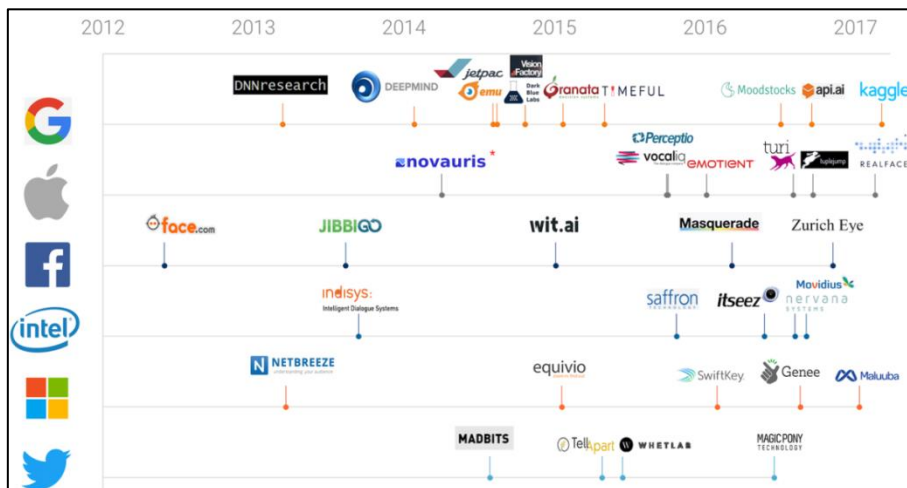
Ivankhenko'dan sonra ilk derin öğrenme mimarisi "Neokognitron", 1979 yılında Fukushima tarafından önerilmiştir. Omurgalı canlıların görsel sinir sistemlerinden esinlenilerek ortaya atılan yapıda, "denetimsiz öğrenme" ile kendi kendini organize eden bir ağ geliştirilmiştir. Fukushima'nın ağları modern ağlara benzer çoklu bükülme ve havuz katmanların içermektedir [10]. Derin mimarilerin çoklu katmanlarında hataların geri yayılımı öğrenmenin en önemli eksikliğidir. Geri yayılım algoritmaları önceki yıllarda ortaya atılmış olsa da ilk başarılı derin sinir ağı uygulamasını Yann LeCun ve arkadaşları posta kutusu yazıları üzerinde geliştirmişlerdir [11]. Her ne kadar ağ başarılı çalışsa da, eğitiminin yaklaşık olarak 3 gün sürdüğünden pratikte uygun olmadığı görülmüştür.

Bu çalışmadan sonra yine Yann LeCun "LeNet" ağını kullanarak el yazısı rakamlarını (MNIST) sınıflandırmak için kıvrımlı ağlarla geri yayılımı birlikte uygulamıştır [12]. 1995 yılında Brendan Frey, Peter Dayan ve Geoffrey Hinton geliştirdikleri uyanık-uyku (wake-sleep) algoritmasını kullanarak 6'sı tamamen bağlı (fully connected), yüzlerce gizli katman içeren bir ağı, her ne kadar eğitim iki gün sürse de, eğitilmesi mümkün olduğunu göstermişlerdir [13]. 1997'de, Hochreiter ve Schmidhuber'in ortaya attığı tekrarlayan sinir ağları (recurrent neural networks) için Uzun Kısa Vadeli Bellek (long short-term memory) gibi bazı önemli gelişmeler görülmüştür [14]. Bu dönemlerde YSA algoritmaları, avantajlarına rağmen -hesaplama maliyetinden dolayı- kullanılamamış, destek vektör makineleri [15] (support vector machine) gibi probleme özgü çalışan, elle hazırlanmış özellikleri

kullanan daha basit modeller, 1990'lı yıllardan 2000'lere kadar daha çok tercih edilmiştir.

Bilgisayarların çalışma hızlarının artması ve sonrasında grafik işlemci birimlerinin (GPU) hesaplamalarda kullanılması ile büyük gelişmeler gerçekleşmiş; hesaplama hızı, 10 yıllık bir sürede yaklaşık 1000 kat artmıştır. Bu dönemde, YSA yeniden, destek vektör makinelerine rakip olmaya başlamıştır [1]. YSA bağlamında ilk kez "Derin Öğrenme" (deep learning) ifadesi 2000 yılında Igor Aizenberg ve arkadaşları tarafından tanıtılmıştır [16]. 2006'da Geoffrey Hinton yayınladığı bir makalede, çok katmanlı ileri beslemeli bir sinir ağının her iterasyonda bir katmanı etkili şekilde nasıl eğitebildiğini (Her bir katmanı denetimsiz olarak kısıtlanmış bir Boltzmann makinesi ile eğitmiştir.), ardından denetimli bir geri yayılım yöntemi ile ince ayar yapabileceklerini göstermiştir [17].

GPU hızlarının artmasıyla birlikte derin ağların ön-eğitim (pre-training) olmaksızın eğitilebilmesi mümkün hale gelmiştir. Ciresan ve arkadaşlarına trafik işaretleri, medikal görüntüleme ve karakter tanıma yarışmalarını kazandıran derin ağlarında bu yaklaşımı kullanmışlardır [18]–[20]. Krizhevsky, Sutskever ve Hinton 2012'de benzer mimariler tasarlamışlardır. GPU destekli yaptıkları çalışmalarında, ezberlemeyi (overfitting) azaltmak için ise, "dropout"¹ adı verilen normalleştirme yöntemini [21] kullanılmıştır. Dropout yönteminin etkinliği, onlara ILSVRC-2012 ImageNet yarışmasında olağanüstü sonuçlar getirdiğinde kanıtlanmıştır [22].



Şekil 2. Yıllara göre yapay zeka başlangıç şirketlerinin satın alınması [23].

¹ Eğitimin her iterasyonunda, gizli katmanlardaki düğümlerin her biri 0,5 olasılıkla ağdan atılır, bu sayede mevcut gizli bir birim diğer gizli birimleri bağlamaz ve ezberleme durumu azaltılır.


Bu gelişmelerden sonra Google, Facebook ve Microsoft gibi teknoloji firmaları bu trendi fark edip derin öğrenme alanına yatırım yapmaya başlamışlardır. Şekil 2’te görüldüğü gibi, 2012-2017 yıllarında çalışma grupları ve başlangıç (startup) şirketleri satın alınmasıyla başlayan süreçte derin öğrenme alanındaki gelişmeler bir hayli hızlanmıştır. Şekil 2’den bazı örnekler vermek gerekirse; facebook tarafından satın alınan “face.com” fotoğraf etiketleme işinde başarıyı artırmak hedeflenmiştir. Apple “Novauris” şirketini satın alarak SİRİ üzerinde iyileştirmeler yapmıştır. Microsoft, doğal dil işleme ve yapay zeka çalışmaları da bulunan yaklaşık 100 dil için çalışan klavye uygulaması şirketi “SwiftKey” satın almıştır.

2.3. Derin öğrenme Mimarileri

Konvolüsyonel Sinir Ağları

Konvolüsyonel Sinir Ağları (Convolution Neural Network-CNN) çok katmanlı algılayıcıların (Multi Layer Perceptron-MLP) bir türüdür. Görme merkezindeki hücreler tüm görseli kapsayacak şekilde alt bölgelere ayrılmış, basit hücreler, kenar benzeri özelliklere, karmaşık hücreler ise daha geniş alıcılara, tüm görsele yoğunlaştığı düşünülmektedir. İleri yönlü bir sinir ağı olan CNN algoritması da, hayvanların görme merkezinden esinlenilerek ortaya atılmıştır. Buradaki matematiksel konvolüsyon işlemi, bir nöronun kendi uyarı alanından uyarılara verdiği cevap olarak düşünülebilir [10], [24], [25]. CNN, bir veya daha fazla konvolüsyonel katman, altörnekleme (subsampling) katmanı ve bunun ardından standart çok katmanlı bir sinir ağı gibi bir veya daha fazla tamamen bağlı katmandan oluşur [2].

Şekil 3’te verilen ilk CNN ağı 1988 yılında Yann LeCun tarafından ortaya atılan, 1998’lere kadar iyileştirmeleri devam eden LeNet isimli mimaridir [26]. LeNet ağında, alt katmanlar art arda yerleştirilmiş konvolüsyon ve maksimum havuzlama katmanlarından oluşur. Sonraki üst katmanlar ise tamamen bağlı geleneksel MLP’ye karşılık gelmektedir.



Şekil 3. LeNet ağına ait mimarisi.

CNN algoritmaları görüntü ve ses işleme alanı başta olmak üzere doğal dil işleme (NLP), biyomedikal gibi bir çok farklı alanda uygulanmaktadır. Özellikle görüntü işleme alanında görülmüş en iyi (state of the art) sonuçlar elde edilmiştir. MNIST veri kümesi üzerinde, Cireşan yaptığı çalışmada, CNN ile hata oranı %2'lere kadar düşürmeyi başarmıştır [27]. Yine Cireşan ve arkadaşları tarafından, MNIST ve NORB veri kümeleri üzerinde denenen başka bir çalışmada CNN ile, öğrenme sürecinin çok hızlı gerçekleştiği ve o zamana kadarki yöntemlerin en başarılı olduğu belirtilmiştir [28]. 2014 yılında, ImageNet Yarışması'nda, milyonlarca resim ve yüzlerce nesne sınıfı ile nesne sınıflandırması ve algılaması dalında en başarılı dereceleri alan ekiplerin hepsi CNN algoritmalarının modifikasyonlarını kullanmışlardır [29]. 2015'te yapılan bir çalışmada CNN, ters yüzler de dahil olmak üzere geniş açı aralıklarındaki yüzleri yakalayabilme başarısını göstermiştir. Bu ağ, çeşitli açılar ve yönlerde yüzleri içeren 200.000 görüntü ve yüzleri olmayan 20 milyon görüntü daha içeren bir veri tabanı üzerinde eğitilmiştir [30].


