


DERİN ÖĞRENME VE TÜRKİYE'DEKİ UYGULAMALARI

Dr. Kıyas KAYAALP

Dr. Ahmet ALİ SÜZEN




İKSAD
Publishing House

DERİN ÖĞRENME VE TÜRKİYE'DEKİ UYGULAMALARI

Dr. Kıyas KAYAALP

Dr. Ahmet Ali SÜZEN



ISBN 978-605-7510-53-2

**Institution Of Economic Development And Social
Researches Publications®**

(The Licence Number of Publicator: 2014/31220)

TURKEY TR: +90 342 606 06 75

USA: +1 631 685 0 853

E posta: kongreiksad@gmail.com

www.iksad.org

www.iksadkongre.org

Kitabın tüm hakları IKSAD Yayınevi’ne aittir.

İzinsiz çoğaltılamaz, kopyalanamaz.

Metinlerden etik ve yasal olarak yazarlar sorumludur.

Iksad Publications - 2018© ISBN 978-605-7510-53-2

GRAFİK TASARIM: İBRAHİM KAYA

Dr. Kıyas KAYAALP

Dr. Kıyas KAYAALP, Lisans eğitimini Marmara Üniversitesi Elektronik ve Bilgisayar eğitiminde, Yüksek Lisans eğitimini Süleyman Demirel Üniversitesi Elektronik Bilgisayar Eğitimi bölümünde ve Doktora eğitimini de Süleyman Demirel Üniversitesi Fizik bölümünde tamamlamıştır. Halen Isparta Uygulamalı Bilimler Üniversitesinde Dr. Öğretim Üyesi olarak çalışmaktadır. Yazar Derin Öğrenme, Veri Madenciliği, Yapay Zekâ, Programlama Dilleri, Nesnelerin İnterneti konularında akademik çalışmalarına devam etmektedir.

Dr. Ahmet Ali SÜZEN

Dr. Ahmet Ali SÜZEN, Lisans ve Yüksek Lisans eğitimlerini Süleyman Demirel Üniversitesi Elektronik Bilgisayar Eğitimi bölümünde ve Doktora eğitimini de Süleyman Demirel Üniversitesi Bilgisayar Mühendisliğinde tamamlamıştır. Halen Isparta Uygulamalı Bilimler Üniversitesinde Öğretim Görevlisi Dr. olarak çalışmaktadır. Yazar Derin Öğrenme, Siber Güvenlik,

Adli Bilişim, Nesnelerin İnterneti konularında akademik çalışmalarına devam etmektedir. Ayrıca yazarın, WPF Programlama, Silverlight4.0 ve Robot Programlama kitapları bulunmaktadır.

ÖNSÖZ

Yapılan bilimsel çalışmalar sonucunda veriler ortaya çıkmaktadır. Bu veriler zamanla üzerinde çalışılması gereken büyüklüklere ulaşmaktadır. Elde edilen veriler aynı zamanda o alan ile ilgili gelecek çalışmalar hakkında bilgileri barındırabilmektedir. Bunun sonucunda elde edilen verilerin yorumlanarak sonuçlar çıkartılması konunun daha etkili öğrenilmesini sağlamaktadır. Bu sebeple birçok alanda başarılı sonuçlar almak için derin öğrenme algoritmaları kullanılmaktadır. Derin öğrenme, insan beyninin algılama ve karar verme özelliğini taklit eden bir makine öğrenmesi alanıdır.

Bu kitapta derin öğrenme ve yöntemlerinin tanımı, tarihsel gelişimi, süreci ve ülkemizdeki uygulama alanları işlenerek, derin öğrenmenin hangi alana nasıl uygulandığına dair somut örnekler incelenmiştir. Derin öğrenme algoritmaları olan CNN, RNN, RBM, LSTM ve derin oto kodlayıcıların geliştirilme süreçleri, uygulamalar üzerinden analiz edilmiştir. Ayrıca ülkemizdeki derin öğrenme uygulamaları mühendislik ve sağlık alan başlıkları altında incelenmiştir.

1.GİRİŞ

Yapay zekâ, insan davranışlarının makine tarafından taklit edilmesini sağlamaktadır. Bu sebeple otonom sistemlerin geliştirilmesinden yapay zekâ teknolojilerine ihtiyaç duyulmaktadır (Fürnkranz, 1999). Yapay zekâda karar verme veya tahmin oluşturma süreçleri makine öğrenmesi ile gerçekleşmektedir. Makine öğrenmesi gözetimli ve gözetimsiz yöntemleri kullanarak sınıflandırma ve kümeleme işlemlerini sağlar. Makine öğrenmesinden insan faktörün devre dışı bırakılarak, karmaşık verilerin hızlı öğrenilmesi ve uygulanmasında derin öğrenme yöntemleri kullanılmaktadır (Le, Bengio, Hinton, 2015).Dünyadaki teknolojik gelişmeler ve hedefler doğrultusunda ülkemizde derin öğrenme uygulamaları artmaktadır.

Gerçekleştirilen çalışmanın birinci bölümünde derin öğrenmenin tanımı, tarihçesi, süreci, algoritmaları ve kullanıldığı alanlar ile ilgili bilgiler verilmiştir. İkinci bölümde de derin öğrenme yöntemleri ve kütüphaneleri kullanılarak yapılan çalışmalar incelenmiştir. Bu çalışmalarda kullanılan yöntem ve elde edilen başarı

sonuçları verilmiştir. Ayrıca incelenen çalışmalar alanlara göre gruplanmıştır. Çalışma kapsamında elde edilen bilgilerin, derin öğrenme alanında çalışanlara kaynak oluşturması planlanmaktadır.

2.DERİN ÖĞRENME

2.1.Tanım

Bugüne kadar derin öğrenmenin, literatürde farklı kaynaklarda değişik birçok tanımı yapılmıştır. Derin öğrenme; bilgisayarların, deneyimlerden öğrenmelerini ve dünyayı kavramların hiyerarşisi açısından anlamalarını sağlayan bir makine öğrenimi olarak tanımlamıştır (Gu, Zhang, Kim, 2016).Başka bir kaynakta derin öğrenme; denetimli veya denetimsiz özellik çıkarma, dönüştürme, desen analizi ve sınıflandırma için birçok doğrusal olmayan gizli katmandan yararlanan bir makine öğrenme teknikleri sınıfı olarak tanımlamıştır (Deng, Yu, 2014). Yine derin öğrenme; insan beyninin son derece karmaşık problemler için gözlemlenme, analiz etme, öğrenme ve karar verme yeteneğini taklit etmeyi amaçlayan,büyük miktarda

denetimsiz veri kullanan bir makine öğrenmesi olarak tanımlanmıştır (Najafabadi, Villanustre, Khoshgoftaar, Seliya, Wald, Muharemagic, ,2015).

Derin öğrenme konusunda farklı kaynaklardan alınan tanımlar bileştirilecek olursa; derin öğrenme insan beyninin karmaşık problemler için gözleme, analiz etme, öğrenme ve karar verme gibi yeteneklerini taklit eden, denetimli veya denetimsiz olarak özellik çıkarma, dönüştürme ve sınıflandırma gibi işlemleri büyük miktarlardaki verilerden yararlanarak yapabilen bir makine öğrenmesi tekniğidir.

2.2.Tarihçe

Derin öğrenme, yapay sinir ağları ve insan beyninin işlevlerini taklit eden hesaplama sistemleri kavramına dayanır. Derin öğrenmenin tarihi, Warren McCulloch ve Walter Pitts'in 1943 yılında düşünce sürecini taklit etmek için matematiğe ve sinir mantığı olarak adlandırılan algoritmalara dayalı sinir ağları için bir hesaplama modeli oluşturmalarına uzanmaktadır (McCulloch, Pitts,

1943). 1958 yılında, Frank Rosenblatt tarafından basit toplama ve çıkarma işlemleri kullanılarak iki katmanlı bir bilgisayar yapay sinir ağına dayalı, denetimli öğretimli bir desen tanıma algoritması olan perceptron oluşturuldu (Haykin, 2009). 1965 yılında Ivakhnenko ve Lapa, derin öğrenme algoritmalarını geliştirmeye yönelik Siberetik Tahmin Araçları isimli çalışmalarında, karmaşık denklemlerin aktivasyon fonksiyonlarına sahip modelleri kullanmıştır (Ivakhnenko, Lapa, 1965).

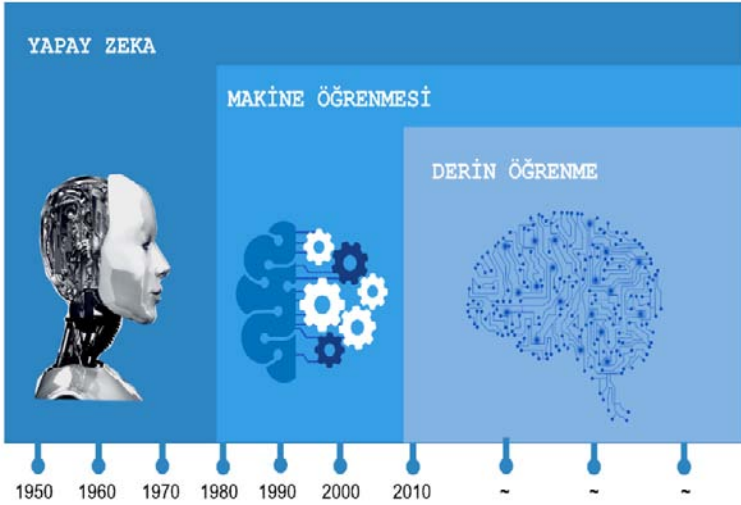
1980'li yıllara gelindiğinde Kunihiro Fukushima tarafından, el yazısı tanıma ve diğer desen tanıma sorunları için kullanılan hiyerarşik ve çok katmanlı yapay sinir ağı olan Neocognitron önerilmiştir. Önerilen tasarımda bilgisayarın öğrenme işlemi, görsel örüntüler kullanılarak yapılmıştır(Fukushima, 1988). Juyang Weng ve arkadaşları 1992 yılında, karma sahnelerden otomatik olarak 3 boyutlu nesne tanıma işlemi gerçekleştiren Cresceptron yöntemini yayımladı (Weng, Cohan, Herniou, 1992). 1995 yılında Cortes ve Vapnik, benzer verilere sahip iki grubun sınıflandırılması için destek vektör ağlarını geliştirmişlerdir (Cortes, Vapnik, 1995).

1997'de Hochreiter ve Schmidhuber tarafından LSTM (Uzun Kısa Süreli Hafıza) uzun vadeli bağımlılık problemlerinin çözümü için tekrarlayan bir sinir ağı önerilmiştir (Hochreiter, Schmidhuber, 1997).

2000'li yılların ortalarında, Hinton ve Salakhutdinov'un bir çalışmasının sonrasında “Derin Öğrenme” popülerlik kazanmaya başlamıştır. Bununla beraber çok katmanlı bir sinir ağının, bir kerede bir katmanının nasıl önceden eğitebileceği gösterilmiştir. (Hinton, Salakhutdinov, 2016). 2012 yılında Google'ın araştırma ekibi tarafından, 16000 işlemciden ve bir milyardan fazla bağlantıdan oluşan yapay desen tanıma algoritmalarının performansı, insan düzeyine ulaşmıştır (Nytimes, 2012). 2014 yılında Facebook, fotoğraflarda kullanıcılarını otomatik olarak etiketlemek için DeepFace adlı derin öğrenme teknolojisini kullanmıştır. Bu etiketleme için derin öğrenme algoritmaları, 120 milyon parametreyi hCNNba katarak yüz tanıma görevlerini gerçekleştirmiştir. (Taigman, Yang, Ranzato, Wolf, 2014). Google'nın DeepMind algoritması olan AlphaGo 2016 yılında karmaşık tahta oyunu Go sanatında, milyonlarca simülasyon

kullanarak uzmanlaşmış ve profesyonel bir oyuncu olan Lee Sedol'u turnuvada 4-1 yenmiştir (Guardian, 2016).

