



# Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme

**Ferdi DOĞAN\***

Adıyaman Üniversitesi, Kahta Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, Kahta, Adıyaman.  
fdogan@adiyaman.edu.tr ORCID:0000-0002-9203-697X, Tel: (416) 725 81 50 (1188)

**İbrahim TÜRKÖĞLU**

Fırat Üniversitesi, Teknoloji Fakültesi, Yazılım Mühendisliği Bölümü, Merkez, Elazığ.  
iturkoglu@firat.edu.tr ORCID: 0000-0003-4938-4167

Geliş: 30.03.2018, Kabul Tarihi: 19.12.2018

## Öz

*Derin öğrenme makine öğreniminin bir koludur. Makine öğreniminin başlarından günümüze kadar geçen süreçte yapay zekaya olan ilgi giderek artmış ve günümüzde en çok kullanılan yapay zeka algoritmaları olan derin öğrenme mimarilerinin ortaya çıkmasını sağlamıştır. Derin öğrenme mimarileri ile birlikte yapay zeka problemlerinin çözümü için pek çok derin öğrenme yaklaşımları geliştirilmiştir. Endüstri, tıp, robotik, görüntü işleme, bilgisayar görmesi, nesne tespiti, ses işleme-tanıma, çeviri, gelecek tahmini, finansal gibi pek çok alanda akıllı çözümler üretmektedir. Bu çalışmada, derin öğrenme mimarileri ve algoritmaları incelenerek, literatürde yapılmış çalışmalar ışığında uygulama alanları temelinde başarımları değerlendirilmiştir. Derin öğrenme mimarileri ile birlikte derin öğrenmede kullanılan kütüphanelere yer verilmiştir. Bununla beraber farklı problemlerin çözümlerine yönelik geliştirilen derin öğrenme mimarileri yer almaktadır.*

**Anahtar kelimeler:** Derin öğrenme, Yapay sinir ağları, Derin CNN, Konvolüsyonel sinir ağları

\* Yazışmaların yapılacağı yazar


## Giriş

Günümüz mühendislik uygulamalarında insan gibi düşünen, insan gibi davranışlar sergileyen uygulamalara ağırlık verilmektedir. İnsan olgusunun mühendislik uygulamalarında yer alması için kullanılan adlandırma makine öğrenmesi olarak bilinir (Goldberg ve Holland, 1988; Quinlan, 1986). İnsanın hayatı boyunca öğrendiği şeylerin günlük yaşamda hayatını kolaylaştırdığı ve deneyimlerine göre hareket ettiğini örnek olarak aynı şekilde makine öğrenmesi gerçekleştirilmeye çalışılmaktadır. Makine öğrenmesinin özellikle sanayide üretim kademesinde işlerin hızlandırılması, ürün kalitesinin artırılması, ürünlerin sınıflandırılması vb. gibi işlemleri hızlıca yapması için kullanımı tercih edilmektedir (Sebastiani, 2002; Jordan ve Mitchell, 2015). Bunun dışında güvenlik uygulamalarında, sınıflandırma, medikal teşhis ve tanı uygulamalarında, ileriye dönük tahminsel yaklaşımlarda vb. (Michalski vd, 20013; Sommer ve Paxson, 2010; Buczak ve Guven, 2016; Kourou vd, 2015; Holder vd., 2017) gibi pek çok alanda kullanımı artmakta ve hayatı kolaylaştırmaktadır. Bu gibi uygulamaların gerçekleştirilmesi için kullanılan makine öğrenmesindeki temel nokta insan beynindeki nöronların çalışmasından faydalanılarak benzer bir yaklaşımla makinanın öğrenmesini ve buna göre davranmasını sağlamaktır (Fukushima, 1975). İnsan beynindeki sinir hücrelerinin çalışma mantığından faydalanılarak yapay sinir hücre modeli oluşturulmuştur (Harvey, 1994). Bu yapay sinir hücre modeli zaman içerisinde geliştirilmiş ve makine öğrenmesinde sıklıkla kullanılmaya başlanmıştır. Günümüzde bu yapay sinir hücre mantığı daha ileri seviyelere taşınarak derin öğrenme mantıklı bir model kullanılmaya başlanmıştır (Hinton vd., 2006).

Yapay sinir ağı insan beyninin öğrenme sürecinden etkilenerek ortaya atılmış bir yaklaşımdır. Bu yaklaşım ilk kez 1943 yılında insan beynindeki hücrelerin yapısının matematiksel modellenmesi oluşturularak gerçekleştirilmiştir (McCulloch ve Pitts, 1943).