CNN modellerinin, görüntü işlemenin haricinde, çeşitli NLP problemleri için de kullanılabileceği gösterilmiştir. Anlamsal ayrıştırma [31], arama sorgusu elde etmede [32], cümle modelleme [33], sınıflandırma [34], tahmin problemlerinde [35] mükemmel sonuçlar elde edilmiştir. CNN algoritmaları ilaç keşfinde de kullanılmıştır. 2015 yılında Atomwise şirketinin geliştirdiği AtomNet, ilaç tasarımı için geliştirilen ilk derin sinir ağı olmuştur [36]. Kimyasal tepkimelerin 3 boyutlu temsilleriyle eğitilen sistem, Ebola ve skleroz gibi hastalıklarda yeni biyomolekülleri keşfedebilmek için kullanılmıştır [37]. Go oyunu için de yine CNN kullanılmış, geleneksel yöntemlerle geliştirilen GNU Go algoritmasını, önceden eğitilmiş 12-katmanlı bir CNN modeli oyunların %97'sinde yenmiştir [38]. Google DeepMind tarafından geliştirilen CNN tabanlı AlphaGo ise ilk kez profesyonel bir oyuncuyu (insanı) yenebilen program olmuştur [39].

Tekrarlayan Sinir Ağları

İlk olarak Basit Tekrarlayan Ağ (Simple Recurrent Network-SRN), Jeff Elman tarafından tasarlanmıştır. Elman'ın cümle yapısı simülasyonunda kullanılan her bir kelime için gizli kalıpların üzerinde ortalama örüntü kümeleme sonucunda isim ve fiil kategorileri temiz şekilde ayrılmıştır. Bunun yanında isimler arasında canlı-

cansız ayrımları, hatta insan-hayvan, hayvanlar arasında avcı-yırtıcı gibi kümeler de ayrılmıştır [40]. Tekrarlayan Sinir Ağı (Recurrent Neural Network-RNN), birimler arasındaki bağlantıların yönlendirilmiş bir döngü oluşturduğu yapay sinir ağı sınıfıdır. Bu döngü ile, dinamik zamansal davranış sergilemesine olanak tanıyan bir ağ iç durumu oluşturulmuştur. İleri beslemeli sinir ağların aksine, RNN'ler kendi giriş belleğini girdilerin rastgele dizilerini işlemek için kullanabilmektedirler [41]. Tekrarlayan sinir ağındaki (RNN) temel düşünce sıralı bilgileri kullanmaktır. Görüntü tabanlı verilerde tüm girdilerin (veya çıktılarının) birbirinden bağımsız olduğunu varsayılmaktadır. Fakat NLP gibi zaman değişkeni olan alanlar için bu durum mümkün değildir. Örneğin, bir cümle içinde bir sonraki kelimeyi tahmin etmek için, o anki kelimedenden önce hangi sözcüklerin geldiğini bilmek gerekmektedir. RNN mimarisinin yinelenen (recurrent) olarak adlandırılmasının sebebi, bir dizinin her ögesi için (cümledeki kelimeler gibi) aynı görevi önceki çıktılara bağlı olarak yerine getirmesidir .

Alex Graves'in çalışmasında, ses verilerinin fonetik sunumuna gerek kalmadan doğrudan metine çeviren bir RNN tabanlı konuşma tanıma sistemi sunulmuştur [42]. Başka bir çalışmada, RNN'ler CNN ile birlikte, etiketlenmemiş görüntüler için tanımlayıcı üreten bir modelin parçası olarak kullanılmıştır. Birleştirilmiş model, görüntüdeki nesnelere tanımlamanın yanında, tanımlayıcıların görüntülerdeki konumlarını bile bulmayı başarmıştır (Şekil 4) [43].



Şekil 4. Görüntü tanımlayıcıları oluşturmak için derin görsel-anlamsal hizalama [43].

Uzun Kısa Vadeli Hafıza Ağları

RNN mimarilerinde önceki bilgi kullanımına dayalı bir yaklaşım vardır. Örneğin “Ağaç toprakta yetişir” cümlesinde “toprak” kelimesini tahmin etmek kolaydır. Fakat bağlamlar arası boşluk arttığında RNN modelin geçmişten gelen bir bilgiyi kullanması oldukça zordur. Örneğin, “İngiltere’de büyüdüm Akıcı bir şekilde İngilizce

konuşurum.” gibi bir metinde “İngilizce” kelimesini tahmin ederken, içinde bulunduğu cümleden yola çıkarak bir dil adı olacağını tahmin edilebilir, ancak doğru kelimenin “İngilizce” olduğunu tahmin etmek için, metnin başındaki cümledeki yer bilgisini hafızada tutmak gerekmektedir. Teoride mümkün olan “uzun-vadeli bağımlılıklar”, pratikte büyük problemlere yol açtığı görülmüştür [44]. Bu problemi çözmek için, uzun vadeli bağımlılıkları öğrenebilen özel bir RNN türü olan Uzun Kısa Vadeli Bellek (Long Short Term Memory - LSTM) ağları Hochreiter ve Schmidhuber tarafından 1997 yılında tanıtılmıştır [14]. LSTM mimarisi giriş, unutma ve çıkış olmak üzere 3 kapı, blok girişi, Sabit Hata Döngüsü, çıkış aktivasyon fonksiyonu ve gözetleme (peephole) bağlantılarına sahiptir [45]. Bloğun çıktısı tekrar tekrar bloğun girişine ve tüm kapılarına bağlanır. Gözetleme bağlantıları ve unutma kapısı ilk geliştirilen mimaride bulunmamaktadır. LSTM’in kendi durumunu sıfırlamak için unutma kapısı [46], kesin zamanlamaları öğrenmeyi kolaylaştırmak için ise gözetleme bağlantıları eklenmiştir [47].

LSTM mimarileri konuşma/metin işleme konularında oldukça iyi sonuçlar vermektedir. Çerçeve tabanlı ses sınıflandırma çalışmasında farklı lehçelerdeki zengin içerikler barındıran TIMIT veri kümesi kullanılmış, %70 başarı oranı elde edilmiştir [48]. Uygun ayarlamalar ile uçtan uca eğitimden geçen başka bir LSTM yaklaşımı ile aynı veri kümesi üzerinde %83 başarı oranına ulaşılmıştır [49]. Fernández ve arkadaşları, anahtar kelime tespitinde geniş kapsamlı konuşma verileri barındıran Verbmobil veri kümesi üzerinde %84.5’lik bir doğruluk oranını LSTM ile elde etmişlerdir [50]. Baccouche’nin insan aktivitelerini ön bilgi kullanmadan sınıflandırmayı öğrenen tamamen otomatikleştirilmiş CNN ve LSTM tabanlı derin öğrenme modeli başarılı sonuçlar vermiştir [51].

İlginç bir başka uygulama ise LSTM ile müzik bestesi üretimi denemesidir. RNN ile nota tahmini yapılabilsede “dinlenebilir” beste yapmak pek mümkün değildir. Bu çalışmada, ise uzun vadeli öğrenme yeteneği ile LSTM’nin bir blues türünde müzikleri başarılı bir şekilde öğrendiğini ve bu tarzda yeni besteler oluşturabileceğini gösteren model tasarlanmıştır [52]. Hizalamadan bağımsız olarak protein homolojisinin algılanması [53], robotik kalp cerrahisinde düğümleri bağlamayı öğrenen bir sistem tasarlanması [54], düzensiz dillerde öğrenme [55], çevrimdışı elyazı tanınması [56] gibi çok farklı konularda da LSTM mimarileri kullanılmıştır.

Sınırlı Boltzmann Makineleri

Sınırlı Boltzmann makineleri (Restricted Boltzmann Machines-RBM), aslında Harmonium [57] adıyla 1986'da ilk olarak ortaya atılmış, ancak çok uzun zaman sonra (2006) Geoffrey Hinton ve arkadaşları tarafından hızlı bir öğrenme algoritması olarak ön plana çıkarılmıştır [58]. RBM girdi seti üzerinde olasılık dağılımını öğrenebilen üretken bir rastgele yapay sinir ağıdır. RBM, Boltzmann Makinalarının bir türüdür. Görünür ve gizli olmak üzere aralarında simetrik bağlantı bulunan iki parçalı graflardan oluşurlar. Bir graf içindeki düğümlerde kendi aralarında bağlantı bulunmaz [59]. Buna karşın, Kısıtlı Boltzmann makineleri gizli birimler arasında da bağlantı vardır. Bu kısıtlama, Boltzmann makinelerinin genel sınıfı için mevcut olanlardan daha etkili eğitim algoritmalarına imkan tanır [60].

RBM'ler, boyut indirgeme [58], sınıflandırma [61], işbirlikçi filtreleme [62], özellik öğrenimi [63] ve konu modelleme [64] gibi farklı konular için kullanışlı bir algoritmadır.

Derin İnanç Ağları

Geoffrey Hinton tarafından tanıtılan, Derin inanç ağları (DBN), önceki bölümde verilen RBM'lerin yığını olarak tanımlanmaktadır. Her RBM katmanı hem önceki hem de sonraki katmanlarla bağlıdır. Ancak herhangi bir katmanın düğümleri birbirleriyle yatayda iletişimi bulunmamaktadır. En son katman olarak bir softmax katmanı ile sınıflandırma veya denetimsiz bir öğrenme için kümeleme yeteneğine sahiptir [58].