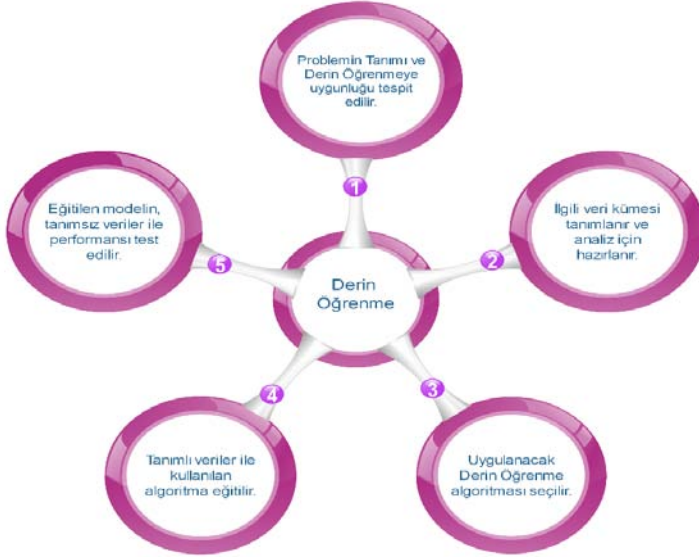
1940'li yıllarda başlayan yapay zekâ teknolojisi, 1980'li yıllarının başında yerini bir alt dalı olan makine öğrenmesine bırakmıştır.2010 yılının başında ise makine öğrenmesinin eksiklikleri derin öğrenme ile giderilmiştir. Yapay zekâ ile başlayan öğrenme ve yorumlama algoritmalarının tarihsel değişimi Şekil 1'de verilmiştir.



Şekil 1. Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenmenin Kronolojisi

2.3. Derin Öğrenme Süreci

Geleneksel makine öğrenme algoritmaları doğrusal yapıdadır. Fakat derin öğrenme algoritmalarında uygulanacak alanın karmaşıklığına göre değişen bir hiyerarşi modeli vardır. Derin öğrenme süreci, sonuçtaki başarı oranı belirli bir seviyeye ulaşıncaya kadar tekrar eder. Bu süreçte verilerin geçmesi gereken genel adımlar Şekil2'de gösterilmektedir.



Şekil 2. Derin Öğrenme Süreçleri

2.4.Derin Öğrenme Mimarileri

2.4.1. Konvolüsyonel Sinir Ağları (Convolutional Neural Network (CNN))

İnsanlar bir görüntüye baktığında nesnelere, nesnelere renklerini ve şekillerini, aynı tipteki nesnelere sayısını, duruş biçimleri gibi özelliklerini rahatça söyleyebilmektedirler. Aynı görüntüyü bilgisayar ise, bir sayı matrisi olarak görmektedir. Konvolüsyonel sinir ağları, görüntüyü birçok gizli katmandan geçirerek kullanıcıya “Yeşil çimlerin üzerinde koştuğu biri büyük diğeri yavru iki kedi” gibi basit cümlelerle görüntüde bulunan nesnelere ve özelliklerini aktarılabilir.

Konvolüsyonel sinir ağları ile görüntü sınıflandırma, nesne tanımlama, görüntü segmentasyonu gibi işlemler başarılı bir şekilde yapılmaktadır. İnsanların görme sistemini örnek alan Konvolüsyonel sinir ağları ile yapay sistemlerde, nesnelere algılanması, tanımlanması ve sınıflandırılması amaçlanmıştır(Le, vd. 2009; Behnke, 2003; LeCun, vd., 1990; LeCun vd., 1998; Bengio, vd., 2013; LeCun, vd., 2015; Huang, vd., 2006; Jarrett, vd.,

2009; Rantazo, vd., 2007). Konvolüsyonel sinir ağları Şekil 3'de görüldüğü gibi çok sayıda konvolüsyon, örnekleme ve ileri besleme katmanına sahiptir (Hu, Huang, Wei, Zhang, Li, 2015).

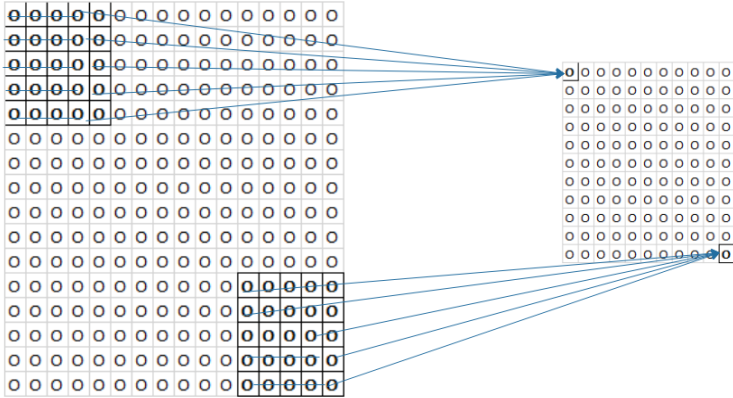


Şekil 3. Konvolüsyonel sinir ağı katmanları.

Konvolüsyonel sinir ağları çok sayıda gizli katman kullanılarak görüntülerdeki farklı özelliklerin algılanmasını sağlamaktadır. Bundan dolayı görüntülerdeki nesnelerin hangi nitelikte olduğu (insan, hayvan, ağaç vb.) kolay bir şekilde ayırt edilebilmektedir.

Birçok gizli alt katmandan oluşan konvolüsyonel sinir ağlarındaki, ilk katman konvolüsyonel katmandır. Bu katman genellikle Şekil 4'de verilen örnekte görüldüğü gibi 16x16x3 gibi piksel değerlerin oluşan bir sayı dizisidir. Filtreler (5x5x3) yardımı ile görüntü dizisinin

sol üst köşesinden başlanılarak, filtrelerdeki değerler ile görüntülerdeki değerler çarpılarak tek bir sonuç elde edilir. Bu işlem soldan sağa doğru, yukarıdan aşağı doğru yapılır. 16x16x3 ilk katmandan 11x11x1 özellik haritası olarak adlandırılan bir sayı dizisi elde edilir.



Şekil 4. Konvolüsyonel katmanı ile özellik haritasının çıkartılması


Daha sonra nesnelerin tanımlanması için görüntüye eğrilik filtresi uygulayarak, görüntüde eğriliklerin olup olmadığı bulunmaktadır. Eğrilik filtresi sayısal değerler içeren bir dizidir. Filtre yine sağdan sola, yukarıdan aşağıya doğru piksel tabanlı hareket ettirilir. Buradan elde edilen değerler ile görüntüdeki nesneler yavaş yavaş tanımlanmaya başlamaktadır. Eğrilik filtresi yerine üçgen filtreler veya diğer tanımlı filtreler de uygulanabilir.

Konvolüsyonel sinir ağlarının eğitim sürecinde sinir ağına etiketlenmiş binlerce resim verilerek, görüntünün ne olduğu öğretilir. Konvolüsyonel sinir ağlarında test verileri ile derin öğrenme algoritmasının öğrenme işleminde ne kadar başarılı olduğu test edilmektedir. Konvolüsyonel sinir ağları tıbbi taramalardan sağlık hastalıklarının teşhisinde, görüntü, ses, metin ve video işlemede, resimlerin başlıklandırılmasında (CNN+RNN), resimlerdeki nesnelere tanımlamada oldukça yaygın ve başarılı şekilde kullanılmaktadır.

2.4.2. Tekrarlayan Sinir Ağları (Recurrent Neural Network)


Tekrarlayan sinir ağları (RNN) ardışık bilgileri kullanan, gizli katman çıkışını tekrar aynı katmana giriş olarak gönderebilen bir derin öğrenme algoritmasıdır.

Şekil 5'de, RNN algoritmasının temel çalışma mantığı görülmektedir. Burada; X ağıın girdi değerini, h ağıın çıktı değerini, A ise gizli katmanı temsil etmektedir. Burada gizli katmandan çıkan değer yine gizli katmana gelerek, bir çeşit kendi kendini çağırın fonksiyon görevi görmektedir.



Şekil 5.RNN algoritmasının çalışması (elitcenkalp, 2018)

Son yıllarda RNN algoritmasının yaygın olarak kullanılmasının başlıca nedeni, bir döngü oluşturabilmesi ve sıralı bir şekilde gelişen olayların birbiriyle anlamlandırılabilmesidir. RNN algoritmasının Şekil 6'da verildiği gibi 5 farklı çalışma yöntemi bilinmektedir.



Şekil 6. RNN algoritmasının çalışma biçimleri

- a) Tekli giriş - tekli çıkış,
- b) Tekli giriş-çoklu çıkış,
- c) Çoklu giriş-tekli çıkış,
- d) Çoklu sıralı giriş-çoklu sıralı çıkış,
- e) Çoklu senkronize giriş- çoklu senkronize çıkış

RNN algoritması;

- Çeviri yapılırken (Bahdanau, Cho, Bengio, 2014),
- Resimler için altyazı oluştururken (Karpathy, Fei-Fei, 2015)
- Kredi kartı sahtekârlığını tespit ederken (Ando, Gomi, Tanaka, 2016),
- Gürültülü verilerden gürültüsüz verilerin elde edilmesinde (Giles, Lawrence, Tsoi, 2001),
- Büyük metinlerin özetlerinin çıkarılmasında (Rush, Chopra, Weston, 2015),
- El yazısı tanımda (Shkarupa, Mencis, Sabatelli, 2016),
- Konuşma tanımda (Mikolov, vd., 2010; Graves, Jaitly, 2014),
- Otomatik wikipedia makalelerinin yazılmasında kullanılabilir (Dang, Ignat, 2017).

Ayrıca bir algoritmanın yetersiz kaldığı durumlarda ise iki yöntemin hibrit kullanılması da mümkün olmaktadır. Bu duruma Google Translate (CNN+RNN), sürücüsüz otomobillerde (CNN+RNN) birden fazla yöntemin kullanılması örnek verilebilir.


2.4.3. Uzun Kısa Süreli Hafıza Ağları (Long-Short Term Memory)

Derin öğrenme algoritmaları, görüntüler üzerinden elde edilen bilgiler ile birçok sınıflandırma ve tahmin işlemleri gerçekleştirilebilmektedir. Örneğin, bir videoda bir oda içerisine sırasıyla çocuklar girip, bir masa etrafında oturup ve resim yapıyor olsunlar, daha sonra odaya girecek bir çocuğun masaya oturup resim yapacağını RNN ile tahmin etmek çok zor değildir. Ama videoda belli süre içinde başka olaylar gerçekleşir ve odaya yeni bir çocuk gelirse RNN bu çocuğun masaya oturup resim yapacağını tahmin edemeyebilir. Çünkü aradan geçen zaman ve zaman içerisinde başka olayların gerçekleşmesi RNN için tahmin işini zorlaştırmıştır. Bu tür problemlerin çözümü için RNN'nin gelişmiş bir türü olan Uzun Kısa Süreli Hafıza Ağları (LSTM) 1997 yılında Hochreiter ve Schmidhuber tarafından literatüre kazandırılmıştır (Hochreiter, Schmidhuber, 1997).

LSTM hücreleri RNN hücrelerine benzer yapıda bulunmaktadır. Ancak bu öğrenme algoritmasında

bulunan ve Şekil 7'de gösterilengirdi, çıktı, sigmoid (veya tanjant) ve unut kapıları RNN algoritmasında bulunmamaktadır.

- Girdi kapısı girdi verisini aktarmak için kullanılır.
- Çıktı kapısı çıktı verisini aktarmak için kullanılır.
- Unut kapısı önceki hücreden gelen verinin ne kadarının unutulması gerektiğine karar vermek için kullanılır.
- Sigmoid kapısı çıktının sigmoid fonksiyonuna verilip son halinin alınması için kullanılır.