Burada temel amaç insan beyninin öğrenmesini sağlayan sinir hücrelerinin matematiksel olarak modellenerek bir bilgisayar sisteminin benzer bir yaklaşım sergilemesini sağlamaktır. Bir insanın öğrenmesi yan yana gelen sinapsların birbiriyle olan bağlantılarıyla gerçekleşir (Hebb, 1949). Sayısallaştırılmış bir sinir hücresi mantığı ile yapay sinir ağı oluşturulmuştur.

Yapay sinir ağındaki matematiksel yaklaşımla basit bir sinir ağı modellenmesi yapılmış ve bilgisayar sistemlerinde uygulanması amaçlanmıştır. Sonraki yıllarda Hebb bu sinir hücrelerinin tekrar eden durumlar karşılığında öğrenmenin arttığını belirlemiştir. Bu işlemde nöronların matematiksel modellenmesi nöronların gücünün artırılması gerektiğini ortaya koymuştur (Hebb 1949).



Şekil 1. Bir Sinir Hücresinin Matematiksel Modeli-Perceptron Sinir Hücresi Modeli

Şekil 1'de bir sinir hücresinin matematiksel modeli gösterilmiştir. Burada X1, X2, X3 ile belirtilen her bir dendriti göstermektedir. Dendritlere ait ağırlıklar ise W1, W2, W3 ile gösterilmektedir (Sarle, 1994). Her bir sinyalin toplandığı Net ise çekirdeği temsil etmektedir. Tüm sinyallerin ağırlıkları ile çarpılarak toplam elde edilmektedir. Elde edilen Net toplam değeri bir sonraki nörona belirli bir eşik değeri ile gönderilmesi için F(Net) transfer fonksiyonu ile gerçekleştirilmekte. F(Net) için kullanılacak 3 temel fonksiyon vardır. Keskin limitli transfer fonksiyonunun da giriş değeri 0'dan küçük içe çıkış değeri 0'dır. Giriş değeri 0'dan büyük ise çıkış değeri +1 değerini alır. Eşik değeri fonksiyonunda ise girdi değeri toplamda 0 ve daha küçük ise 0, 1 ve daha büyük girişler için 1, 0 ile 1 arasındaki değerlerde ise kendini alır. Sigmoid fonksiyonu süreklilik gösteren ve türevi alınabilen bir fonksiyondur. Doğrusal olmaması sebebiyle sıklıkla tercih edilmektedir. Girdi

değerine bağlı olarak 0-1 aralığında bir değer alır (Stein, 1956).

1956 yılında Dartmouth'ta düzenlenen bir konferansta zeka ile donatılmış bir bilgisayar programını gerçekleştirme olanağını araştırmayı öne sürmüşlerdir. Böylelikle yapay zeka terimi kullanılmıştır. (J. McCarthy vd., 1956), LISP ile yapılan satranç oyunu oynayan mantık teorisi üzerine kurulu ilk yapay zeka programı üretilmiştir. 1958 yılında Frank Rosenblatt örüntü sınıflandırma için iki katmanlı perceptron ağını önermiştir (Rosenblatt, 1958). Daha sonra Robinson geliştirdiği yapay zeka algoritmasında çözünürlük ilkesine dayanan makine odaklı bir mantık makalesini yayınlamıştır (Robinson, 1965). 1970'li yılların ortalarına kadar yapay sinir ağlarının karanlık döneme girip durma noktasına gelmiştir. Bu dönemde XOR probleminin çözülmemiş olması yapay zekanın geleceği konusunda ciddi kaygılara yol açmıştır. Ve yapay zeka bu noktadan sonra duraklama dönemine girmiştir (Minsky, 1969). 1970 ve 1980'li yıllar arasında bilgiye dayalı sistemler ağırlıklı yer almıştır. 1970'lerin ortalarında XOR probleminin çözümü üzerine yaklaşım getirmiştir (Werbos, 1974). Hopfield neuro biyolojik yapıların makinalar içinde uygulanabilirliği konusunda yayınladığı bir makale ile makine öğrenimine dikkat çekmiştir (Hopfield, 1982). 1986 yılında yayınlanan bir kitapta paralel dağıtık sistemlere ait problemlerin çözümleri ortaya konmuştur. Burada XOR probleminin çözümü de yer almaktadır (McClelland, 1986). Aynı yıl Fukushima yaptığı çalışma ile örüntü tanıma için bir yaklaşım getirmiştir (Fukushima, 1986). Daha sonra Broomhead ve Lowe yaptıkları çalışma ile radial tabanlı sistemleri çok katmanlı sistemlere alternative olarak geliştirmişlerdir (Broomhead ve Lowe, 1988). Probalistik ağlar (Specht 1988) ve genel regresyon ağları (Specht, 1991) ortaya konmuştur. Yapılan çalışmalarla yapay zeka, yeniden yön bulmuştur. Pek çok bilimsel çalışmada kullanılır hale gelmiştir (Yadav, 2015).