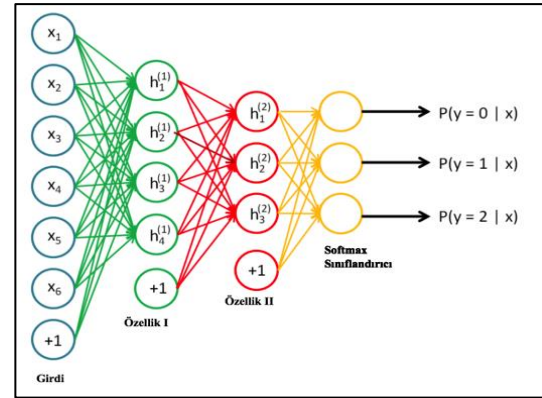
DBN mimarileri görüntü tanıma ve üretme konularında uygulanmıştır [65]–[67]. Salakhutdinov ve Hinton, bütün dokümana TF-IDF uygulamak yerine DBN kullanan bir sistem ile büyük bir belge veri kümesinde kelime-sayı vektörleri elde etmişlerdir [68]. İnsan hareketi tanımlamak için Taylor ve arkadaşları çeşitli hareket dizilerini sentezleyerek ve hareket yakalama sırasında kaybolan verilerin çevrimiçi olarak doldurularak gösterilmesini sağlamışlardır [69].

Derin Oto-Kodlayıcılar

Diabolo ağı olarak adlandırılan Oto-kodlayıcılar (Autoencoders-AE) denetimsiz öğrenme için kullanılan bir özel yapay sinir ağıdır [70], [71]. AE, bir veri kümesi için boyut indirgeme amacıyla bir temsil (kodlama) öğrenmeyi hedefler. Son yıllarda,

AE konsepti, verinin üretken modellerini öğrenmek için daha yaygın olarak kullanılmaya başlamıştır [72], [73]. AE, kabaca girdi verisinin sıkıştırılmış gösteriminden en iyi özelliklerin öğrenilmesini hedefleyen bir ileri beslemeli sinir ağıdır [74]. AE mantığında, girdi verisi şifreleme-şifre çözme işleminden sonra çıktı olarak yine aynı girdiyi görene kadar ağırlıklar değiştirilir. Hedefe ulaşıldığında gizli katmandaki düğüm sayısı ile girdi verisi temsil edilmiş olmaktadır.

Derin veya yığılı oto-kodlayıcılar ise (Deep/Stacked Autoencoder-DAE), her bir katmandaki çıktıların ardışık katmanın girişlerine bağlandığı AE'lerin çok katmanlarından oluşan sinir ağıdır [75].



Şekil 5. Genel bir DAE mimarisi [76].

Şekil 5'de ardışık olarak yerleştirilmiş iki AE ağı bulunmaktadır (Şifre çözme kısımları gösterilmemiştir.). Girdi dizisi (Input) ilk gizli katmanda şifrelenerek Özellik I (Features I) dizisi elde edilmiştir. Sonraki gizli katmana elde edilen özellik dizisi girdi olarak verilmiş ve şifreleme sonucunda özellik II (features II) dizisi elde edilmiştir. Özellik II dizisi ise özellik vektörü olarak son katmanda softmax sınıflandırıcıya girdi olarak verilmiş, sınıflandırma işlemi bu vektörle gerçekleştirilmiştir.

Yapılan bir çalışmada, DAE mimarisi kumaş hatası tespiti için uygulanmış, 2 ardışık AE ile oluşturulan derin ağ ile oldukça ayırt edici özellikler elde edilmiştir [75]. Mail spam yakalama için kullanılan bir başka çalışmada ise sonuçlar Naive Bayes, Destek Vektör Makineleri, Karar Ağaçları gibi diğer yöntemler ile kıyaslanmış hem doğruluk hem de f1 ölçümlerinde daha iyi performans gösterdiği görülmüştür [77]. Konuşma spektrogram kodlaması üzerindeki bir çalışmada ise DAE tabanlı

bir mimari uygulanmış, konuşma verisi ile, alınan sonuçların, daha önce görüntü yamalarını kodlamak için elde edilen başarı ile yaklaşık olarak aynı olduğunu gözlemlenmiştir [78]. DAE özellikle anormallik (anomaly) ve aykırı değer (outlier) tespiti gibi konularda da iyi sonuçlar vermektedir [79], [80].

2.4. Derin Öğrenme Uygulamaları

Bir önceki bölümde mimariler üzerinden bir inceleme yapılmıştır. Bu bölümde ise alan bazında bir ayrıştırma yapılarak, özellikle son yıllarda hangi alanlara, hangi yöntemler uygulanıyor konusu irdelenecektir.

Doğal Dil İşleme

Doğal dil işleme alanında oldukça başarılı olan derin öğrenme algoritmalarından, özellikle DAE, LSTM, CNN mimarileri etkileyici sonuçlar vermiştir. Az miktarda etiketlenmiş veri ile duygu analizi yapmak bilinen bir problemdir. Shusen Zhou, Aktif derin ağ (ADN) olarak adlandırdığı bir yarı-eğitici öğrenme algoritmasını bu problem üzerinde çalışmıştır. RBM tabanlı kurulan bu derin ağ, 5 duygu analizi veri kümesi üzerinde uygulanmıştır [81].

Zhou ve arkadaşları başka bir çalışmada, bulanık DBN adı verilen iki aşamalı bir yarı-eğitici öğrenme metodu sunmuşlardır. İlk olarak, DBN ile yarı-eğitici öğrenme tarafından oluşturulan veri seti ile eğitilmiştir. Ardından, derin mimari tarafından öğrenilmiş görüşleri baz alan bir bulanık üyelik fonksiyonu devreye girmiş, kıyaslanan önceki çalışmalara göre etkili sonuçlar alınmıştır [82]. Duygu analizinden esinlenen You ve arkadaşları, hapishanelerdeki kısa mesajların otomatik güvenlik denetimi için kısa mesajları (güvenli ve güvensiz) sınıflandıran yeni derin öğrenme tabanlı bir ağ olan RNN modeli kullanmışlardır. Çalışmada, kısa mesajlardan word2vec [83] vasıtasıyla tipik özellikler çıkarılmış ve RNN ile sınıflandırılmıştır. Deneysel sonuçlar, RNN modelinin SVM'ye göre daha yüksek olan ortalama %92.7 doğruluk elde ettiğini göstermiştir [84].

Cümle sınıflandırma doğal dil işlemede başka önemli bir problemdir. CNN tabanlı bir yaklaşım ile önceden eğitilmiş kelime vektörleri cümle sınıflandırma probleminde kullanılmış ve 4'ü çok değerli 7 konu üzerinde (duygu analizi ve soru sınıflandırma dahil) yüksek başarılar göstermiştir [34]. Ayrıca çoklu konu (multi-tasking) öğrenme için de yine CNN yöntemi kullanılmıştır [35]. Ses tanıma

üzerine yapılan çalışmalarda da RNN ağları kullanılmaktadır [49].

Yousefi-Azar metin özetleme için, DAE ile, Terim Frekans (tf) girdisinden bir özellik alanı hesaplamak için tek belge özetleme yöntemlerini sunmuştur. ENAE adını verdiği, tf değerlerine rastgele gürültüler eklenmiş topluluk (ensemble) tabanlı öğrenme yöntemini denemiştir. İki farklı konudaki e-mail veri kümesi üzerinde çalışmış ortalama %11,2 hatırlama (recall) değerlerine ulaşmıştır [85]. Metinlerdeki anahtar kelimelerin tespiti için LSTM tabanlı bir yaklaşım, bu konuda başarılı olan HMM ile kıyaslanmış ve daha başarılı olduğu görülmüştür [50].

Yazar cinsiyeti belirlemek amaçlı bir çalışmada CNN ve LSTM birlikte kullanılmıştır. Rusça metinler üzerinde yapılan çalışma, geleneksel yöntemlerle kıyaslanmış %86 doğruluk ile state-of-art çalışmalara yakın başarı göstermiştir [86]. Brocardo ve arkadaşları, yazarlık doğrulama konusunda DBN kullanımını araştırmışlardır. Çalışmada, modelden sözcüksel, sözdizimsel ve uygulamaya özgü özellikler elde edilmiştir. Twitter ve Enron e-mail veri kümesi üzerinde test edilen bu model %8-16 arası hata oranlarıyla umut vadetmiştir [87].

Web üzerinden elde edilen metinlerde veya sorgularda düşük boyutlu anlamsal temsiller elde etmek, veri işleme için önemli bir problemdir. CLSM (Convolutional Latent Semantic Model) adı verilen model kullanılarak web sayfalarından tıklama verisi ile eğitilen büyük çaplı bir gerçek dünya verisi üzerinde çalışılmıştır. Döküman sıralama (document ranking) değerlendirme yapılmış, belgelerdeki göz çarpan semantik bilgilerin elde edildiği, önceki yöntemlerden açıkça üstün olduğu görülmüştür [88].

Jianfeng Gao ve arkadaşlarının çalışmasında, okuduğu kaynak belgeye dayanarak bir kullanıcıya ilgi duyacağı belgeleri tavsiye etmek için CNN tabanlı derin bir anlamsal benzerlik modeli (DSSM) sunulmuştur. DSSM, milyonlarca Web geçişi üzerinde eğitim alıp ve kaynak-hedef belge çiftlerini özellik vektörlerine eşleştirmiştir. Bu sayede kaynak belgeler ile ilgi duyulabilecek belgeler arasındaki mesafeler azaltılmış olmuştur. Model sadece ilgililik (interestingness) alanında başarılı olmamış, ayrıca konu modelleme konusunda da etkili sonuçlar üretmiştir [89]. Anlamsal ayrıştırma konusunda buna benzer başka yaklaşımlar da uygulanmıştır [71-72].