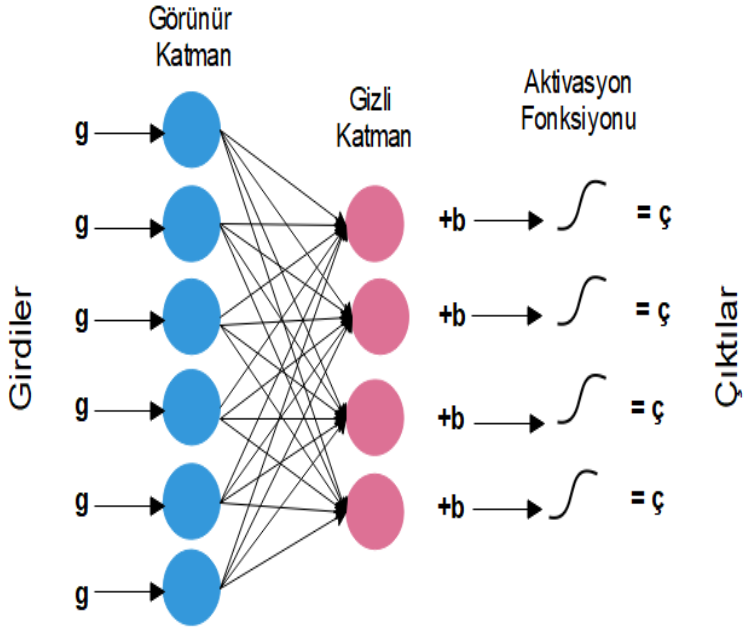
Şekil 7. LSTM algoritmasının yapısı(Colah, 2015)

Literatürde LSTM ile yapılmış bir çokuygulama mevcuttur. Bunlardan bazıları;

- Resimlerden otomatik başlık çıkarma (Machinelearningmastery, 2012),
- Sessiz videolara otomatik ses ekleme (Machinelearningmastery, 2012),
- Protein homolojisinin algılanması (Hochreiter, Heusel, Obermayer, 2007),
- İlişkili metinlerden kelime üretme (Machinelearningmastery, 2012),
- Düzensiz dillerde öğrenme (Schmidhuber, Gers, Eck, 2002),
- Çevrimdışı el yazısının tespit edilmesidir (Graves, Schmidhuber, 2009).

2.4.4. Sınırlı Boltzman Makineleri (Restricted Boltzmann Machines)

Sınırlı Boltzman Makineleri (RBM) veri setindeki olasılık dağılımlarını öğrenebilen iki katmanlı rastlantısal bir yapay sinir ağlarıdır. Şekil 8'de verildiği gibi RBM'nin ilk katmanı görünür veya girdi katmanı olarak adlandırılır. İkinci katmanı ise gizli katmandır. Gizli katmandaki her düğüm derin öğrenme hesaplamalarının gerçekleştiği yerlerdir. Görünür düğümlere RBM ile öğrenilecek olan veri kümesindeki bir özellik alınır. Örneğin, görüntü kümesinden bilgiler alınırken görünür katmandaki her bir düğüme bir pikselin renk değeri atanır. Görünür katmandaki bütün düğümlerdeki bilgiler, gizli katmandaki bir düğüme iletilerek hesaplamalardan geçirilir. Aynı işlemler gizli katmandaki diğer düğümler içinde yapılır. Düğümlerin çıktısını elde etmek için bir aktivasyon algoritmasından geçirilir.



Şekil 8. RBM algoritmasını işlem süreci

RBM'lerde istenirse birden fazla gizli katman kullanılabilir.

Sınırlı Boltzmann Makinesinin özellikleri:


- Öğrenme algoritması olarak Zıt İraksama yöntemini kullanmaktadır.
- Görünür düğüm, dışarıdan girdi alabilen veya dışarıya çıktı verebilen düğümdür.
- Gizli düğüm dışarı ile irtibatı olmayan düğümdür.
- Girdi ve çıktı düğümlerinin sayısında bir sınır yoktur, girdi ve çıktı düğümlerinin sayısı birbirlerine eşit olmak zorunda değildir.
- Görünür düğümler kendi aralarında bağ yapmamaktadır, ancak saklı düğümler ile çift yönlü bağ yapmaktadır(Pekmezci, 2012).

RBM'ler, kümeleme (Larochelle, Bengio, 2008), özellik öğrenimi (Coates, Ng, Lee, 2011), boyut indirgeme (Hinton, Salakhutdinov, 2006), işbirlikçi filtreleme (Salakhutdinov, Mnih, Hinton, 2007) ve konu modelleme (Hinton, Salakhutdinov, 2009) gibi çeşitli uygulamalarda kullanılan derin öğrenme algoritmasıdır.

2.4.5. Derin Oto-Kodlayıcılar

1980'li yıllarda Hinton ve PDP grup tarafından literatüre kazandırılan Derin Oto kodlayıcılar, girdi olarak aldıkları veriyi çıktı olarak üretmeye çalışan, birden fazla katmandan oluşan derin öğrenme algoritmasıdır (Baldi, 2012). Derin Oto kodlayıcılar da amaç, verilen girdiye en çok benzeyen çıktıyı üretecek olan veriye ait önemli yapısal bilgileri içeren fonksiyonun bulunmasıdır.

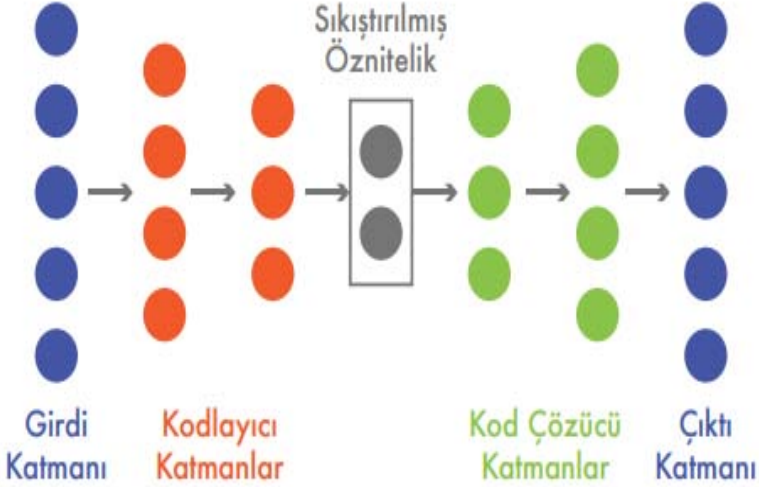
Derin Oto kodlayıcılar Şekil 9'da verildiği gibi girdi, gizli ve çıktı olmak üzere üç katmandan oluşmaktadır (Kaynar, Görmez, Işık, 2016). Girdi katmanındaki verinin aynısına yakın bir çıktı amaçlandığı için girdi ve çıktı katmandaki nöron sayıları birbirine eşittir. Algoritmanın performansını etkileyen gizli katmandaki nöron sayısı istenildiği kadar tanımlanabilir. Örnek olarak 32x32 piksellik bir el yazısı görüntüsünün benzerini üretecek bir derin oto kodlayıcı da girdi ve çıktı katmanında 1024 (32x32) adet nöron varsa gizli katmanda da 512 tane nöron bulunabilir.



Şekil 9. Derin oto kodlayıcı algoritma şeması
(Towardsdatascience, 2017)

Gizli katmandaki ara katmanlar önceki katmandan veriyi alıp nöronlardaki aktivasyon fonksiyonlarından (doğrusal veya doğrusal olmayan nöron üzerindeki fonksiyon) geçirip sonraki katmana veriyi ileten yapılardır. Şekil 10'da iki katmanlı basit bir derin oto kodlayıcı gösterilmiştir. Ara katmanlarda bulunan nöronlar aktivasyon fonksiyonları ile veri üzerinde işlemler yapar. Ortada çıkarılan sıkıştırılmış öznitelik katmanı, derin oto kodlayıcıların kullanım amacı olan veriye ait küçük boyutta öznitelikleri temsil eder. Kod çözücü katmanlar sıkıştırılmış öznitelikten girdiye benzer çıktıyı üretmeye çalışır. Çıktı girdinin tamamen aynısı olmayabilir. Girdi ve çıktı arasındaki benzerlik ne kadar fazla ise


algoritmada bulunan fonksiyonun başarılı olduğunu gösterir (Yücer, 2018).



Şekil 10. İki katmanlı derin oto kodlayıcı(Yücer, 2018)

Derin oto kodlayıcı modelindeki çıktı katmanında girdi katmanındaki verinin aynısını elde etmeye çalışmak, bazı sistemler için o verinin ezberlenmesine ve test verisi için kötü sonuçlar elde edilmesine neden olmaktadır. Bu problemi çözmek için üretilen ve Şekil 11’de verilen gürültü giderici (Denoising) oto kodlayıcı modelinde,

girdi katmanındaki veriye gürültüler eklenerek çıktı katmanında gürültüsüz girdi değerleri elde edilmektedir. Böylece sistem eğitim verisinde olmayan farklı örüntülere sahip verileri de öğrenebilmektedir (Kaynar, Aydın, Görmez, 2017).



Şekil 11. Derin oto kodlayıcıda gürültü ekleme modeli
(Towardsdatascience, 2017)

Derin oto kodlayıcılar bir sınıflama işlemi yapamamaktadır. Bu algoritmanın kullanım amacı, N boyutlu bir özellik vektörünü daha küçük bir boyutlu vektöre en az kayıpla düşürmektir. Derin oto kodlayıcılar ses ve görüntü işleme uygulamaların gürültü giderme ve boyut düşürmek amacıyla kullanılan oldukça başarılı sonuçlar veren bir yöntemdir (Kaynar, Arslan, Görmez, Işık, 2018). Bu nedenle, oto kodlayıcılar veri sıkıştırma, öznetelik çıkarma işlemlerinde sıklıkla kullanılmaktadır.

2.5. Derin Öğrenmenin Kullanıldığı Alanlar

Derin öğrenme ile sınıflandırma, tanımlama, tahmin, teşhis ve görüntü ayırma alanlarında çalışmalar yapılabilmektedir. Bu geniş çalışma alanlarından dolayı verinin elde edildiği her alana derin öğrenme yöntemleri uygulanabilmektedir. Derin öğrenme yöntemleri kullanılarak yapılabilecek çalışmalar bu bölümde verilmiştir (Yaronhadad, 2014).

Bilgisayar öngörüsü ve desen tanıma;

- Ünlü kişilerin seslerinin yine kendilerine ait farklı görüntülerle kullanılması,
- Resim ve videolarda renklerin restorasyonu,
- Çözünürlüğü düşük resimlerden anlaşılabilir görüntülerin elde edilmesi,
- Gerçek zamanlı çoklu insan hareketlerinin tahmini,
- Resimlerin içindeki imgeleri metin haline getirme,
- Fotoğraflardaki insanların bakış yönünü değiştirme,

- Videolardaki görüntülerin davranışlarının gerçek zamanlı analizi,
- Fotoğrafların tekrarlanması ile yeni nesnelere oluşturulması,
- Galaksilerin fotoğraflarını oluşturma,
- Resimlerin üzerindeki yazıların bir dilden başka bir dile çevrilmesi,
- Nesli tükenen hayvanların tespiti ve korunması,
- Var olan görüntülerden yeni modellerin elde edilmesi,
- Fotoğraflardaki ve/veya videolardaki metinlerin okunması,
- Güneş enerjisi potansiyelinin tahmin edilmesi.

Bilgisayar oyunları, robotlar ve otonom arabalar;

- Bilgisayar oyunlarının bilgisayarlar tarafından oynanması,
- Kendi kendini kullanabilen araçlar,
- Robotlar,
- Bilgisayar oyununun kuralını otomatik olarak öğrenen bilgisayarlar.

Ses;

- Sizinle konuşan sistemler (Siri, Alexa),
- Beste yapan bilgisayarlar,
- Video görüntülerinden dudak okuyan bilgisayarlar.

Sanat;

- Ünlü ressamların resimlerindeki stillerinin başka resimlere uyarlanması,
- Matematik sayfalarının, bilgisayar kod parçalarının, wikipedia makalelerinin hatta Shakespeare tarzında roman yazan bilgisayarlar,
- El yazılarının anlamlı bir şekilde bilgisayar metinlerine çevrilmesi.

Bilgisayar tahminleri;

- Seçim sonuçlarının tahmini,
- Deprem tahminleri.

3. TÜRKİYE'DE DERİN ÖĞRENME UYGULAMALARI

3.1. Mühendislik Alanındaki Uygulamalar

Cengil ve Çınar'ın 2016 yılında yaptıkları çalışmalarında, konvolüsyonel sinir ağlarını (CNN) kullanan yazarlar, CIFAR-100 kütüphanesinden 8 farklı görüntünün (otobüs, traktör, tren, dinazor, fil, kelebek, sandalye, televizyon) 800 adetini eğitim ve 40 adetini de test işlemleri için kullanmışlardır. Çalışmada yazarlar, CNN'yi girdi olarak kabul eden Caffe kaynak yazılımı ile görüntüleri başarı ile birbirinden ayırmışlardır (Cengil, Çınar, 2016).