Yapay sinir ağı modeli teorisiyle birlikte makine öğrenmesi konusunda bir çağ başlatılmıştır. İnsan düşüncelerine göre karar verme yetisi yapay sinir ağı modeli ile makinelerle de geçmiştir. Lineer denklemlerin çözümünde başarılı sonuçlar elde edilmiştir (Sajikumar ve Thandaveswara, 1999). Literatüre bu yöntemle kazandırılmış pek çok yaklaşım yer almaktadır. Yapılan çalışmalarda ileri beslemeli yapay sinir ağı modeli kullanılmış ve başarı oranı belirli bir sınırdan kalmıştır (Morris ve Rubin, 1991).

İlk yapılan yapay sinir ağı modelinde tek katmanlı ileri beslemeli yapay sinir ağı modeli kullanılmıştır (Lippmann, 1987). Elde edilen sonuçlar belirli bir oranda kalmış ve üzerine çıkamamıştır. Daha sonrasında yapılan çalışmalarda geri beslemeli sinir ağı modeli oluşturulmuştur. Geri beslemeli sinir ağı modeli ile elde edilen sonuçlar üzerinde düzenlemeler yapılarak daha başarılı sonuçlara ulaşılmıştır. Yapay sinir ağı modelleri ile yapılan çalışmalar artarken halen lineer denklemlerde sağlıklı çalışan bu sistem lineer olmayan sistemlerde çalışmamakta ve doğru sonuçlar üretilmemekteydi (Jain vd., 1996).

Linear olmayan problemlerin çözüme ulaşması çok katmanlı yapay sinir ağı modeli ortaya çıkarmış ve geri beslemeli çok katmanlı sinir ağı modeli ile lineer olmayan denklemler çözüme kavuşmuş. Ve sinir ağlarına olan ilgi yeniden artmıştı (Eberhart ve Kennedy, 1995).

Çok katmanlı sinir ağı modelinin ortaya çıkmasıyla birlikte katman sayısının artırılarak daha iyi sonuçlar vermesi için Convolutional Neural Network (CNN) geliştirilmiştir. Burada yer alan sinir ağı modelinde gizli katmanlar yer almakta ve elde edilen sonuçlar oldukça başarılı olmaktadır (Pan vd., 2000).

Konvolüsyonel sinir ağlarının gelişmesi ile birlikte sınıflandırma işlemleri daha başarılı sonuçlar vermiştir. Konvolüsyon işlemi ile obje üzerindeki hatlar belirli hale getiriliyor ve sinir ağı modeli içine dahil ediliyordu (LeCun ve

Bengio, 1995). 2006 yılında Geoffrey Hinton ve Ruslan Salakhutdinov tarafından yayınlanan makale ile derin öğrenme terimi ortaya atılmış ve derin öğrenme çalışmaları başlamıştır (Hinton ve

Salakhutdinov, 2006). Sinir ağlarının gelişim süreci tablo 1’ de verilmektedir.

**Tablo1.** Sinir ağlarının tarihsel dönüm noktaları

Yıllar	Gerçekleşen	Yayıncı
1940	Elektronik Beyin (1943)	S. McCulloch, W. Pitts
1950	Perceptron – Tek katmanlı algılayıcı (1957)	M. Hoff, B. Widrow, F. Rosenblatt
1960	Adaline (1960) Multi Layer Perceptron- Çok katmanlı algılayıcı (1965)	A.G. Ivakhnenko, V.G. Lapa
1970	Neocognitron (1979)	K. Fukushima
1980	Backpropagation (1986)	D.Rumelhart, G.Hinton, R.Williams
1990	XOR probleminin ortaya çıkışı (1991) Destek Vektör Makineleri (SVM-Support Vector Machine)	S. Hochreiter Schölkopf, Burges, Vapnik
2000		
2010	Deep Neural Networks – Derin Sinir ağları (2006)	G. Hinton