Cümlelerin doğru ifade edilmesi dilin anlaşılması için önemlidir.

CNN yöntemiyle yapılan bir çalışmada cümlelerin semantik modellemesi üzerinde çalışılmış ve %25 hata oranlarıyla ciddi bir başarı göstermiştir [33]. Doğal dil işleme alanında kullanıcının sözleri konsept/alanına göre farklı etiketlenmelidir. Yapılan bir çalışmada veriler benzer olsa da, etiket veri setleri farklı olduğunda, mevcut ek açıklamalardan (annotation) yararlanmak için bir yaklaşım önerilmiştir. Bu yaklaşım CCA (canonical correlation analysis)'dan gelen etiket yerleştirmelerine dayanır. Sonuçlar incelendiğinde "takvim-hatırlatıcı" (Calendar-reminder) gibi önemli yakınlıklar ortaya çıkmıştır [90].

Karpathy ve Fei Fei çalışmalarında, görüntü verilerindeki doğru bölgelere uygun tanımlayıcılar eklemek için görüntü üzerinde CNN, cümleler üzerinde çift yönlü RNN algoritmalarını kullanarak geliştirdikleri modeli, Flickr8K, Flickr30K ve MSCOCO veri kümeleri üzerinde uygulamıştır. Bölge seviyesi ve tam görsel üzerinde üretilen tanımlayıcıların oldukça doğru olduğu görülmüştür [43]. Yine başka veri kümeleri ile, aynı problem benzer modeller kullanılarak çözülmüştür [91]. Mail spam tespiti de son yıllarda derin öğrenme alanında uygulama alanlarına girmiştir. DAE metoduyla yapılan bir çalışmada model, geleneksel yöntemlere göre daha üstün sonuçlar vermiştir [77]. Konuşma tanıma konusunda da DBN modeliyle yapılan çalışmalar ses kayıt verileri üzerinde etkileyici sonuçlar vermiştir [92], [93].

Görüntü/Video İşleme

Görüntü işleme alanında en popüler problemlerden biri görüntü sınıflandırma problemidir. Bu görev için ortak bir değerlendirme seti olarak genellikle MNIST kullanılır. MNIST eğitim için 60000 ve test için 10000 el yazısı rakamlarından oluşmaktadır. Yapay sinir ağlarından, istatistiksel yöntemlere kadar farklı türde çok sayıda yöntem bu veri kümesi üzerinde test edilmiştir [94]. Bugüne kadarki en başarılı sonuçlardan biri %0.23 hata ile Cireşan'ın 2012'de yaptığı çalışmadır. CNN modeli kullanılan bu çalışmada ön işlem olarak genişlik normalizasyonu uygulanmıştır [27].

Cireşan ve ekibi 2011 yılında da CNN modelini kullanarak, görsel desen tanıma yarışmasında ilk defa süper insan performansı elde etmiştir [19]. Ayrıca bu ekip, 2011 yılında ICDAR Çin el yazısı yarışması ve

2012'de ISBI resim bölümlenme yarışması kazanmıştır [18]. Alex Krizhevsky, Geoffrey Hinton ve ekibi tarafından oluşturulan benzer bir sistem, büyük ölçekli ImageNet yarışmasını, sıg makine öğrenme yöntemleri karşısında belirgin bir farkla kazanmıştır [22]. Benzer bir model aynı zamanda kanser tespiti için büyük medikal görüntülerin analizi konusundaki ICPR ve MICCAI yarışmalarını kazanmıştır [95]. 2014 ImageNet yarışmasında benzer derin öğrenme modelleri kullanılarak hata oranları daha da azaltılmıştır [22], [96], [97]. Bunların yanında derin öğrenme tabanlı denetimsiz öğrenme algoritmaları da etiketsiz verilerden sınıfa özgü özellikler çıkarılması için kullanılmaktadır. Quoc V. Le çalışmasında, havuzlama ve normalizasyon ile birlikte 9-katmanlı bir DAE ile internetten indirilmiş 10 milyon görüntü bulunan bir veri kümesi eğitmiştir. 1000 makine (16.000 çekirdek) ile oluşturulan bir paralel küme ile eğitim 3 günde yapılmıştır. Bu model sayesinde yüz etiketleme yapmadan yüz tanıma sistemi, hatta kedi yüzü ve insan vücudu parçası da tanımlamak mümkün olmuştur [98].

Nesne tanıma problemleri için de derin öğrenme algoritmaları oldukça başarılıdır. Derin kalıntı ağları (deep residual network) kullanılan bir çalışma ILSVRC 2015, ImageNet algılama, ImageNet yerelleştirme, COCO segmentasyon yarışmalarında 1. olmuştur [99]. Girshick ve ekibi, görüntüdeki nesnelere tanımlamak ve anlamsal segmentasyon yapmak için bölgeleri ve CNN modelini bir araya getirdikleri, R-CNN adı verilen algoritmayla zengin özellikler elde etmişlerdir [100]. Sahne etiketleme problemi, bir görüntüdeki ham piksellerin ait olduğu nesne kategorisiyle etiketlenmesiyle çözülebilir. Clement Farabet çalışmasında çoklu ölçekli (multiscale) CNN modeli önermiştir. Bu model, SIFT Flow, Barcelona, Stanford arka plan veri kümeleri üzerinde diğer yaklaşımlara göre çok daha hızlı ve başarılı sonuçlar üretmiştir [101]. Üzerinde çalışılan bir başka problemde trafikteki yayaların tespiti. Bu konuda seyrek (sparse) CNN modeliyle geliştirilen denetimsiz öğrenme yöntemi rekabetçi sonuçlar vermiştir [102].

Biyomedikal Sinyal/Görüntü İşleme

Derin öğrenme, görüntü işlemenin bir alt dalı sayılabileceğinden, tıbbi görüntü analizi problemlerin çözümünde de oldukça etkilidir [103]. Beyin tümörü araştırmalarında, görüntü segmentasyonuna ihtiyaç duyulmaktadır. Bu görev için son yıllarda derin öğrenme yöntemleriyle başarılı bir şekilde otomatik

segmentasyon yapılmaktadır. Derin öğrenme modelleri, özellikle büyük miktarda MRI verileri ile nesnel yorumlar yapılmasına imkan sağlamıştır [104], [105]. Beyin tümörü için otomatik MRI Segmentasyonu konusunda özellikle CNN tabanlı algoritmalar, ayırt edici özellikler çıkararak başarılı sonuçlar üretmiştir [106]. Benzeri modeller, diğer hastalıklar için çekilen MRI görüntülerinde de uygulanmıştır. Prasoon ve arkadaşları, derin ağ modelini, düşük alan diz MRI taramalarında tibial kırıkdağın segmentasyonuna uygulamış ve 114 görünmeyen tarama üzerinde test etmiştir [107]. Zhang çalışmasında, meme kanseri klinik bilgisayar teşhisinde önemli bir parametre olan SWE (share wave elastography) verisinden elde edilen görüntülerden iyi-kötü huylu tümörlerin tespiti için otomatik özellik çıkarımı amacıyla bir derin öğrenme modeli kurmuştur. RBM ve PGBM (point-wise gated Boltzmann Machine) ile 2 katmanlı oluşturulan model 227 SWE verisiyle eğitilmiş, %93.4 doğruluk göstermiştir [108]. Sun ve ekibi tarafından yapılan çalışmada, akciğer kanseri tespitinde otomatik çıkarılan özellikler kullanan derin öğrenme ile, geleneksel yöntemlerle (elle) çıkarılan özellikleri kullanan CADx sistemi karşılaştırılmıştır. Derin öğrenme ağı CNN, DBN ve DAE olmak üzere 3 kanallı oluşturulmuştur. Sonuçlar AUC (area under curve) değerine göre incelendiğinde CADx karşısında, CNN belirgin bir şekilde üstün çıkmış, DBN yakın ama üstün bir değer vermiş, DAE ise daha kötü sonuçlar göstermiştir [109].

İlaç endüstri için aday ilaçların olumsuz sonuçlardan dolayı piyasaya sürülememesi büyük bir problemdir. Kimyasal bileşiklerdeki bu problem; bileşenlerin yetersiz etkinlik göstermesi, hedefte olmayan bileşenler ile hatalı tepkimeye girmesi veya beklenmeyen toksik etkilerden kaynaklanmaktadır [110]. 2012 yılında çoklu görev derin sinir ağı ile George Dahl ve ekibi bileşiğin biyomoleküler hedef tahmini konusundaki “Merck Moleküler Aktivite Sorunu” [111] isimli bir yarışmayı kazanmışlardır [112]. 2014 yılında ise Sepp Hochreiter ve ekibi yine derin öğrenme kullanarak ilaçlardaki hedef dışı ve toksik etkileri tespit etmek için açılan bir yarışmayı kazanmışlardır [113]. Bu ve benzeri gelişmeler derin öğrenmenin sanal tarama konusunda üstün olabileceğini göstermiştir [114]. 2015 yılında yapı temelli ilaç tasarımı için derin öğrenme kullanılan AtomNet, Atomwise şirketi tarafından piyasaya sürülmüş ve ardından ebola ve skleroz gibi hastalıklar için yeni aday biyomoleküllerin keşfinde kullanılmıştır [36].