Demir ve Ünal 2017 yılında yaptıkları çalışmalarında, resimlerin belirli bir bölgesinden bir kısmını çıkartarak, derin öğrenme ile bu boşluğu gerçekçi bir yama ile doldurabilecek bir sinir ağı geliştirmişlerdir. Yazarlar çalışmalarında iç boyama yapmak için gerçekleştirilen bir otomatik kodlayıcının, eğitimi için yeni bir çözüm yolu önererek, ÇÜA (Çekişmeli Üretici Ağlar) mimarisine bir alternatif sunmuşlardır. Çalışmada Google Street View

setinden alınan 6 adet örnek resim için otomatik kodlayıcı olarak Euclid uzaklık metriği, VGG16 otomatik kodlayıcısı ve ÇÜA kullanılmışlardır. Euclid uzaklığı ile eğitim yapıldığında elde edilen resimlerdeki bulanıklık ve detayların eksikliği kolayca gözlemlenebildiğini, ÇÜA ile elde edilen sonuçlarda resimlerde beklenmeyen detaylar üretildiği ve içeriği bulmakta zorlanıldığı, VGG16 ile elde edilen çıktılara bakıldığında diğerlerine göre detayları daha iyi bulduğu görülebildiğini ifade etmişlerdir (Demir, Ünal, 2017).

Turhan ve Bilge'nin 2017 yılında gerçekleştirdikleri çalışmalarında, 27 kişinin el yazısından alınan ve 5 harf içeren 5944 görüntüyü GAN modeli ile tanımlamaya çalışmışlardır. Yazarlar makalelerinde, 4 basamaktan oluşan yeni bir GAN modeli önermişlerdir. Önerilen basamaklı modelin her basamağında farklı sayılardan (2,3,4,5) oluşan kelimelerle derin öğrenme ağını eğitilmişlerdir. Yaptıkları el yazısı tanıma çalışması ile yazarlar orijinal modelden çok daha hızlı bir model oluşturduklarını ifade etmişlerdir (Turhan, Bilge, 2017).

Karasoy ve Ballı tarafından 2017 yılında yapılan bir çalışmada, cep telefonlarına gelen mesajların normal veya spam mesaj olarak değerlendirilmesi için bir derin öğrenme metodu sunmuşlardır. 3146 spam ve 2166 normal mesajdan oluşan veri setindeki mesaj bilgilerini kelime köklerine ayırmışlardır. Yazarlar, Google tarafından piyasaya sürülen Word2Vec ile kelimelerin özelliklerini çıkardıktan sonra, Random Forest ile sınıflandırma işlemini gerçekleştirerek mesajın normal veya spam mesaj olarak değerlendirilmesini sağladıklarını ifade etmişlerdir (Karasoy, Ballı, 2017).

Çelik ve Arıca 2017 yılında gerçekleştirdikleri çalışmaları ile yüz imgelerinin önleştirilmesi için 3B model tabanlı algoritma ile derin öğrenme yaklaşımını birlikte kullanan yeni bir metot önermişlerdir. Çalışmada Multi-PIE veri kümesinde bulunan 20.000 imge üç boyutlu yarı önleştirme işlemi için sırasıyla hizalama ve global kontrast normalleştirme aşamalarında geçirildikten sonra, 10000 tanesi eğitim, 5000 tanesi doğrulama ve 5000 tanesi de test işlemi için kullanılmıştır. Yazarlar

önerdikleri yeni yöntem ile daha önceden yapılan başka bir çalışmanın sonuçlarını karşılaştırmışlar ve özellikle imgelerin ağız bölgesinde kayda değer bir ifade değişikliğine gidildiğini ifade etmişlerdir (Çelik, Arıca, 2017).

Karahan ve Akgül 2016 yılında yaptıkları çalışmalarında, 52000 adet negatif ve 16000 adet pozitif göz imgesi kullanmışlardır. Caffe kütüphanesi ile verilerin %80'i eğitim için kullanılmıştır. Yazarlar geliştirdikleri modeli Haar algoritması, CACD ve FDDB veri kümelerinden elde edilen resimlerle test etmişlerdir. Haar algoritması CACD veri kümesinde %86 başarımlık sağlarken, yazarların geliştirdikleri metod %91 başarımlık sağlamaktadır. Ama Haar algoritması FDDB veri kümesinde %85 başarımlık sağlarken geliştirilen derin öğrenme metodu %81 başarımlık sağlamıştır. Yazarlar, Haar ve geliştirdikleri metodun özellikle ağız ve burundan yanlış tespit yaptığını ifade etmişlerdir (Karahan, Akgül, 2016).

Koyun ve Afşin'in 2017 yılında yaptıkları çalışmalarında, 2160000 adet karakteri konvolüsyonel sinir ağının eğitilmesinde kullanmışlar. Yazarlar Karakter Tanıma işlemi için geliştirdikleri derin öğrenme metodunu, Matlab ortamında gömülü olarak gelen OCR aracı ile karşılaştırdıklarında, kendi geliştirdikleri metodun daha iyi sonuç verdiğini ifade etmektedirler (Koyun, Afşin, 2017).

Çalık ve arkadaşlarının 2017 yılında yaptıkları çalışmalarında, SUSIG-Visual veri kümesinden 200 imza örneği üzerinde çalışmışlardır. Çalışmada, Matlab programı üzerinde 6 katmanlı Konvolüsyonel Sinir Ağı oluşturulmuştur. Yazarlar oluşturdukları derin öğrenme metodunun en iyi %90'lık ve en kötü %80'lik bir başarı elde ettiğini ifade etmektedirler (Çalık, Kurban, Yılmaz, Ata, Yıldırım, 2017).

Aydın ve Yüksel'in 2017'de yaptıkları çalışmada, Matlab için tasarlanmış olan Matconvnet Konvolüsyonel Sinir ağını kullanmışlardır. Yazarlar, Sinir Ağını 200 adet veri

ile eğitmişler, 22 adet veri ile de doğrulama işlemini gerçekleştirmişler. Çalışmada, toprağa gömülü bir cisim tespit edilmeye çalışılmış ve %100 başarımla sağlandığı ifade edilmiştir (Aydın, Yüksel, 2017).

Uçar ve Bingöl'ün 2018 yılında gerçekleştirdikleri makalelerinde, derin öğrenmenin bir çeşidi olan ve özellikle görüntü işleme uygulamalarında çok kullanılan DKSA (Derin Konvolüsyonel Sinir Ağları)'ların katmanları kısaca tanıtmış ve mimarileri hakkında bilgi vermişlerdir. DKSA'ları uygulamak için Caffé programını kullanan yazarlar, uygulamaları gömülü olarak Nvidia Jetson TK1/TX1 geliştirme kartları ve Nvidia GTX550/GTX960 ekran kartlarına sahip iki bilgisayar üzerinde gerçekleştirmişlerdir. Kartlar ve bilgisayar üzerinde, LeNet ağı ile el yazısı rakamları tanıma işlemi yaptıklarını ve başarımlarını, hız ve doğruluk açısından yaptıkları değerlendirmede, GPU'ların CPU'lara göre doğruluk oranlarının yakın olmasına karşın daha hızlı olduğunu ifade etmişlerdir (Uçar, Bingöl, 2018).

Ergün ve arkadaşlarının 2017 yılında yaptığı çalışmalarında, videolardaki renk ve hareket bilgisinden faydalanılarak, video aktivite öğrenme ve sınıflandırmayı amaçlamışlardır. Yazarlar veri seti olarak UCF-101 veri setinde bulunan, Spor, İnsan-Alet Etkileşimi, Müzik Aleti Çalma, Vücut Hareketleri ve İnsan-İnsan Etkileşimi olarak adlandırılan 5 farklı aktivite kategorisinden 101 aktivite sınıfına ait ortalama 7.21 saniye uzunluğuna sahip 13320 video klibini kullanmışlardır. Her bir aktivite kategorisi için farklı yüzdelerle eğitim ve test video klip sayısı kullanılmasına rağmen ortalama %71 video klip sayısı eğitim için %29 video klip sayısı da test için kullanılmış. Derin öğrenme sonucunda başarı oranı yaklaşık %70'lerde olduğu ifade edilmektedir (Ergün, Gurkan, Kaplan, Günsel, 2017).

2017 yılında Kaya ve Alatan tarafından gerçekleştirilen çalışmada, nesnelerin etrafındaki bağlam bilgisini kullanarak nesne tespit sonuçlarının iyileştirilmesi amaçlanmıştır. Yazarların önerdiği metotta, iki ilgi bölgesi havuzlama katmanı bulunmaktadır. Birincisi

orijinal hızlı B-CNN ile aynı,yeni eklenen ikinci katman da bağlam öznitelik haritalarından bağlam kutularıyla belirtilen bölgeleri havuzlamaktadır. Çalışmada dört farklı eğitim örneği kullanılmış ve elde edilen başarımlar oranları tablo olarak verilmiştir (Can, Alatan, 2017).

Tümen ve arkadaşlarının 2017 yılında yaptıkları çalışmalarında, çok sınıflı bir yüz ifadesi tespit sistemi için CNN tabanlı bir yaklaşım önerilmiştir. Yazarlar, CNN modelini eğitmek ve doğrulamak için 35887 adet yüz imgesinin olduğu 7 adet yüz (Kızgın, Tiksinme, Korkma, Mutluluk, Üzüntü, Şaşkınlık, Doğal) ifadesini içeren FER2013 veri setini kullanılmışlardır. Derin öğrenme metodunun eğitimi için verilerin %80'i, doğrulama için %10'u ve test için %10'u kullanılmış olup doğrulama verilerinde %58,5 ve test verilerinde %57,1 başarımlar oranı sağlandığı ifade edilmiştir (Tümen, Söylemez, Ergen, 2017).

2017 yılında Gündoğdu ve arkadaşları tarafından yapılan çalışmalarında, görsel olarak deniz araçlarının tanınma oranını artırmak için, derin mesafe metrik öğrenme ve

sınıflandırma maliyetini gözeten bir yöntem önermişlerdir. Yazarlar örnekleme yöntemiyle mesafe metriğini öğrenen bir derin konvolüsyonel sinir ağı önerdikleri modelde, yaklaşık 4000 çeşit geminin kimliğini %60'ın üzerinde bir başarımla bulabildiklerini ifade etmişlerdir (Gündoğdu, Solmaz, Koc, Yucesoy, Alatan, 2017).

Akbulut ve arkadaşlarının 2017 yılında yaptıkları çalışmalarında, derin öğrenme ile yüz imgelerinden cinsiyet tanıma işlemi için Yerel Alıcı Alanlar-Aşırı Öğrenme Makinesini (YAA-AÖM) ve Konvolüsyonel sinir ağlarını kullanmışlardır. Deneysel çalışmada yaş ve yüz sınıflandırması için Adience veri tabanındaki 11408 adet imge kullanılmıştır. Yazarlar CNN ile %98,13 ve YAA-AÖM ile de %80 oranında başarımla elde ettiklerini ifade etmişlerdir (Akbulut, Sengür, Ekici, 2017).

2016 yılında Salman ve Yüksel'in yaptığı çalışmada, hiperspektral görüntüler için yeni bir derin öğrenme yapısı önerilmiş ve aynı veri üzerinde çalışılmış destek vektör makinaları ve K-en yakın komşuluk

algoritmalarıyla karşılaştırılmıştır. Yazarlar hiperspektral görüntülerde derin öğrenme yöntemiyle birlikte öznelik çıkarımı ve sınıflandırıcıdan oluşan sınıflandırma basamaklarının tek adıma indirildiğini ifade etmişlerdir. Önerilen sinir ağı modelinde Pavia Üniversitesine ait 103 farklı bantta, 0.43-0.86 μm aralığında değişen dalga boylarında, 9 sınıfa ait verilerden 200 tanesi eğitim ve 50 tanesine test işlemi için kullanılmıştır. Önerilen yeni yaklaşımda %83,75'lik başarı oranının elde edildiği ifade edilmiştir (Salman, Yüksel, 2016).