## Materyal ve Yöntem


### Derin Öğrenme

Hinton’un yapmış olduğu çalışmalarla yayınlamış olduğu makalede yapay sinir ağlarına yeni bir yaklaşım getirmiştir. Bu yaklaşım derin öğrenme (Deep Convolution Neural Network) olarak adlandırılmıştır (Hinton vd., 2006). Konvolüsyonel sinir ağları çok katmanlı sinir ağları olarak bilinmektedir. Bu sinir ağı sistemiyle önemli çalışmalar yapılmış ve başarıları yüksek sonuçlar elde edilmiştir. Derin konvolüsyonel sinir ağı elde edilen bu başarıları daha yüksek seviyelere çıkararak önemli bir başarıya imza atmıştır (Krizhevsky vd., 2012; LeCun vd., 1998; Szegedy vd., 2015; Zeiler ve Fergus, 2013; Szegedy vd., 2015).

Konvolüsyonel sinir ağı ile sinyal işleme, video analizi, görüntü analizi ve tespiti, sınıflandırma, medikal görüntü işleme gibi pek çok alanda önemli işler çıkarmıştır. Bu sinir ağı kullanılırken bazı aşamalar gerçekleştirilmektedir. Bunlar ön işlem, özellik çıkarımı ve sınıflandırma-tespit şeklinde tanımlanmaktadır. Her bir aşamasında özel yaklaşımlar sergilenmekte ve doğruluğu artırmaya yönelik çalışmalar yapılmaktadır. Özellikle özellik çıkarım işlemi için pek çok farklı yaklaşım sunulmuştur. Özellik çıkarımı ile tespit edilmesi istenen olaya ait belirgin noktalar

ortaya çıkarılmaya çalışılmaktadır. Sonraki süreçte ise yapay sinir ağları kullanılarak belirlenen özelliklere ait sınıfın tespiti için sinir ağları kullanılmaktadır (Snoek vd., 2005; Li vd., 2010; Scherer vd., 2010).

Derin öğrenme ile daha önce yapılan pek çok işlem bir arada yürütülerek sonuca gidilmektedir. Burada özellikle ön işlem ve özellik çıkarımı gibi yapılar göz ardı edilmekte ve sinir ağı içerisinde bu işlemler otomatik olarak yapılmaktadır. Derin konvolüsyonel sinir ağında özellik çıkarımı ağı içerisinde belirlenmekte ve katmanlar içerisinde tespit edilmesi istenen yapıya ait özellikler belirlenmektedir. Alt katman ile üst katman arasında bağlantılı hiyerarşik bir yapı bulunmaktadır. Özellik çıkarımı için özel bir safha bulunmamaktadır. Katmanlar içerisindeki yapısında nesne-olaya ait belirgin özellikler belirlenmekte (Hinton ve Salakhutdinov, 2006) ve sonraki katmana aktarılmaktadır (Bengio, 2009). Şekil 2’ de yer alan görüntüde uydur görüntülerini sınıflandırılmasını sağlayan konvolüsyonel sinir ağı modeli yer almaktadır (Doğan ve Türkoğlu, 2017).



Şekil 2. Uydu görüntülerini sınıflandıran konvolüsyonel sinir ağı modeli

Yapay sinir ağlarında sınıflandırma yapılırken kullanılan 3 temel öğrenme yapısı vardır bunlar öğretmenli öğrenme (Supervised) (Shipp vd., 2002), öğretmensiz öğrenme (Unsupervised) (Hastie, 2009) ve takviyeli öğrenmedir (Reinforcement) (Chapelle, 2006).

Öğretmenli öğrenmede yapay sinir ağına giriş verisi olan  $y(t)$  verisi, çıkışta  $d(t)$  olarak çıkacağı bilgisi verilmiştir. Oluşturulan sinir ağı içerisinde sonuca ulaşmak için ağırlıklar belirlenir. Bu ağırlıklara göre  $y(t)$  girdi verisinin  $d(t)$  çıkış sonucunu elde edilmesi için verilen örnekler göre ağırlıklar güncellenir. Ağırlıkların güncellenmesi işlemi belirlenen iterasyon sayısı kadar devam ederek öğrenme işlemi gerçekleşir (Shipp vd., 2002).