Genetik bilgilerin açıklanması biyo-enformatik dalında önemli bir problemdir. Bu sorunun çözümü için DAE tabanlı bir çözüm önerilmiş ve standart makine öğrenmesi yöntemlerine göre daha iyi sonuçlar üretmiştir [115]. Hochreiter, LSTM modelini, uzak protein homolojisi tespiti için iyi bilinen bir kalite ölçütüne (benchmark) -bir proteinin bir SCOP süper ailesine ait olarak sınıflandırılması- uygulamıştır. Model, sınıflandırma için benzer yaklaşımlara doğruluk açısından yakın sonuçlar vermiş olsa da, onlara göre oldukça düşük bir çalışma zamanına sahip olduğu görülmüştür. [53]. DNA ve RNA'daki bağlayıcı proteinlerin dizilim özelliklerini bilmek, biyolojik sistemlerde düzenleyici süreç modelleri geliştirmek ve nedensel hastalık değişkenlerini tanımlamak için büyük önem arz etmektedir. Alipanahi ve ekibi, dizi özelliklerinin desen keşfi için ölçeklenebilir ve esnek bir yaklaşım sunan derin öğrenme modelini başarıyla kullanmışlardır [116].

Diğer Uygulamalar

Yukarıdaki bahsedilenlerin dışında çok farklı alanlardaki problemler için derin öğrenme yöntemlerinin uygulandığı görülmüştür. Uyku kalitesi tahmini için yapılan bir çalışmada bazı derin öğrenme yöntemleri (CNN, RNN, LSTM, vs.) ile geleneksel lojistik regresyonun öngörücülerin performansını karşılaştırılmış, CNN algoritması en iyi sonucu vermiştir [117]. Ayrıca insanlar üzerinde aktivite tanıma ve hareket tespiti gibi konularda da derin öğrenme algoritmaları uygulanmıştır [91, 110]. CRM (Müşteri İlişkileri Yönetimi) otomasyonu konusunda derin takviye öğrenme (deep reinforcement learning) yöntemi denenmiştir. RFM (güncellik-frekans-tutar) değişkenleri açısından tanımlanan müşteri durumu alanlarındaki muhtemel doğrudan pazarlama eylemlerinin değerini yaklaşık olarak hesaplamak için yapay sinir ağı kullanılmıştır [118]. DARPA, doğal dil işlemenin gücünü kullanmak için Derin Araştırma ve Metin Filtreleme (Deep Exploration and Filtering of Text-DEFT) programını yaratmıştır. Bu yapay zekanın, savunma analistlerinin büyük boyutlu belgeleri verimli bir şekilde araştırmalarını sağlayacak potansiyele sahip olduğu ve bu belgeler içinde örtülü olarak ifade edilen, aktivite içeren bilgileri keşfedebileceği (anormallik tespiti) açıklanmıştır [119].

Araç otonom sistemleri, multimedya yönetimi gibi konularda da derin öğrenme uygulamaları denenmekte, önümüzdeki yıllarda bu yönde daha fazla gelişmeler beklenmektedir. NVIDIA tarafından

üretilecek derin öğrenme kartları ve süper bilgisayarlar bu hedefler için çalıştırılmaktadır [120]. Akıllı şehirlerin kurulmasında akıllı trafik planlaması önemli bir etkidir. Ulaşım ağındaki doğrusal olmayan ve rastgele özelliklerin üstesinden gelmek önemli bir zorluktur. Niu ve arkadaşları, DeepSense adı verilen derin öğrenme modeli ile taksi GPS verileriyle eğitilerek trafik akış tahmini yapmışlardır. Önerilen model ile mevcut yöntemlere göre %5 iyileştirme sağlanmıştır [121]. Ma ve ekibi, RBM kullanarak trafik sıklığı modellenmesi üzerinde çalışmışlardır [122]. Kapalı alan yönlendirmesi başka önemli bir problemdir. Kim ve Chen, drone için otonom olarak iç mekanlarda dolaşabileceği ve tek bir kamera kullanarak belli bir hedefi (örn; çanta) bulabileceği düşünülen bir sistem önermiştir. Çalışma, CNN algoritmasıyla uzman pilotun eylem

seçimleri taklit edilmiş, sistem performansı, çeşitli kapalı mekanlardaki gerçek zamanlı deneylerle gösterilmiştir [123].

2.5. Derin Öğrenme Üzerinde Çalışan Araştırma Ekipleri

Derin öğrenme konusunda birçok üniversite ve büyük çaplı şirketler çalışmalar yapmaktadır. Ayrıca bu alanda başarılı işler çıkaran başlangıç şirketlerinin büyük yatırımlar alındıkları görülmüştür [23]. Başlıca çalışma grupları, bu ekiplerin önde gelen isimleri, kullandıkları kütüphaneler ve çalışma alanları Tablo 1’de verilmiştir.

Tablo 1: Derin Öğrenme çalışan ekipler hakkında bilgiler.

Araştırma Grupları ve Lab.	Ekip	Kütüphaneler	Çalışma Alanları ²
Toronto Ün. - Makine Öğrenmesi Grubu	Geoffrey Hinton Ruslan Salakhutdinov	Torch	DDİ, Gİ
Montréal Ün. - MILA Lab.	Yoshua Bengio Pascal Vincent	Theano Pylearn2	DDİ, Gİ, Sİ
New York Üniversitesi - CILVR Lab.	Yann Lecun Rob Fergus	Theano C++ (CUDA)	DDİ, BG, SR
Stanford Ün. - SAIL ve SVL	Andrew Ng Fei-fei Li	TensorFlow Java	BG, DDİ, SR
Kaliforniya Ün. - BAIR	Pieter Abbeel Trevor Darrell	Caffe	BG, DDİ, SR
Koç Ün. - AI Lab.	Deniz Yuret	KNET	DDİ, Gİ
Google Research Google DeepMind	Jeff Dean Corinna Cortes	TensorFlow	Gİ, DDİ
Facebook - FAIR	Yann Lecun Larry Zitnick	Caffe2	DDİ, BG
Twitter - Cortex	Hugo Larochelle Clement Farabet	Torch	DDİ, Gİ, BG
Microsoft - DLTC	Xiaodong He Jianfeng Gao	Caffe	DDİ, BG
İsviçre U. B. Ün. - IDSIA	Jurgen Schmidhuber Alessandro Antonucci	-	Gİ, SR
Baidu - Derin Öğrenme Enstitüsü (IDL)	Lin Yuanqing Wei Xu	-	DDİ, Gİ

² Tabloda çalışma alanları kısmında kısaltmalar kullanılmıştır. Doğal dil işleme için DDİ, sinyal işleme için Sİ, görüntü işleme için Gİ, Bilgisayarlı görü için BG, Sağlık ve robotik için SR olarak kısaltmalar verilmiştir.

2.6. Derin Öğrenme Kütüphaneleri/Yazılımları

Derin öğrenme için geliştirilen çok farklı çerçeve ve kütüphane bulunmaktadır [124]. Tablo 2’de bu kütüphanelerden bazıları hakkında kısa bilgiler verilmiştir.

Tablo 2: Derin Öğrenme Kütüphaneleri

Kütüphane	Yazıldığı dil	Geliştirici	Öne çıkan özellikleri
Theano [125]-[127]	Python	MILA Lab	- Öğreticileri (tutorial) çok etkili. - Keras, Blocks gibi API sayesinde matematiksel hesaplar kolaylaştırması. - GPU desteği.
Caffe [128]	Python	Berkeley Vision and Learning Center (BVLC)	- Caffe Model Zoo üzerinden indirilebilecek ve hemen kullanılacak önceden eğitilmiş ağların bulunması. - GPU desteği.
Torch [129]	Lua	Ronan Collobert, Clement Farabet, ...	- Algoritmaları oluşturma konusunda maksimum esnekliğe ve hıza sahip olması. - GPU desteği. (CUDA) - Kullanıcı dostu arayüz
Digits [130]	C++	NVIDIA	- Çoklu GPU sistemleri üzerinde sinir ağları tasarımı ve eğitimi, - Gelişmiş görselleştirmelerle performansı gerçek zamanlı olarak izleme - Tamamen etkileşimli
TensorFlow [131]	Python	Google	- Tek bir API ile bir masaüstü, sunucu veya mobil cihazdaki bir veya daha fazla CPU’ya veya GPU’ya dağıtma olanağı.
DeepLearning [132]	Java	Adam Gibson	- JVM tabanlı
KNET [133]	Julia	Deniz Yuret	- Kolay anlaşılır, kısa kodlama yeteneği. - İfade gücü. - GPU Desteği

Bu kütüphanelerden Knet, Theano, Torch, Caffe ve TensorFlow için bazı veri kümeleri ve modeller üzerinden tek GPU ile çalışma zamanı performansının karşılaştırması Tablo 3’te verilmiştir [134].

Tablo 3: Kütüphanelerin çalışma zamanı performansının karşılaştırılması

Model	Veri Kümesi	Knet	Theano	Torch	Caffe	TensorFlow
LinReg	Housing	2.84	<u>1.88</u>	2.66	2.35	5.92
Softmax	MNIST	2.35	<u>1.40</u>	2.88	2.45	5.57
MLP	MNIST	3.68	<u>2.31</u>	4.03	3.69	6.94
LeNet	MNIST	3.59	3.03	<u>1.69</u>	3.54	8.77
CharLM	Hiawatha	2.25	2.42	2.23	<u>1.43</u>	2.86

Tablo incelendiğinde Theano genelde en hızlı çalışan, TensorFlow ise en yavaş çalışan kütüphane olarak görülmektedir.