2017 yılında Çevikalp ve arkadaşları tarafından yapılan çalışmada, imge erişiminde kullanılmak üzere 60 milyon parametre ve 650 bin nöronlu bir ağ yapısı ile öznelik çıkarımı gerçekleştirilmiştir. Önerilen metod için UC Merced Land Use veri tabanındaki 21 farklı sınıfa ait büyük boyutlu imgelerdeki kentsel alanlar seçilmiş ve verilerin %50'si eğitim, %50'si de test işlemi için kullanılmıştır. Yazarlar imge erişimi uygulamalarındaki imge betimlemesinde CNN özneliklerinin kullanımının, hashing yönteminden bağımsız olarak Fisher vektörleri

kullanımına göre daha avantajlı olduğunu ifade etmektedirler (Salman, Yüksel, 2016).

2017 yılında Kaynar ve arkadaşları tarafından yapılan çalışmada, bilgi güvenliği politikalarının vazgeçilmez öğelerinden biri olan saldırı tespiti için derin oto kodlayıcı tabanlı bir derin öğrenme makinesi önerilmiştir. Yazarlar çalışmalarında KddCup99 veri setinden smurf, neptune ve pod gibi türlerinde bulunduğu 22 saldırı ve normal kayıtlardan oluşan 494021 adet verinin %75'ini eğitim ve %25'ini de test için kullanmışlardır. Önerdikleri derin öğrenme metodunda 2 adet derin oto kodlayıcı kullanan yazarlar %99.42 oranında sınıflandırma başarımı sağladıklarını ifade etmişlerdir (Kaynar, Yüksek, Görmez, Işık, 2017).

Keçeli ve arkadaşları tarafından 2017 yılında yapılan çalışmalarında, derin öğrenme ile derinlik videoları kullanılarak tek kişilik hareketleri tanımaya yönelik bir yaklaşım amaçlamışlardır. Yazarlar önerdikleri yöntemi, MSRAction-3D ve UTKinect-Action3D veri kümeleri

üzerinde test etmişlerdir. Yöntem MSRAAction-3D ile test edilirken aktörlerin yarısına ait örnekler eğitim diğer yarısı test aşamasında kullanılmıştır. UTKinect-Action3D veri kümesi üzerinde gerçekleştirilen testlerde ise tek aktöre ait örnekleme dışarda bırakma yöntemi kullanılmıştır. Bu test yönteminde bir aktöre ait hareketler test için kullanılırken, diğer aktörlere ait hareketler eğitim aşamasında kullanılmıştır. Yazarların literatüre katmak istedikleri yeni yöntem, var olan yöntemlerle karşılaştırılmış ve başarı oranı diğer yöntemlerle hemen hemen aynı olduğu görüşüne varılmıştır (Keçeli, Kaya, Can, 2017).

Aslan ve çalışma arkadaşları tarafından 2017 yılında yapılan çalışmalarında, duvara sabitlenmiş kamerası ve hareket sensörü olan gömülü bir bilgisayar ile üzerinde kamera, derinlik sensörü ve mikrofon bulunan gezgin robot kullanılarak gerçekleştirilen yüz tanıma sistemi gerçekleştirilmiştir. Yazarlar önerdikleri sistemde DeepFace yönteminin OpenFace kütüphanesini kullanmışlar ve sistemin eğitimi için 20 kişiden toplanan

1200 fotoğrafı, test için 10 kişiden toplanan 1226 adet fotoğrafı kullanmışlardır. Başarım oranlarını 2 farklı platforma göre inceleyen yazarlar, “aktivasyon kipi ve takip davranışının etkisinde” ve “mesafe ve platform etkisinde”, sabitlenmiş kamera ile ortalama %70’lik, hareketli kamera ile ortalama %93’lük başarım elde ettiklerini ifade etmişlerdir (Aslan, Bayram, İnce, 2017).

2016 yılında Aydemir ve Bilgin tarafından yapılan çalışmada, hiperspektral görüntülerdeki bazı problemlere karşı yarı-güdümlü öğrenme, destek vektör makineleri ve derin öğrenme ile hiperspektral bir görüntü sınıflandırıcı önermişlerdir. Deneysel çalışmada 610 satır ve 340 sütundan ve 103 spektral banttan oluşan Pavia üniversitesinin hiperspektral sahnesi kullanılmıştır. Yazarlar çalışmanın sonunda, %80.78 oranında bir başarım elde ettiklerini ifade etmişlerdir (Aydemir, Bilgin, 2016).

Büber ve Şahingöz tarafından 2017 yılında yapılan çalışmada, derin öğrenme yaklaşımı kullanılarak görüntü işleme yapılması ve rakamsal karakterlerin tanınması

amaçlanmıştır. Uygulamada 250 farklı kişiden alınan el yazısı resimlerinden oluşan MNIST veri setinden 50000 veri eğitim, 10000 veri de test işlemi için kullanılmıştır. Çalışmada ayrıca derin öğrenme yönteminin kullanılabilmesi için algoritma çalışmadan önce belirlenmesi gereken hiperparametrelerin performans üzerindeki etkileri incelenmiştir. Yazarlar en iyi duruma ilişkin gerçekleştirilen test adımıda kullanılmak üzere belirlenen sayısal hiper parametrelerin başarı oranını %94.75 olarak ifade etmişlerdir (Büber, Şahingöz, 2017).

2017 yılında Aker ve arkadaşları tarafından gerçekleştirilen çalışmada, derin öğrenme metotlarının içerik tabanlı marka erişimi problemleri için uygulanmasıdır. Uygulamada METU Trademark Dataset'i kullanan yazarlar, CNN modellerini küresel tanımlayıcılar olarak doğrudan kullanmanın geleneksel metotlara göre daha başarılı olduğunu ifade etmişlerdir (Aker, Tursun, Kalkan, 2017).

Kılıç ve Akgül tarafından 2018 yılındaki çalışması, deniz araçlarının radar görüntülerinden doğrudan veya uydu görüntüleri kullanılarak girdi görüntüler arasındaki benzerlik metriği ile konumu tahmin eden bir yöntemdir. Uygulamada SPx Cambridge Pixel Radar Simulator uygulaması ile Marmara bölgesinden elde edilen toplamda 46100 radar görüntüsü ve buna karşılık Google haritalar servisinden elde edilen aynı sayıda uydu görüntüsü kullanılmıştır. Deneyler sonucunda gözlemlenen başarı sonuçlarının umut verici olduğunu ifade eden yazarlar, bir defaya mahsus olmak üzere yeterli verinin toplanması durumunda GPS bağımlılığını azaltacak bir sonuç elde edilebileceğini de belirtmişlerdir (Kılıç, Akgül, 2018).

2016 yılında Kaynar ve arkadaşları tarafından yapılan çalışmada, spam postalarının otomatik olarak tespit edilmesine yönelik derin öğrenme tabanlı bir yaklaşım sunmuşlardır. Uygulamada 2 farklı veri seti kullanan yazarlar, Türkçe ve İngilizce veri setlerindeki verilerin %75'ini eğitim, %25'ini test amacıyla kullanmışlardır.

Önerilen modelarka arkaya bağlanmış 2 adet derin oto kodlayıcı ile çıkışlarında softmax katmanı içeren bir sınıflayıcıdır. Bu sınıflayıcının%98'lik bir başarı oranına sahip olduğu görülmüştür (Kaynar, Görmez, Işık, 2016).

Koç ve Aptoula tarafından 2017 yılında yapılan çalışmada, n tabanlı hiperspektral bir görüntünün piksellerini sınıflandırmak amaçlanmıştır. Deneylede Pavia üniversitesinin veri tabanından yararlanan yazarlar, birbiriyle ilişkili bileşenleri zıtlıktan bağımsız olarak işleyebilen ve nesnelere birer bütün olarak geometrik ve izgesel niteliklerini betimleyebilen öz-ikili öznelik profillerini ve girdisinden karmaşık öznelik sıradüzenleri oluşturabilen derin konvolüsyonel sinir ağları kullanmışlardır (Koç, Aptoula, 2017).

2016 yılında Beşbımar ve Alatan tarafından yapılan çalışmada, yığın özkodlayıcıların bilgisayarlı görme alanında zorlayıcı ancak çok büyük bir önemi olan görsel nesne takibi için kullanımının araştırılması amaç-

lanmıştır. Deneyler, Görsel Nesne Takibi yarışmasının 25 farklı görüntü dizini üzerinden 10'ar kare alınarak yapılmıştır. Önerdikleri yöntemde lojistik regresyonu kullanan yazarlar, yaptıkları deneyler ve yardımcı veri kümeleri ile öğrenilen nesne gösterimlerinin, görsel nesne takibi konusunda öğrenme aktarımı için kullanışlı olduğunu ifade etmişlerdir (Beşbınar, Alatan, 2016).

Işık ve Artuner tarafından 2016 yılında yapılan çalışmalarında, Yazılım Tabanlı Radyo üzerinden alınan radyo sinyallerinin derin öğrenme sinir ağları ile kimliklendirilmesi amaçlanmıştır. Signal Identification Wiki'de bulunan veri tabanından elde ettikleri görüntüler ile konvolüsyonel bir sinir ağı çalışması yapan yazarlar, toplamda 137 tane görüntünün 82 adetini eğitim, 22 adetini doğrulama ve geri kalan 33 adetini ise test için kullanmışlardır. Caffe platformu ile eğitilen ağın çalıştırılması sonunda %82 oranında bir başarımla sağlandığı ifade edilmiştir (Işık, Artuner, 2016).

2017 yılında Güngör ve çalışma arkadaşları tarafından yapılan çalışmada, öncelikle Türk yemeklerini kapsayan 500 adet görüntüye sahip bir veri tabanı oluşturularak, bunların derin öğrenme ile sınıflandırılması yapılmıştır. Yapılan deneyde 113000 adet görüntü kullanan yazarlar verilerin %80'ini eğitim, %10'unu doğrulama ve %10'unu da test işlemleri için kullanmışlardır. Çalışmada derin öğrenme kütüphanesi olarak TensorFlow kullanılmış ve en fazla %68.2'lik bir başarı oranına ulaşıldığı ifade edilmiştir (Güngör, Baltacı, Erdem, Erdem, 2017).

Bulut ve Yavuz tarafından 2107 yılında yapılan çalışmada, daha önceden karşılaşılmamış zararlı yazılımların çalıştırılmasına gerek kalmadan tespit edilmesi hedeflenmiştir. Yazarlar çalışmada 3229 zararsız ve 1668 adet zararlı mobil yazılım seçmişler ve verilerin %70'ini eğitim, %15'ini doğrulama ve %15'ini de test işlemi için kullanmışlardır. Önerdikleri yöntemde gürültü giderici otomatik kodlayıcı ve çok katmanlı yapay sinir ağı kullanan yazarlar, sınıflandırmada %93.67'lik bir

başarım oranını elde ettiklerini ifade etmişlerdir (Bulut, Yavuz, 2017).

Gündüz ve arkadaşlarının 2017 yılında yaptığı çalışmalarında, Borsa İstanbul'da en çok işlem gören hisse senetlerinden 3 tanesinde günlük değişim yönlerini tahmin etmeye çalışmışlardır. Yazarlar veri kümesi olarak 3 hisse senedinin 5 yıllık (Ocak 2011-Aralık 2015) açılış, kapanış, en yüksek ve en düşük verilerini kullanmışlar. Çalışmada faydalanan Konvolüsyonel Sinir Ağında, 663 işlem günü eğitim verisi olarak, 268 işlem günü de test verisi olarak kullanılmış. Yazarlar çalışmanın sonunda, hisselerin yönünü sırasıyla 0.61, 0.578 ve 0.574 doğruluk oranlarıyla tahmin ettiklerini ve 3 hisse için de en yüksek doğruluk oranına iki çeşit öznitelik kullanılarak ulaştıklarını ifade etmişlerdir (Gündüz, Çataltepe, Yaslan, 2017).

Şeker ve arkadaşlarının 2016 yılında gerçekleştirdikleri çalışmalarında, 5000 fotoğraftan oluşan bir veri seti ile önerdikleri derin öğrenme metodunu eğitmişlerdir.

Yazarlar çalışmalarında, kumaş hatasını tespit etmekten çok kendine özgü bir dokusu olan kumaşların özneliklerini doğru çıkarmayı hedeflediklerini ifade etmektedirler. Eğitim aşamasında 153'ü hatalı olan 1000 örnek veri, test aşamasında ise 60'ı hatasız 100 veri kullanmışlardır. Yazarlar çalışmanın sonucunda önerilen metodun %88 başarı sağladığını belirtmişlerdir (Şeker, Yüksek, 2017).

2017 yılında Razavi ve Yalçın tarafından yapılan çalışmada, akıllı tarım istasyonlarından toplanan görüntülerden bitki tipinin tanınması amaçlanmıştır. Yazarlar iki boyutlu bitki imgelerinden öznelikleri otomatik olarak çıkarabilen bir derin öğrenme yöntemi önermişlerdir. CNN mimarisinin oluşturulmasında TARBİL veri kümesindeki 16 bitki sınıfına ayrılmış 4800 imgeden faydalanılmıştır. Yazarlar 3 farklı derin öğrenme metodunun kullanıldığını, CNN bazlı yaklaşımın, 16 çeşit bitki üzerinde yaklaşık %97.47'lik bir doğrulukla çalıştığını ve diğer yöntemlerle karşılaştırıldığında sınıflandırma doğruluğunun diğer

yöntemlerden daha iyi olduğunu ifade etmektedirler (Razavi, Yalcin, 2017).

Doğan ve Türkoğlu 2018 yılında yaptıkları çalışmalarında, 7628 adet bitki yaprağı görüntüsünü 5 farklı derin öğrenme algoritması ile sınıflandırılması yapılmıştır. YazarlarUCI-Machine Learning Repository veri tabanında bulunan, 32 sınıftan oluşan ve her sınıfta 60 farklı yaprak görüntüsünü tersleme ve yansıma yaparak çoğaltmışlardır. Resimlerin 6101 adetini eğitim, 1527 adetini ise test için kullanmışlardır. 5 farklı derin öğrenme ile gerçekleştirdikleri yaprak sınıflandırmasında sırasıyla AlexNet ile %99,72, ResNet50 ile %99,15, VGG16 ile %99,12, VGG19 ile %98,36 ve GoogleNet ile %97,77 doğruluk oranına ulaştıklarını ifade etmişlerdir (Doğan, Türkoğlu, 2018).

2017 yılında Çıtak ve Genç tarafından yapılan çalışmada, antep fıstığının çitlatma işleminden sonra çitlak olup olmadığının sınıflandırılması yapılmıştır. Uygulamada 2 farklı veri seti kullanan yazarlar, kontrollü ortam veri

setini 1200 adet çeşitli seviyelerde çıtlaak bulunan ve 1200 adet çıtlaak bulunmayan fıstık görüntüsünü farklı oryantasyonlarla dönüşüme tabi tutarak 9000 bine çıkarmışlardır. Kontrolsüz ortam veri setini de, 1.2 milyon görüntü parçacığından oluşturmuşlardır. Uygulamada bölütleme işleminde Theano derin öğrenme alt-yapısını kullanan Keras kütüphanesi kullanılmıştır. Yazarlar geliştirilen yeni yöntem ile %98'lik bir başarıım elde edildiğini ifade etmişlerdir (Çıtak, Genç, 2017).

3.2. Sağlık Alanındaki Uygulamalar

Sarıkaya ve İnce tarafından 2017 yılında yapılan çalışmada, tek kanallı ticari bir beyin-bilgisayar arayüzü cihazıyla insan duygusunu saptamak amaçlanmıştır. Deneyde 10 sağlıklı gönüllüden alınan EEG verileri kullanılmıştır. Uygulamada kullanılan 4193 EEG sinyalinden %70'i eğitim, %15'i doğrulama ve %15'i de test işlemleri için kullanılmıştır. Yazarlar yapay sinir ağlarını temel alan bir sınıflandırıcı kullanılarak komedi, korku ve hüzün duygularını barındıran çoklu ortam

türlerinde ortalama %87'lik bir başarıml ile sınıflandırıldığını ifade etmişlerdir (Sarıkaya, İnce, 2017).

Yalçın ve Cilasun tarafından 2016 yılında yapılan çalışmalarda, tekerlekli sandalye kullanan felçli hastalarda, aracın kontrolünün hastaya bırakılmasında meydana gelebilecek riskli durumlara çözüm bulma yönünde bir çalışma gerçekleştirmişlerdir. Aynı seyir rotasını kullanan hastalar için çevresel görüntülerden elde edilen bilgilere göre, otomatik olarak yön belirleyebilen bir algoritma önerilmiştir. Yazarlar, çalışmalarında veri seti olarak Avusturalya'nın St. Lucia, Queensburg şehrinde çekilmiş bir dizi video kaydından 800 adet görüntü kullanmışlardır. Verilerin %25 test, %75 eğitim için kullanılmış ve %78.5 başarıml oranı elde edildiği ifade edilmektedir (Yalçın, Cilasun, 2016).

Dağlarlı ve Arıbaş tarafından 2017 yılında yapılan çalışmalarda, 184 kişiye sordukları 4 şıklı 10 adet sorudan oluşan anket yardımıyla 4 kişilik türünü tespit etmeye çalışmışlardır. Eğitim sürecinde önerdikleri derin

öğrenme metodunda 475 iterasyon tanımlayan yazarlar, elde ettikleri sonuçların genel sınıflandırma performanslarının yaklaşımıyla doğrulandığını ifade etmişlerdir (Dağlarlı, Arıbaş, 2017).

Yalçın 2016 yılında yaptığı çalışmasında, RGB-D video görüntülerindeki insan aktivitelerini otomatik olarak tanımlamak istemiştir. Yalçın, 3B iskelet eklem verileri üzerinden derin öğrenme ile iskelet hareketlerinden insanların yapmış olduğu aktiviteleri sınıflandırmak istemiştir. İnsan görüntülerinden alınan ham veriler, öteleme, döndürme ve ölçeklendirme gibi işlemler ile bir ön işlemden geçirilmiştir. Önerdiği yöntemin eğitimi için Human3.6M aktivite veri setini kullanan yazar, derin anlama ağı olarak 5 gizli katmana, her katman için 47 nörona, eğiticişiz öğrenme oranı 0,001 ve eğiticili öğrenme oranı 0,12 olan bir model kullanmıştır (Yalçın, 2016).

Tatarođlu ve arkadaşlarının 2017 yılında yaptıkları çalışmalarında, bilgisayar ortamında inceledikleri İHK

(İmmuno Histo Kimya) doku örneklerini, dijital mikroskop sistemi ile sayısallaştırmışlardır. Yazarlar 50990 adet hücre parçasını, modellerin eğitilmesi, doğrulanması ve sınanması için, Caffe platformunda bulunan AlexNet ve VGG-16 mimarilerini kullanmışlardır. Meme kanserinde CerbB2 tümörlerinin skor sınıflandırılmasında, VGG-16 mimarisi ile %99 oranında eğitim, %96 oranında doğrulama, AlexNet mimarisi ile de %98 oranında eğitim, %91 oranında doğrulama başarımı sağlamışlardır (Tataroğlu, vd., 2017).

Kaya ve arkadaşları tarafından 2017 yılında yapılan çalışmada, akciğer nodül görüntülerinin görüntü işleme yöntemleri kullanılarak nodüllerin şekli ve dokusal yapısına bağlı özneliklerinin çıkarılması ve derin öğrenme yöntemleri ile sınıflandırılması yapılmıştır. Çalışmadaki veriler LIDC veri tabanından alınmış, ön işleme ve genelleştirme işlemlerinden geçirilmiştir. Sınıflandırıcı olarak RF ve SVM algoritmaları kullanılmıştır. Yazarlar SVM sınıflandırıcısının, derin özneliklerle nodül özelliklerinin sınıflandırılmasında,

klasik özniteliklere göre daha başarılı sonuçlar ürettiğini tespit etmişlerdir. Ayrıca RF sınıflandırıcı klasik özniteliklerde daha başarılı sonuçlar sağlamıştır. Fakat habislik tahmininde derin özniteliklerin kullanılması, özellikle duyarlılık ölçümünün yükselmesinin sağlandığını bulmuşlardır (Kaya, Keçeli, Can, 2017).

Oktay'ın 2018 yılında yaptığı çalışmasında, bir derin oto kodlayıcı yapısı ile diş filmi görüntülerinden dişleri tanımayı amaçlayan bir sistem sunmuştur. Yazarın önerdiği mimari, girdi görüntü yamalarının boyutlarının her kademedede arttığı, sıralı yığınlanmış derinotokodlayıcı yapısını içermektedir. İlerdeki yığınlarda sadece adayın diş yamaları verilerek algısız yamalar elenmiştir. Yazar çalışmasında diş tanıma aşamasındaki maliyetleri düşürülmekle beraber hassas yerleştirme olanağını da gerçekleştirmiştir. Geliştirilen yöntem 210 adet dental panoramik görüntüye sahip veri kümesi üzerinde test edilmiş ve %91 doğruluk ile çalışmıştır (Oktay, 2018).

2017 yılında Arık ve arkadaşları tarafından yapılan çalışmada, derin öğrenme yöntemleri ile melanoma tespiti için cilt lezyonlarını sınıflandıran bir sistem önerilmiştir. Çalışmada ISIC arşivinden sağlıklı ve hastalıklı toplam 1279 görüntünün yaklaşık %65'i eğitim ve %35'ide test için kullanılmıştır. Yazarlar veri sınırlılığı nedeniyle, önerdikleri sistemin %70 başarı sağladığını, uzman dermatolojistlerin ise hastalığı ortalama %75 oranında tahmin edebildiklerini belirtmişlerdir (Arik, Gölcük, Karşılıgil, 2017).

Cilasun ve Yalçın'ın 2016 yılında gerçekleştirdiği çalışmada, epilepsi nöbet tespiti için EEG sinyalleri üzerinde derin konvolüsyonel sinir ağlarını kullanmışlardır. Yazarlar 173.61 Hz frekansında örneklenmiş, 100 kanallı ve 5 farklı sınıfa ayrılmış EEG verisi içeren veri setini kullanmışlardır. Veri setindeki bilgiler göz-açık, göz-kapalı, sağlıklı, epileptik ve nöbet esnasında epileptik olmak üzere yaklaşık 23 saniyelik periyotlar halinde kaydedilmiş EEG işaret verilerinden oluşmaktadır. Çalışmanın sonucu literatürdeki diğer çalışmalarla

karşılaştırılmış ve %99.7 oranında başarımlar elde edildiği ifade edilmiştir (Cilasun, Yalçın, 2016).

2017 yılında Baştürk ve arkadaşları tarafından yapılan çalışmada, EMG sinyallerinden faydalanılarak 6 farklı el hareketini sınıflandırmaya çalışılmışlardır. Yazarlar örneklem frekansı 500 Hz olan beş adet sağlıklı denekten, 6 farklı hareketin 130 defa tekrar edilmesi ile 900 adet örneklemden oluşan EMG veri setini kullanmışlardır. Ön işlemden geçirilen verilerden öznel olarak çıkarmak için 9 farklı yöntem kullanılmıştır. Verilerin %80 eğitim, %20 test işlemi için kullanan yazarlar, EMG sinyallerinin derin sinir ağı sınıflandırıcı ile klasik sınıflandırıcılardan daha iyi sonuçlar ürettiğini ve EMG sinyallerinin tıbbi teşhis de özellikle ellerini kullanamayan kişilere protez kontrolünde yardımcı olabileceğini ifade etmişlerdir (Baştürk, Yüksel, Çalışkan, Badem, 2017).

Baştürk ve çalışma arkadaşları tarafından 2017 yılında yapılan çalışmada, son yıllarda birçok bireyin yaşamını

kaybetmesine neden olan Melanom kanserinin derin sinir ağları ile tespit edilmesi amaçlanmıştır. Uygulamada 80'er adet normal ve normal olmayan tipte ve 40 adet melanom tipinde toplamda 200 adet görüntüye sahip olan PH² veri seti kullanılmıştır. Yazarlar önerdikleri derin sinir ağlarının literatürde var olan diğer yöntemler ile doğruluk değerleri üzerinden istatistiksel olarak karşılaştırma yaptıklarını ve önerdikleri yöntemin daha başarılı olduğunu ifade etmişlerdir (Baştürk, Yüksel, Badem, Çalışkan, 2017).