3. Potansiyel Çalışma Alanları (Potential Study Fields)

Önceki bölümlerde de anlatıldığı gibi derin öğrenme algoritmaları çok farklı alandaki problemlerde kullanılmaktadır. Artan veri miktarıyla birlikte görüntü işleme alanında özellikle görüntü sınıflandırma, nesne tanıma gibi problemler öne

çıkılmaktadır. Konu ile ilgili ILSVRC gibi yarışmalarda artık büyük veri ile başa çıkabilecek bir yöntem olarak kendisini ispatlayan derin öğrenme metodları sıklıkla kullanılmakta ve en başarılı sonuçları vermektedir [29]. Bunun yanında otonom araç teknolojilerinde gerçek zamanlı veri işleme yeteneği ile GPU tabanlı derin öğrenme algoritmaları

kullanılmaktadır. Araçlardaki 4-5 kamera ve birçok sensörden gelen verilerle başa çıkabilmek için derin öğrenme gelecekte de kullanılacak bir yol olarak görülmektedir. Büyük verinin en önemli problemlerinden bir tanesi de etiketleme maliyetidir. Bunun üstesinden gelmek için yine gelecekte denetimsiz derin öğrenme yöntemleri ön plana çıkacaktır.

Derin öğrenme üzerinde araştırma yapan ekiplerin neredeyse hepsi doğal dil işleme alanında geliştirmeler yapmaktadır (Tablo 1). Ancak çoğu çalışmanın İngilizce için yapıldığı görülmüştür. Özellikle Türkçe için bu alanda yapılan çalışmalar büyük önem arz etmektedir. Doğal dil işleme konusunda metin özetleme, sınıflandırma, soru-cevap gibi problemlerin çözümünde derin öğrenme algoritmalarının (özellikle RNN, LSTM, CNN gibi) başarı bir şekilde kullanıldığı görülmüştür. Bu sebeple, bu alana yönelmek, Türkçe için çözümler sunmak değerli olacaktır.

Kaynaklar (References)

- [1] J. Schmidhuber, “Deep learning in neural networks: An overview,” *Neural Networks*, vol. 61, pp. 85–117, 2015.
- [2] Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, pp. 436–444, 2015.
- [3] A. L. Blum and P. Langley, “Selection of relevant features and examples in machine learning,” *Artif. Intell.*, vol. 97, no. 1–2, pp. 245–271, Dec. 1997.
- [4] Y. Bengio, A. Courville, and P. Vincent, “Representation Learning: A Review and New Perspectives,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 35, no. 8, pp. 1798–1828, 2013.
- [5] L. Deng and D. Yu, “Deep Learning: Methods and Applications,” *Found. Trends® Signal Process.*, vol. 7, no. 3–4, pp. 197–387, 2014.
- [6] Y. Bengio, “Learning Deep Architectures for AI,” *Found. trends® Mach. Learn.*, vol. 2, no. 1, pp. 1–127, 2009.
- [7] H. A. Song and S.-Y. Lee, “Hierarchical Representation Using NMF,” in *International Conference on Neural Information Processing.*, 2013, pp. 466–473.
- [8] A. G. Ivakhnenko and V. G. Lapa, “Cybernetic Predicting Devices,” 1966.
- [9] Tim Dettmers, “Deep Learning in a Nutshell: History and Training Parallel Forall,” 2015. [Online]. Available: <https://devblogs.nvidia.com/paralleforall/deep-learning-nutshell-history-training/>. [Accessed: 20-Mar-2017].
- [10] K. . N. Fukushima, “A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position.,” *Biol. Cybern.*, vol. 36, no. 4, pp. 193–202, 1980.
- [11] Y. LeCun et al., “Backpropagation Applied to Handwritten Zip Code Recognition,” *Neural Comput.*, vol. 1, no. 4, pp. 541–551, Dec. 1989.
- [12] LeCun Yann, Boser B, and Denker J S, “Handwritten Digit Recognition with a Back-Propagation Network,” 1989.
- [13] G. E. Hinton, P. Dayan, B. J. Frey, and R. M. Neal, “The wake-sleep algorithm for unsupervised neural networks,” *Science*, vol. 268, no. 5214, pp. 1158–61, May 1995.
- [14] S. Hochreiter and J. Schmidhuber, “Long Short-Term Memory,” *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997.
- [15] C. Cortes and V. Vapnik, “Support-Vector Networks,” *Mach. Learn.*, vol. 20, no. 3, pp. 273–297, 1995.
- [16] I. N. Aizenberg, N. N. Aizenberg, and J. Vandewalle, “Multiple-Valued Threshold Logic and Multi-Valued Neurons,” in *Multi-Valued and Universal Binary Neurons*, Boston, MA: Springer US, 2000, pp. 25–80.
- [17] G. E. Hinton, “Learning multiple layers of representation,” *Trends Cogn. Sci.*, vol. 11, no. 10, pp. 428–434, Oct. 2007.
- [18] D. Cireşan, A. Giusti, L. M. Gambardella, and J. Schmidhuber, “Deep Neural Networks Segment Neuronal Membranes in Electron Microscopy Images,” in *Advances in neural information processing systems*, 2012, pp. 2843–2851.
- [19] D. Cireşan, U. Meier, J. Masci, and J. Schmidhuber, “Multi-column deep neural network for traffic sign classification,” *Neural Networks*, vol. 32, pp. 333–338, 2012.

- [20] D. C. Cireşan, U. Meier, L. M. Gambardella, and J. Schmidhuber, "Convolutional Neural Network Committees for Handwritten Character Classification," in 2011 International Conference on Document Analysis and Recognition, 2011, pp. 1135–1139.
- [21] G. E. Hinton, N. Srivastava, A. Krizhevsky, I. Sutskever, and R. R. Salakhutdinov, "Improving Neural Networks by Preventing Co-adaptation of Feature Detectors," *Neural Evol. Comput.*, Jul. 2012.
- [22] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," in *Advances in neural information processing systems*, 2012, pp. 1097–1105.
- [23] "The Race For AI: Google, Twitter, Intel, Apple In A Rush To Grab Artificial Intelligence Startups," *cbinsights*, 2017. [Online]. Available: <https://www.cbinsights.com/blog/top-acquirers-ai-startups-ma-timeline/>. [Accessed: 21-Apr-2017].
- [24] D. H. Hubel and T. N. Wiesel, "Receptive fields and functional architecture of monkey striate cortex," *J. Physiol.*, vol. 195, no. 1, pp. 215–243, Mar. 1968.
- [25] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proc. IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
- [26] Y. Le Cun et al., "Handwritten digit recognition: applications of neural network chips and automatic learning," *IEEE Commun. Mag.*, vol. 27, no. 11, pp. 41–46, Nov. 1989.
- [27] D. Cireşan, U. Meier, and J. Schmidhuber, "Multi-column Deep Neural Networks for Image Classification," Feb. 2012.
- [28] D. C. Cireşan, U. Meier, J. Masci, and L. M. Gambardella, "Flexible, High Performance Convolutional Neural Networks for Image Classification," in *Proceedings of the Twenty-Second international joint conference on Artificial Intelligence*, 2012, pp. 1237–1242.
- [29] "Results of ILSVRC2014," 11-Nov-2014. [Online]. Available: <http://arxiv.org/abs/1311.2524>. [Accessed: 26-Apr-2017].
- [30] S. S. Farfadi, M. Saberian, and L.-J. Li, "Multi-view Face Detection Using Deep Convolutional Neural Networks," in *Proceedings of the 5th ACM on International Conference on Multimedia Retrieval*, 2015, pp. 643–650.
- [31] E. Grefenstette, P. Blunsom, N. de Freitas, and K. M. Hermann, "A Deep Architecture for Semantic Parsing," Apr. 2014.
- [32] Y. Shen, X. He, J. Gao, L. Deng, and G. Mesnil, "Learning semantic representations using convolutional neural networks for web search," in *Proceedings of the 23rd International Conference on World Wide Web - WWW '14 Companion*, 2014, pp. 373–374.
- [33] N. Kalchbrenner, E. Grefenstette, and P. Blunsom, "A Convolutional Neural Network for Modelling Sentences," Apr. 2014.
- [34] Y. Kim, "Convolutional Neural Networks for Sentence Classification," Aug. 2014.
- [35] R. Collobert and J. Weston, "A unified architecture for natural language processing: Deep neural networks with multitask learning," in *Proceedings of the 25th international conference on Machine learning - ICML '08*, 2008, vol. 20, no. 1, pp. 160–167.
- [36] I. Wallach, M. Dzamba, and A. Heifets, "AtomNet: A Deep Convolutional Neural Network for Bioactivity Prediction in Structure-based Drug Discovery," Oct. 2015.
- [37] J. Yosinski, J. Clune, A. Nguyen, T. Fuchs, and H. Lipson, "Understanding Neural Networks Through Deep Visualization," Jun. 2015.
- [38] C. J. Maddison, A. Huang, I. Sutskever, and D. Silver, "Move Evaluation in Go Using Deep Convolutional Neural Networks," Dec. 2014.
- [39] C.-S. Lee et al., "Human vs. Computer Go: Review and Prospect [Discussion Forum]," *IEEE Comput. Intell. Mag.*, vol. 11, no. 3, pp. 67–72, Aug. 2016.
- [40] J. L. Elman, "Finding Structure in Time," *Cogn. Sci.*, vol. 14, no. 2, pp. 179–211, Mar. 1990.
- [41] T. Mikolov, "Recurrent neural network based language model," in *Interspeech*, 2010.
- [42] A. Graves and N. Jaitly, "Towards End-To-End Speech Recognition with Recurrent Neural Networks.," in *ICML*, 2014, pp. 1764–1772.