Yetkin ve Hamamcı tarafından 2016 yılında yapılan çalışmada, hastanın düzlemsel görüntüsü ile daha önceden alınmış baş MR görüntüleri arasındaki bağıl pozun kestirimi için derin öğrenme tabanlı bir yöntem sunulmuştur. Uygulamada sağlıklı bir denekten 3B gradyan-eko sekansı kullanılarak alınan MR hacmi kullanılmıştır. Bu hacim 3B render işlemine tabi tutulduktan sonra, 18 farklı ışık açısıyla 324 görüntü elde edilmiş ve konvolüsyonel sinir ağında görüntülerin 260

tanesi eğitim ve 64 tanesi de test işlemi için kullanılmıştır (Yetkin, Hamamcı, 2016).

Sezer ve Çekmez'in 2017 yılında yaptıkları çalışmalarında, mikroskop görüntülerinden niceliksel olarak protein yerleşim görüntülerini içeren HeLa veri setindeki imgelerden %70'ini eğitim (4859 adet), %30'unu (2037 adet) test işlemi için kullanmışlardır. Çalışmanın sonunda, AlexNet metodu, HeLa veri setini %67.34 başarıyla sınıflandırırken kelime çantası yöntemi bu veri setini %84.7 başarıyla sınıflandırdığını, kendilerinin geliştirdiği modelin ise %98.6'lık bir başarı elde ettiğini ifade etmişlerdir (Sezer, Çekmez, 2017).

4. SONUÇ

Bu çalışmada derin öğrenme ve yöntemlerinin tanımı, tarihsel gelişimi, süreci ve ülkemizdeki uygulamaları hakkında bilgileri verilmiştir. Derin öğrenme algoritmaları olan CNN, RNN, RBM, LSTM ve derin oto kodlayıcıların geliştirilme süreçleri incelenerek, gerçek uygulamalar ile örneklendirilmiştir. Ayrıca ülkemizde derin öğrenme uygulamaları mühendislik ve sağlık alan başlıklarından incelenmiştir. Mühendislik alanında yapılan çalışmaların sınıflandırma, görüntü ayırma ve tanımlama tabanlı olduğu görülmüştür. Bu çalışmalar mühendislikte bilişim, ziraat, gıda, tekstil ve coğrafi bilgi sistemleri alt başlıklarını temsil etmektedir. Sağlık alanında yapılan çalışmalar ise sınıflandırma, tahmin, teşhis ve görüntü ayırma tabanlıdır.

Derin öğrenme uygulamalarının geliştirilmesinde açık kaynak derin öğrenme kütüphaneleri kullanılmaktadır. Çizelge 1'de derin öğrenme algoritmalarını destekleyen kütüphanelerin karşılaştırılması verilmiştir. Buna göre açık kaynak kütüphanelerinin birçoğu derin öğrenme

algoritmalarını desteklediği görülmektedir. Yapılan çalışmalarda kullanılan bu kütüphanelere ihtiyaç olması durumunda yeni algoritmalarda eklendiği görülmektedir. Ayrıca çalışmalarda birden fazla derin öğrenme algoritmasının hibrit olarak kullanılmaktadır.

Çizelge 1. Derin öğrenme kütüphanelerinin desteklediği algoritmaların karşılaştırılması

	CNN	RNN	RBM	LSTM	Derin Oto Kod.
Theano	√	√	√	√	√
Tensor-Flow	√	√	√	√	√
Torch	√	√	-	√	√
Caffe	√	√	√	√	√
MXNet	√	√	√	√	√
Neon	√	√	-	√	√
Microsoft Cognitive Toolkit (CNTK)	√	√	√	√	√

KAYNAKÇA

Akbulut, Y., Sengur, A., Ekici, S. (2017). Gender recognition from face images with deep learning. 2017 International Artificial Intelligence and Data Processing Symposium (IDAP), (September), 1–4.
<https://doi.org/10.1109/IDAP.2017.8090181>

Aker, C., Tursun, O., Kalkan, S. (2017). Analyzing deep features for trademark retrieval. In Signal Processing and Communications Applications Conference (SIU), 2017 25th (pp. 1-4). IEEE.

Ando, Y., Gomi, H., Tanaka, H. (2016). Detecting Fraudulent Behavior Using Recurrent Neural Networks. In Computer Security Symposium 2016.

Arik, A., Gölcük, M., & Karşılıgil, E. M. (2017). Deep learning based skin cancer diagnosis. In Signal Processing and Communications Applications Conference (SIU), 2017 25th (pp. 1-4). IEEE.

Aslan, E. S., Bayram, B., İnce, G. (2017). Kapalı Ortamlar İçin Dağıtık Mimarili Yüz Tanıma Sistemi. In Signal Processing and Communication Application Conference (SIU), 2017 25th. IEEE.

Aydemir, M. S., Bilgin, G. (2016). Semi-supervised classification of hyperspectral images with small sample sizes. In Signal Processing and Communication Application Conference (SIU), 2016 24th (pp. 681-684). IEEE.

Aydin, E., Yuksel, S. E. (2017). ~~Derin~~Ö Yöntemini Kullanarak Yere Nüfuz Eden Radar ile Gömülü Hedef Tespiti. 2017 25th Signal Processing and

Communications Applications Conference, SIU 2017.

<https://doi.org/10.1109/SIU.2017.7960299>

Bahdanau, D., Cho, K., Bengio, Y. (2014). Neural machine translation by jointly learning to align and translate. arXiv preprint arXiv:1409.0473.

Baldi, P. (2012). Autoencoders, unsupervised learning, and deep architectures. In Proceedings of ICML workshop on unsupervised and transfer learning (pp. 37-49).

Baştürk, A., Yuksel, M. E., Caliskan, A., Badem, H. (2017). Deep Neural Network Classifier for Hand Movement Prediction. 2017 25th Signal Processing and Communications Applications Conference (SIU), 1–4.

<https://doi.org/10.1109/SIU.2017.7960566>

Baştürk, A., Yüксеi, M. E., Badem, H., Çalışkan, A. (2017). Deep neural network based diagnosis system for melanoma skin cancer. In Signal Processing and

Communications Applications Conference (SIU), 2017 25th (pp. 1-4). IEEE.

Behnke, S.. (2003). Hierarchical Neural Networks for Image Interpretation, volume 2766 of Lecture Notes in Computer Science. Springer.

Bengio, Y., Courville, A., Vincent, P., (2013). Representation learning: A review and new perspectives", IEEE Trans. Pattern Anal. Mach. Intell., vol. 35, no. 8, pp. 1798–1828.

Beşbınar, B., & Alatan, A. A. (2016, May). Visual object tracking with autoencoder representations. In Signal Processing and Communication Application Conference (SIU), 2016 24th (pp. 2041-2044). IEEE.

Bulut, I., Yavuz, A. G. (2017). Mobile malware detection using deep neural network. In Signal Processing and

Communications Applications Conference (SIU), 2017 25th (pp. 1-4). IEEE.

Büber, E., Sahingoz, O. K. (2017). Makine Öğrenmesi Sistemi ile Görüntü İşleme ve En Uygun Parametrelerin Ayarlanması. IDAP 2017 - International Artificial Intelligence and Data Processing Symposium, 1–5. <https://doi.org/10.1109/IDAP.2017.8090316>

Can, E., Alatan, A. A. (2017). Object Detection with Convolutional Context Features. 25th Signal Processing and Communications Applications Conference (SIU), 1–4. <https://doi.org/10.1109/SIU.2017.7960502>

Cengil, E., Çınar, A. (2016). A New Approach for Image Classification: Convolutional Neural Network. European Journal of Technic EJT, 6(2), 96–103.

Cilasun, M. H., Yalçın, H. (2016). A Deep Learning Approach to EEG based Epilepsy Seizure Determination. 2016 24th Signal Processing and Communication

Application Conference (SIU), 1573–1576.
<https://doi.org/10.1109/SIU.2016.7496054>

Coates, A., Ng, A., Lee, H., (2011). An Analysis of Single-Layer Networks in Unsupervised Feature Learning, in PMLR, pp. 215–223.

Colah, Erişim Tarihi: 24.04.2018, Erişim Linki:
<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

Cortes, C., Vapnik, V. (1995). Support-Vector Networks. Machine Learning, 20(3), 273–297.
<https://doi.org/10.1023/A:1022627411411>

Çalik, N., Kurban, O. C., Yilmaz, A. R., Ata, L. D., Yildirim, T. (2017). Signature recognition application based on deep learning. In Signal Processing and Communications Applications Conference (SIU), 2017 25th (pp. 1-4). IEEE.

Çelik, A., Arıca, N. (2017). Face frontalization enhanced by deep learning. In Signal Processing and Communications Applications Conference (SIU), 2017 25th (pp. 1-4). IEEE.

Çevikalp, H., Dordinejad, G. G., & Elmas, M. (2017, May). Feature extraction with convolutional neural networks for aerial image retrieval. In Signal Processing and Communications Applications Conference (SIU), 2017 25th (pp. 1-4). IEEE.

Çıtak, E., Genç, Y. (2017). Machine learning for product quality inspection. In Signal Processing and Communications Applications Conference (SIU), 2017 25th (pp. 1-4). IEEE.

Dağlarlı, E., Arıbaş, E. (2017). Personality identification by deep learning. In Signal Processing and Communications Applications Conference (SIU), 2017 25th (pp. 1-4). IEEE.

Dang, Q. V., Ignat, C. L. (2017). An end-to-end learning solution for assessing the quality of Wikipedia articles. In Proceedings of the 13th International Symposium on Open Collaboration (p. 4). ACM.

Demir, U., Ünal, G. (2017). Danışman Ağ Kullanarak Derin Otomatik Kodlayıcılar ile İçboyama. In Signal Processing and Communications Applications Conference (SIU), 2017 25th (pp. 1-4). IEEE.

Deng, L., Yu, D. (2014). Deep Learning: Methods and Applications. Foundations and Trends® in Signal Processing, 7(3-4), 197-387.
<https://doi.org/10.1561/20000000039>

Doğan, F., Türkoğlu, İ., (2018). Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması, Sakarya University Journal of Computer And Information Sciences VOL. 1, ID. Saucis-1-2018, April 2018

Elitcenkalp, Erişim Tarihi: 17.05.2018, Erişim Linki: <http://elitcenkalp.blogspot.com/2018/04/recurrent-neural-network.html>

Ergün, E., Gurkan, F., Kaplan, O., Günsel, B. (2017). Video Action Classification by Deep Learning. 2017 25th Signal Processing and Communications Applications Conference (SIU), 1–4. <https://doi.org/10.1109/SIU.2017.7960446>

Fukushima, K. (1988). Neocognitron: A hierarchical neural network capable of visual pattern recognition. Neural Networks, 1(2), 119–130. [https://doi.org/10.1016/0893-6080\(88\)90014-7](https://doi.org/10.1016/0893-6080(88)90014-7)

Fürnkranz, J. (1999). Separate-and-conquer rule learning. Artificial Intelligence Review, 13(1), 3-54.

Giles, C. L., Lawrence, S., Tsoi, A. C. (2001). Noisy time series prediction using recurrent neural networks and

grammatical inference. *Machine learning*, 44(1-2), 161-183.

Graves, A., Jaitly, N. (2014). Towards end-to-end speech recognition with recurrent neural networks. In *International Conference on Machine Learning* (pp. 1764-1772).

Graves, A., Schmidhuber, J. (2009). Offline handwriting recognition with multidimensional recurrent neural networks. In *Advances in neural information processing systems* (pp. 545-552).

Gu, X., Zhang, H., Zhang, D., Kim, S. (2016, November). Deep API learning. In *Proceedings of the 2016 24th ACM SIGSOFT International Symposium on Foundations of Software Engineering* (pp. 631-642). ACM.

Gündoğdu, E., Solmaz, B., Koc, A., Yucesoy, V., Alatan, A. A. (2017). Deep Distance Metric Learning for Maritime Vessel Identification. 2017 25th Signal Processing and Communications Applications Conference (SIU), 1–4.
<https://doi.org/10.1109/SIU.2017.7960170>

Gündüz, H., Cataltepe, Z., Yaslan, Y. (2017). Stock Market Direction Prediction Using Deep Neural Networks. 2017 25th Signal Processing and Communications Applications Conference (SIU), 1–4.
<https://doi.org/10.1109/SIU.2017.7960512>

Güngör, C., Baltacı, F., Erdem, A., Erdem, E. (2017). Turkish cuisine: a benchmark dataset with Turkish meals for food recognition. In Signal Processing and Communications Applications Conference (SIU), 2017 25th (pp. 1-4). IEEE.

Haykin, S. (2009). Rosenblatt's Perceptron. *Neural Networks and Learning Machines*, (1943), 47–67. Upper Saddle River, NJ, USA: Pearson.

Hinton,G.E., Salakhutdinov, R., (2006). Reducing the Dimensionality of Data with Neural Networks, *Science* (80-.),, vol. 313, no. 5786, pp. 504–507.

Hinton,G.E., Salakhutdinov,R., (2009). Replicated Softmax: an Undirected Topic Model, in *Advances in Neural Information Processing Systems 22*, pp. 1607–1614.

Hochreiter, S., Heusel, M., Obermayer,K., (2007). Fast model-based protein homology detection without alignment, *Bioinformatics*, vol. 23, no. 14, pp. 1728–1736.

Hochreiter, S., Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780.
<https://doi.org/10.1162/neco.1997.9.8.1735>

Hu, W., Huang, Y., Wei, L., Zhang, F., Li, H. (2015). Deep convolutional neural networks for hyperspectral image classification. Journal of Sensors, 2015.

Huang, F.J., LeCun, Y., (2006). "Large-scale learning with SVM and convolutional nets for generic object categorization", in Proc. of IEEE Int. Conf. on Computer Vision and Pattern Recognition.

Işık, G., Artuner, H. (2016). Recognition of radio signals with deep learning Neural Networks. In Signal Processing and Communication Application Conference (SIU), 2016 24th (pp. 837-840). IEEE.

Ivakhnenko, A. G., Lapa, V.G., (1965). Cybernetic predicting devices. N.Y. CCM Information Corp.

Jarrett, K., Kavukcuoglu, K., Ranzato, M., LeCun, Y., (2009). What is the best multi-stage architecture for

object recognition?, in Proc. of IEEE Int. Conf. on Computer Vision, pp. 2146–2153.

Karahan, S., Akgul, Y. S. (2016). Derin Öğrenme ile Göz Tepiti. 2016 24th Signal Processing and Communication Application Conference (SIU), 2145–2148. <https://doi.org/10.1109/SIU.2016.7496197>

Karasoy, O., Ballı, S. (2017). Classification Turkish SMS with deep learning tool Word2Vec. In Computer Science and Engineering (UBMK), 2017 International Conference on (pp. 294-297). IEEE.

Karpathy, A., Fei-Fei, L. (2015). Deep visual-semantic alignments for generating image descriptions. In Proceedings of the IEEE conference on computer vision and pattern recognition(pp. 3128-3137).

Kaya, A., Keceli, A. S., & Can, A. B. (2017). Investigation of transfer learning on pulmonary nodule characteristics. 2017 25th Signal Processing and

Communications Applications Conference, SIU 2017, 0–
3. <https://doi.org/10.1109/SIU.2017.7960357>

Kaynar, O., Arslan, H., Görmez, Y., Işık, Y. E. (2018). Makine Öğrenmesi ve Öznitelik Seçim Yöntemleriyle Saldırı Tespiti. International Journal of Informatics Technologies, 11(2).

Kaynar, O., Aydın, Z., Görmez, Y. (2017). Sentiment Analizinde Öznitelik Düşürme Yöntemlerinin Oto Kodlayıcı Derin Öğrenme Makinaları ile Karşılaştırılması. Bilişim Teknolojileri Dergisi, 10(3), 319-326.

Kaynar, O., Görmez, Y., Işık, Y. E. (2016). Oto Kodlayıcı Tabanlı Derin Öğrenme Makinaları ile Spam Tespiti, (November).

Kaynar, O., Yuksek, A. G., Gormez, Y., Isik, Y. E. (2017). Intrusion detection with autoencoder based deep

learning machine. 2017 25th Signal Processing and Communications Applications Conference (SIU), (May), 1–4. <https://doi.org/10.1109/SIU.2017.7960180>

Keçeli, A. S., Kaya, A., Can, A. B. (2017). Action recognition with skeletal volume and deep learning. In Signal Processing and Communications Applications Conference (SIU), 2017 25th (pp. 1-4). IEEE.

Kiliç, M. M., Akgül, Y. S. (2018). Ship location estimation from radar and optic images using metric learning. In 2018 26th Signal Processing and Communications Applications Conference (SIU). IEEE.

Koç, Ş. G., Aptoula, E. (2017). Öz-ikili öznitelik profilleri ile eğitilmiş evrişimsel sinir ağları ile hiperspektral görüntü sınıflandırma. In Signal Processing and Communication Application Conference (SIU), 2017 25th. IEEE.

Koyun, A., Afşin, E. (2017). Derin Öğrenme ile İki Boyutlu Optik Karakter Tanıma. Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi, 10(1), 11-14. Derin Öğrenme ile İki Boyutlu Optik Karakter Tanıma, 22–25.

Larochelle, H., Bengio, Y., (2008). Classification using discriminative restricted Boltzmann machines, in Proceedings of the 25th international conference on Machine learning - ICML, pp. 536–543.

LeCun, Y., Bengio, Y., Hinton. G., (2015). Deep learning, Nature, vol. 521, pp. 436–444.

LeCun, Y., Boser, B., Denker, J.S., Henderson, D., Howard, R.E., Hubbard, W., Jackel, L.D., et al. (1990). Handwritten digit recognition with a backpropagation network, In Advances in neural information processing systems.

LeCun, Y., Bottou, L., Bengio, Y., Haffner. P., (1998). Gradient based learning applied to document recognition, Proceedings of the IEEE, 86(11):2278–2324.

Lee,H., Grosse, R., Ranganath, R., Ng, A.Y., (2009). Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations, In Proceedings of the 26th Annual International Conference on Machine Learning, pp. 609–616. ACM.

Machinelearningmastery, Erişim Tarihi:
03.02.2018,Erişim Linki:
<https://machinelearningmastery.com/inspirational-applications-deep-learning/>

McCulloch, W. S., Pitts, W. (1943). A Logical Calculus of the Idea Immanent in Nervous Activity. Bulletin of Mathematical Biophysics, 5, 115–133.
<https://doi.org/10.1007/BF02478259>

Mikolov, T., Karafiát, M., Burget, L., Černocký, J., Khudanpur, S. (2010). Recurrent neural network based language model. In Eleventh Annual Conference of the International Speech Communication Association.

Najafabadi, M. M., Villanustre, F., Khoshgoftaar, T. M., Seliya, N., Wald, R., Muharemagic, E. (2015). Deep learning applications and challenges in big data analytics. *Journal of Big Data*, 2(1), 1–21.
<https://doi.org/10.1186/s40537-014-0007-7>

Nytimes, Erişim Tarihi:17.05.2018, Erişim Linki:
https://www.nytimes.com/2012/06/26/technology/in-a-big-network-of-computers-evidence-of-machine-learning.html?_r=1&hpw&pagewanted=all

Oktay, A. B. (2018). Büyükten Küçüğe Oto-Kodlayıcılar ile Dışlerin Konumlandırılması. *Bilişim Teknolojileri Dergisi*, 11(1), 29–34.
<https://doi.org/10.17671/gazibtd.317893>

Pekmezci, M., (2012). Kısıtlanmış Boltzman Makinesi ile Zaman Serilerinin Tahmini, Y.Lisans Tezi, Bilgisayar Mühendisliği Anabilim Dalı, Fen Bilimleri Enstitüsü, Maltepe Üniversitesi.

Ranzato, M.A., Huang, F.J., Boureau, Y., LeCun, Y., (2007). Unsupervised learning of invariant feature hierarchies with applications to object recognition, in Proc. of IEEE International Conference on Computer Vision and Pattern Recognition (CVPR), pp. 1–8.

Razavi, S., Yalcin, H. (2017). Using convolutional neural networks for plant classification. In Signal Processing and Communications Applications Conference (SIU), 2017 25th (pp. 1-4). IEEE.

Rush, A. M., Chopra, S., Weston, J. (2015). A neural attention model for abstractive sentence summarization. arXiv preprint arXiv:1509.00685.

Salakhutdinov,R., Mnih,A., Hinton,G., (2007). Restricted Boltzmann machines for collaborative filtering, in Proceedings of the 24th international conference on Machine learning – ICML, pp. 791–798.

Salman, M., & Yüksel, S. E. (2016, May). Hyperspectral data classification using deep convolutional neural networks. In Signal Processing and Communication Application Conference (SIU), 2016 24th (pp. 2129-2132). IEEE.

Sarıkaya, M. A., İnce, G. (2017). Emotion recognition from EEG signals through one electrode device. In Signal Processing and Communications Applications Conference (SIU), 2017 25th (pp. 1-4). IEEE.

Schmidhuber,J., Gers, F., Eck,D., (2002). Learning Nonregular Languages: A Comparison of Simple Recurrent Networks and LSTM, Neural Comput., vol. 14, no. 9, pp. 2039–2041.

Sezer, A., Çekmez, U. (2017). Cells classification with deep learning. In Signal Processing and Communications Applications Conference (SIU), 2017 25th (pp. 1-4). IEEE.

Shkarupa, Y., Mencis, R., Sabatelli, M. (2016). Offline Handwriting Recognition Using LSTM Recurrent Neural Networks. In The 28th Benelux Conference on Artificial Intelligence.

Şeker, A., Yüksek, A. G. (2017). Kumaş Hatası Tespiti için Yığılanmış Oto-kodlayıcı Yöntemi. Cumhuriyet Üniversitesi Fen-Edebiyat Fakültesi Fen Bilimleri Dergisi, 38(2), 342-354.

Taigman, Y., Yang, M., Ranzato, M., Wolf, L. (2014). DeepFace: Closing the Gap to Human-Level Performance in Face Verification. Proceedings of the IEEE Computer Society Conference on Computer Vision

and Pattern Recognition, 1701–1708.

<https://doi.org/10.1109/CVPR.2014.220>

Tataroğlu, G. A., Genc, A., Kabakci, K. A., Capar, A., Toreyin, B. U., Ekenel, H. K., Cakir, A. (2017). A Deep Learning Based Approach for Classification of CerbB2 Tumor Cells in Breast Cancer. 2017 25th Signal Processing and Communications Applications Conference, SIU 2017, (May).

<https://doi.org/10.1109/SIU.2017.7960587>

Theguardian, Erişim Tarihi:23.04.2018, Erişim Linki:

<https://www.theguardian.com/technology/2016/jun/27/al-phago-deepmind-ai-code-google>

Towardsdatascience Applied Deep Learning - Part 3:

Autoencoders, Erişim Tarihi: 22.02.2018, Erişim Linki:

<https://towardsdatascience.com/applied-deep-learning-part-3-autoencoders-1c083af4d798>

Turhan, C. G., & Bilge, H. Ş. (2017, May). Generating word images using deep generative adversarial networks. In Signal Processing and Communications Applications Conference (SIU), 2017 25th. IEEE.

Tümen, V., Söylemez, Ö. F., Ergen, B. (2017, September). Facial emotion recognition on a dataset using convolutional neural network. In Artificial Intelligence and Data Processing Symposium (IDAP), 2017 International (pp. 1-5). IEEE.

Uçar, A., Bingöl, M. S. (2018). Derin öğrenmenin Caffe kullanılarak grafik işleme kartlarında değerlendirilmesi. DÜMF Mühendislik Dergisi, 9(1), 39-49.

Weng, J., Cohan, P., Herniou, M. (n.d.).(1992). Camera Calibration with Distortion Models and Accuracy Evaluation.

Yalçın, H. (2016). Human activity recognition using deep belief networks. In Signal Processing and Communication Application Conference (SIU), 2016 24th (pp. 1649-1652). IEEE.

Yalçın, H., Cılasun, M. H. (2016). Deep learning based autonomous direction estimation. In Signal Processing and Communication Application Conference (SIU), 2016 24th (pp. 1645-1648). IEEE.

Yaronhadad, Erişim Tarihi: 01.03.2018, Erişim Linki: <http://www.yaronhadad.com/deep-learning-most-amazing-applications/>

Yetkin, A. E., Hamamcı, A. (2016). Data Augmentation for Head Pose Estimation From MRI Surface. Tıp Teknolojileri Kongresi, 27-29 Ekim 2016.

Yücer, Ş., (2018). Üç Boyutlu İskelet Verilerinden Metrik Öğrenme Tabanlı Hareket Tanıma, Gebze Teknik

Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar
Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi.