- [43] A. Karpathy and L. Fei-Fei, "Deep Visual-Semantic Alignments for Generating Image Descriptions," in CVPR, 2015, pp. 3128–3137.
- [44] Y. Bengio, P. Simard, and P. Frasconi, "Learning long-term dependencies with gradient descent is difficult," *IEEE Trans. Neural Networks*, vol. 5, no. 2, pp. 157–166, Mar. 1994.
- [45] K. Greff, R. K. Srivastava, J. Koutník, B. R. Steunebrink, and J. Schmidhuber, "LSTM: A Search Space Odyssey," Mar. 2015.
- [46] F. A. Gers, J. Schmidhuber, and F. Cummins, "Learning to forget: continual prediction with LSTM.," *Neural Comput.*, vol. 12, no. 10, pp. 2451–71, Oct. 2000.
- [47] F. A. Gers and J. Schmidhuber, "Recurrent nets that time and count," in Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks. IJCNN 2000. Neural Computing: New Challenges and Perspectives for the New Millennium, 2000, pp. 189–194 vol.3.
- [48] A. Graves and J. Schmidhuber, "Framewise phoneme classification with bidirectional LSTM and other neural network architectures," *Neural Networks*, vol. 18, no. 5–6, pp. 602–610, Jul. 2005.
- [49] A. Graves, A. Mohamed, and G. Hinton, "Speech recognition with deep recurrent neural networks," in 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, 2013, pp. 6645–6649.
- [50] S. Fernández, A. Graves, and J. Schmidhuber, "An Application of Recurrent Neural Networks to Discriminative Keyword Spotting," in International Conference on Artificial Neural Networks, 2007, pp. 220–229.
- [51] M. Baccouche, F. Mamalet, C. Wolf, C. Garcia, and A. Baskurt, "Sequential Deep Learning for Human Action Recognition," Springer, Berlin, Heidelberg, 2011, pp. 29–39.
- [52] D. Eck and J. Schmidhuber, "Learning the Long-Term Structure of the Blues," Springer, Berlin, Heidelberg, 2002, pp. 284–289.
- [53] S. Hochreiter, M. Heusel, and K. Obermayer, "Fast model-based protein homology detection without alignment," *Bioinformatics*, vol. 23, no. 14, pp. 1728–1736, Jul. 2007.
- [54] H. Mayer, F. Gomez, D. Wierstra, I. Nagy, A. Knoll, and J. Schmidhuber, "A System for Robotic Heart Surgery that Learns to Tie Knots Using Recurrent Neural Networks," in 2006 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2006, pp. 543–548.
- [55] J. Schmidhuber, F. Gers, and D. Eck, "Learning Nonregular Languages: A Comparison of Simple Recurrent Networks and LSTM," *Neural Comput.*, vol. 14, no. 9, pp. 2039–2041, Sep. 2002.
- [56] A. Graves, "Offline Handwriting Recognition with Multidimensional Recurrent Neural Networks."
- [57] P. Smolensky, "Information Processing in Dynamical Systems: Foundations of Harmony Theory," 1986.
- [58] G. E. Hinton and R. R. Salakhutdinov, "Reducing the Dimensionality of Data with Neural Networks," *Science (80-.)*, vol. 313, no. 5786, pp. 504–507, Jul. 2006.
- [59] R. Salakhutdinov and G. Hinton, "Deep Boltzmann Machines," in International Conference on Artificial Intelligence and Statistics, 2009, pp. 3–11.
- [60] M. A. Carreira-Perpiñán and G. E. Hinton, "On Contrastive Divergence Learning," *Artif. Intell. Stat.*, vol. 10, 2005.
- [61] H. Larochelle and Y. Bengio, "Classification using discriminative restricted Boltzmann machines," in Proceedings of the 25th international conference on Machine learning - ICML '08, 2008, pp. 536–543.
- [62] R. Salakhutdinov, A. Mnih, and G. Hinton, "Restricted Boltzmann machines for collaborative filtering," in Proceedings of the 24th international conference on Machine learning - ICML '07, 2007, pp. 791–798.
- [63] A. Coates, A. Ng, and H. Lee, "An Analysis of Single-Layer Networks in Unsupervised Feature Learning," in PMLR, 2011, pp. 215–223.
- [64] G. E. Hinton and R. R. Salakhutdinov, "Replicated Softmax: an Undirected Topic Model," in Advances in Neural Information Processing Systems 22, 2009, pp. 1607–1614.
- [65] G. E. Hinton, S. Osindero, and Y.-W. Teh, "A Fast Learning Algorithm for Deep Belief Nets,"

- Neural Comput., vol. 18, no. 7, pp. 1527–1554, Jul. 2006.
- [66] M. Ranzato, F. J. Huang, Y.-L. Boureau, and Y. LeCun, “Unsupervised Learning of Invariant Feature Hierarchies with Applications to Object Recognition,” in 2007 IEEE Conference on Computer Vision and Pattern Recognition, 2007, pp. 1–8.
- [67] Y. Bengio, P. Lamblin, D. Popovici, and H. Larochelle, “Greedy layer-wise training of deep networks,” Proceedings of the 19th International Conference on Neural Information Processing Systems. MIT Press, pp. 153–160, 2006.
- [68] R. Salakhutdinov and G. Hinton, “Semantic hashing,” *Int. J. Approx. Reason.*, vol. 50, pp. 969–978, 2009.
- [69] G. W. Taylor, G. E. Hinton, and S. T. Roweis, “Modeling Human Motion Using Binary Latent Variables,” in *Advances in Neural Information Processing Systems 19*, 2006, pp. 1345–1352.
- [70] Y. Bengio, “Learning Deep Architectures for AI,” *Found. Trends® Mach. Learn.*, vol. 2, no. 1, pp. 1–127, 2009.
- [71] C.-Y. Liou, W.-C. Cheng, J.-W. Liou, and D.-R. Liou, “Autoencoder for words,” *Neurocomputing*, vol. 139, pp. 84–96, 2014.
- [72] A. B. L. Larsen and S. K. Sønderby, “Generating Faces with Torch,” 13-Nov-2015. [Online]. Available: <http://arxiv.org/abs/1506.05751>. [Accessed: 27-Apr-2017].
- [73] D. P. Kingma and M. Welling, “Auto-Encoding Variational Bayes,” Dec. 2013.
- [74] A. Krizhevsky and G. E. Hinton, “Using Very Deep Autoencoders for Content Based Image Retrieval,” in *European Symposium on Artificial Neural Networks*, 2011, pp. 489–494.
- [75] A. Seker and A. Gürkan YUKSEK, “Stacked Autoencoder Method for Fabric Defect Detection,” *Sci. Sci. J.*, vol. 38, no. 2, 2017.
- [76] “Stacked Autoencoders,” Stanford University, 2013. [Online]. Available: http://ufldl.stanford.edu/wiki/index.php/Stacked_Autoencoders. [Accessed: 27-Apr-2017].
- [77] G. Mi, Y. Gao, and Y. Tan, “Apply Stacked Auto-Encoder to Spam Detection,” *Adv. Swarm Comput. Intell.*, vol. 9141, pp. 3–15, 2015.
- [78] L. Deng, M. Seltzer, D. Yu, A. Acero, A. Mohamed, and G. Hinton, “Binary Coding of Speech Spectrograms Using a Deep Auto-encoder,” in *Interspeech 2010*, 2010, p. 1692–1695.
- [79] O. Lyudchik, “Outlier detection using autoencoders,” 2016.
- [80] S. Yadav and S. Subramanian, “Detection of Application Layer DDoS attack by feature learning using Stacked AutoEncoder,” in *International Conference on Computational Techniques in Information and Communication Technologies*, 2016, pp. 361–366.
- [81] S. Zhou, Q. Chen, and X. Wang, “Active deep learning method for semi-supervised sentiment classification,” *Neurocomputing*, vol. 120, pp. 536–546, 2013.
- [82] S. Zhou, Q. Chen, and X. Wang, “Fuzzy deep belief networks for semi-supervised sentiment classification,” *Neurocomputing*, vol. 131, pp. 312–322, 2014.
- [83] Y. Goldberg and O. Levy, “word2vec Explained: deriving Mikolov et al.’s negative-sampling word-embedding method,” Feb. 2014.
- [84] L. You, Y. Li, Y. Wang, J. Zhang, and Y. Yang, “A deep learning-based RNNs model for automatic security audit of short messages,” in *2016 16th International Symposium on Communications and Information Technologies (ISCIT)*, 2016, pp. 225–229.
- [85] M. Yousefi-Azar and L. Hamey, “Text Summarization Using Unsupervised Deep Learning,” *Expert Syst. Appl.*, vol. 68, pp. 93–105, Feb. 2017.
- [86] A. Sboev, T. Litvinova, D. Gudovskikh, R. Rybka, and I. Moloshnikov, “Machine Learning Models of Text Categorization by Author Gender Using Topic-independent Features,” *Procedia Comput. Sci.*, vol. 101, pp. 135–142, 2016.
- [87] M. L. Brocardo, I. Traore, I. Woungang, and M. S. Obaidat, “Authorship verification using deep belief network systems,” *Int. J. Commun. Syst.*, p. e3259, 2017.

- [88] Y. Shen, X. He, J. Gao, L. Deng, and G. Mesnil, "A Latent Semantic Model with Convolutional-Pooling Structure for Information Retrieval," in *CIKM*, 2014.
- [89] J. Gao, L. Deng, M. Gamon, and X. He, "Modeling interestingness with deep neural networks," 14/304,863, 2014.
- [90] Y.-B. Kim, K. Stratos, R. Sarikaya, and M. Jeong, "New Transfer Learning Techniques For Disparate Label Sets," in *Association for Computational Linguistics*, 2015.
- [91] O. Vinyals, A. Toshev, S. Bengio, and D. Erhan, "Show and Tell: A Neural Image Caption Generator," *arXiv*, vol. 32, no. 1, pp. 1–10, Nov. 2014.
- [92] A.-R. Mohamed, T. N. Sainath, G. Dahl, B. Ramabhadran, G. E. Hinton, and M. A. Picheny, "DEEP BELIEF NETWORKS USING DISCRIMINATIVE FEATURES FOR PHONE RECOGNITION," in *Acoustics, Speech and Signal Processing*, 2011, p. 5060–5063.
- [93] G. Hinton et al., "Deep Neural Networks for Acoustic Modeling in Speech Recognition: The Shared Views of Four Research Groups," *IEEE Signal Process. Mag.*, vol. 29, no. 6, pp. 82–97, Nov. 2012.
- [94] Y. LeCun, C. Cortes, and C. Burges, "MNIST handwritten digit database." [Online]. Available: <http://yann.lecun.com/exdb/mnist/>. [Accessed: 30-Apr-2017].
- [95] D. C. Cireşan, A. Giusti, L. M. Gambardella, and J. Schmidhuber, "Mitosis Detection in Breast Cancer Histology Images with Deep Neural Networks," in *Medical Image Computing and Computer-Assisted Intervention*, 2013, pp. 411–418.
- [96] "ImageNet," Stanford Vision Lab, 2016. [Online]. Available: <http://image-net.org/>. [Accessed: 30-Apr-2017].
- [97] O. Russakovsky et al., "ImageNet Large Scale Visual Recognition Challenge," *Int. J. Comput. Vis.*, vol. 115, no. 3, pp. 211–252, Dec. 2015.
- [98] Q. V. Le et al., "Building high-level features using large scale unsupervised learning," *arXiv Prepr. arXiv1112.6209*, Dec. 2011.
- [99] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 770–778.
- [100] R. Girshick, J. Donahue, T. Darrell, and J. Malik, "Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation," in *The IEEE Conference on Computer Vision and Pattern Recognition*, 2014, pp. 580–587.
- [101] C. Farabet, C. Couprie, L. Najman, and Y. LeCun, "Learning Hierarchical Features for Scene Labeling," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 35, no. 8, pp. 1915–1929, Aug. 2013.
- [102] P. Sermanet, K. Kavukcuoglu, S. Chintala, and Y. Lecun, "Pedestrian Detection with Unsupervised Multi-stage Feature Learning," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2013, pp. 3626–3633.
- [103] S. K. Zhou, H. Greenspan, and D. Shen, *Deep learning for medical image analysis*. .
- [104] M. Havaei et al., "Brain tumor segmentation with Deep Neural Networks," *Med. Image Anal.*, vol. 35, pp. 18–31, Jan. 2017.
- [105] A. Işın, C. Direkoğlu, and M. Şah, "Review of MRI-based Brain Tumor Image Segmentation Using Deep Learning Methods," *Procedia Comput. Sci.*, vol. 102, pp. 317–324, 2016.
- [106] G. Urban, M. Bendszus, F. A. Hamprecht, and J. Kleesiek, "Multi-modal Brain Tumor Segmentation using Deep Convolutional Neural Networks," in *MICCAI BraTS (Brain Tumor Segmentation) Challenge. Proceedings, winning contribution*, 2014, pp. 31–35.
- [107] A. Prason, K. Petersen, C. Igel, F. Lauze, E. Dam, and M. Nielsen, "Deep Feature Learning for Knee Cartilage Segmentation Using a Triplanar Convolutional Neural Network," in *MICCAI*, 2013, pp. 246–253.
- [108] Q. Zhang et al., "Deep learning based classification of breast tumors with shear-wave elastography," *Ultrasonics*, vol. 72, pp. 150–157, 2016.
- [109] W. Sun, B. Zheng, and W. Qian, "Automatic Feature Learning Using Multichannel ROI Based on Deep Structured Algorithms for Computerized Lung Cancer Diagnosis," *Comput. Biol. Med.*, 2017.

- [110] J. Arrowsmith and P. Miller, "Trial Watch: Phase II and Phase III attrition rates 2011–2012," *Nat. Rev. Drug Discov.*, vol. 12, no. 8, pp. 569–569, Aug. 2013.
- [111] "Merck Molecular Activity Challenge," Kaggle. [Online]. Available: <https://www.kaggle.com/c/MerckActivity/details/winners>. [Accessed: 30-Apr-2017].
- [112] G. E. Dahl, N. Jaitly, and R. Salakhutdinov, "Multi-task Neural Networks for QSAR Predictions," Jun. 2014.
- [113] "Tox21 Data Challenge Final Subchallenge Leaderboard," 2014. [Online]. Available: <https://tripod.nih.gov/tox21/challenge/leaderboard.js> p. [Accessed: 01-May-2017].
- [114] T. Unterthiner, A. Mayr, M. Steijaert OpenAnalytics, J. K. Wegner Johnson, H. Ceulemans, and S. Hochreiter, "Deep Learning as an Opportunity in Virtual Screening," in *Workshop on Deep Learning and Representation Learning*, 2014.
- [115] D. Chicco, P. Sadowski, and P. Baldi, "Deep autoencoder neural networks for gene ontology annotation predictions," in *Proceedings of the 5th ACM Conference on Bioinformatics, Computational Biology, and Health Informatics - BCB '14*, 2014, pp. 533–540.
- [116] B. Alipanahi, A. DeLong, M. Weirauch, and B. Frey, "Predicting the sequence specificities of DNA- and RNA-binding proteins by deep learning," *Nat. Biotechnol.*, 2015.
- [117] A. Sathyanarayana et al., "Sleep Quality Prediction From Wearable Data Using Deep Learning," *JMIR mHealth uHealth*, vol. 4, no. 4, p. e125, Nov. 2016.
- [118] Y. Tkachenko, "Autonomous CRM Control via CLV Approximation with Deep Reinforcement Learning in Discrete and Continuous Action Space," *ArXiv*, Apr. 2015.
- [119] B. Onyshkevych, "Deep Exploration and Filtering of Text (DEFT)." [Online]. Available: <http://www.darpa.mil/program/deep-exploration-and-filtering-of-text>. [Accessed: 01-May-2017].
- [120] "The NVIDIA DGX-1 Deep Learning System," NVIDIA. [Online]. Available: <http://www.nvidia.com/object/deep-learning-system.html>. [Accessed: 01-May-2017].
- [121] X. Niu, Y. Zhu, and X. Zhang, "DeepSense: A novel learning mechanism for traffic prediction with taxi GPS traces," in *2014 IEEE Global Communications Conference*, 2014, pp. 2745–2750.
- [122] X. Ma, H. Yu, Y. Wang, Y. Wang, and M. González, "Large-Scale Transportation Network Congestion Evolution Prediction Using Deep Learning Theory," *PLoS One*, vol. 10, no. 3, p. e0119044, Mar. 2015.
- [123] D. K. Kim and T. Chen, "Deep Neural Network for Real-Time Autonomous Indoor Navigation," Nov. 2015.
- [124] "Comparison of deep learning software." [Online]. Available: https://en.wikipedia.org/wiki/Comparison_of_deep_learning_software. [Accessed: 01-May-2017].
- [125] Theano Development Team, "Theano: A {Python} framework for fast computation of mathematical expressions," *arXiv e-prints*, vol. abs/1605.02688.
- [126] Jason Brownlee, "Popular Deep Learning Libraries," 2016. [Online]. Available: <http://machinelearningmastery.com/popular-deep-learning-libraries/>. [Accessed: 01-May-2017].
- [127] "DeepLearning 0.1 documentation." [Online]. Available: <http://deeplearning.net/tutorial/contents> [Accessed: 01-May-2017].
- [128] Y. Jia et al., "Caffe: Convolutional Architecture for Fast Feature Embedding," Jun. 2014.
- [129] R. Collobert, C. Farabet, and K. Kavukcuoğlu, "Torch | Scientific computing for LuaJIT.," NIPS Workshop on Machine Learning Open Source Software, 2008. [Online]. Available: <http://torch.ch/>. [Accessed: 01-May-2017].
- [130] "NVIDIA DIGITS." [Online]. Available: <https://developer.nvidia.com/digits> [Accessed: 01-May-2017].
- [131] "TensorFlow." [Online]. Available: <https://www.tensorflow.org/> [Accessed: 01-May-2017].

[132] “Deeplearning4j: Open-source, Distributed Deep Learning for the JVM.” [Online]. Available: <https://deeplearning4j.org/> [Accessed: 01-May-2017].

[133] Deniz Yuret, “Welcome to Knet.jl’s documentation!” [Online]. Available: <http://denizyuret.github.io/Knet.jl/latest/>. Accessed: 17-Aug-2017].

[134] Deniz Yuret, “Julia ve Knet ile Derin Öğrenmeye Giriş,” 2016. [Online]. Available: <http://www.denizyuret.com/2016/09/julia-ve-knet-ile-derin-ogrenmeye-giris.html>. [Accessed: 17-Aug-2017].

Abdulkadir ŞEKER*

Abdulkadir ŞEKER, 2012 yılında Karadeniz Teknik Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği bölümünden mezun oldu. Erciyes Üniversitesi Fen Bilimleri Enstitüsü Elektrik ve Bilgisayar Mühendisliği’nde 2016 yılında yüksek lisansını tamamladı. 2013 yılında Cumhuriyet Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü’nde Araştırma Görevlisi olarak başladığı görevine halen devam etmektedir.