Öğretmensiz öğrenmede ise bir çıkış bilgisi verilmeksizin giriş görüntüleri ağına girişine uygulanır. Ağdaki katmanlarda sonuç verisi oluşturulur. Buna göre oluşan çıkışlarda benzer değerlere sahip olan sonuçlar bir kümeye alınır. Oluşan her bir küme bir sınıfı temsil eder (Hastie, 2009).

Takviyeli öğrenmede ise ağa giren verinin çıkış verisi ne olması gerektiği konusunda bir bilgi verilmez. Girdi verisinin çıkışı üretilmesi beklenir. Bir öğretmen yardımıyla üretilen çıkışa göre sonucun doğru ya da yanlış olduğu bilgisi verilir. Girdi verisi yanlış sonucu ürettiğinde ağı ağırlıklarının doğru sonucu üretmesi için tekrar güncelleme yapar (Chapelle, 2006).

Her problemin çözümü için aynı yapay sinir ağı modeli kullanılamaz. Yapay sinir ağları

kullanıldıkları yerlere ve amaca göre farklılık göstermektedir. Problemlerin yapısına göre tercih edilecek olan model değişkenlik göstermektedir. Aşağıda yer alan bölümde yapay sinir ağları modelleri görülmektedir. Sınıflandırma, tespit, tanı, tahmin, teşhis vb. sonuçların üretilmesi için farklı sinir ağı modelleri tercih edilir. Bu durum verinin yapısına göre de değişkenlik gösterebilmektedir. Verinin görüntü, ses, sinyal olması da seçilecek olan sinir ağı modelini belirlemede etkili olmaktadır.

### a) Konvolüsyonel Sinir Ağları (Convolutional Neural Network)

Çok katmanlı ileri beslemeli bir yapay sinir ağı olan konvolüsyonel sinir ağı (CNN) özellikle görüntü analizlerinin yapılması için kullanılmaktadır. Hayvan görü sistemine dayanan bir yaklaşımla ortaya atılmıştır (Hubel ve Wiesel, 1968). Filtrelemeye dayalı bir yapıdadır. Kullanılacak olan filtre ile görüntünün özelliğini belirtecek öznitelikleri belirgin hale getirir. Özellikle sınıflandırıcı işlemlerinde başarılı sonuçlar üretmektedir. Filtreler farklı boyut ve değerlerde kullanılarak baskınlık düzeyi az olan özniteliklerin ortaya çıkmasını sağlar (Fukushima, 1982; Simard, 2003). Şekil 2'de konvolüsyonel sinir ağına ait örnek bir mimari görülmektedir.

İlk olarak LeCun ve arkadaşları tarafından gradyan temelli bir yaklaşım sunularak ortaya çıkan ağ yapısına konvolüsyonel sinir ağı adı verilmiştir. Oluşturulan bu yapay sinir ağına ise LeNet adı verilmiştir (LeCun vd., 1998).

Çok katmanlı bu sinir ağı içerisinde birden fazla konvolüsyon katmanı, tam bağlı katman, aktivasyon katmanı, sınıflandırıcı katman, havuzlama katmanı ve bunlara ek katmanlar yer almaktadır. Her katman kendi işlevini yürüterek sınıflandırıcı katmanda sonuç üretilmektedir.


Derin öğrenme yapıları içerisinde en çok kullanılan sinir ağı konvolüsyonel sinir ağlarıdır. Daha çok sınıflandırma ve tespit işlemleri için kullanılmaktadır. Sinir ağı içerisindeki katmanlarla sınıflandırılacak öğelere ait

öznitelikler belirlenerek sınıflandırıcı katmanı ile öğeler sınıflandırılır.

Imagenet tarafından 2012 ve 2014 yılında yapılan gerçekleştirilen en büyük nesne tanıma yarışması olan Büyük Ölçekli Görsel Tanıma yarışmasında en başarılı sonuçlar Konvolüsyonel sinir ağları ile elde edilmiştir (Girshick vd., 2014).


### b) Tekrarlayan Sinir Ağı (Recurrent Neural Network)

Elman tarafından tasarlanan basit tekrarlayan sinir ağları (Simple Recurrent Network-SRN) dil bilimciler ve psikanaliz için çığır açan bir yaklaşım olmuştur. Elmanın yayınladığı makalede konuşma akışı üzerindeki gizli yapı üzerinde çalışılan bir öğrenme sürecini temsil ediyordu. Örüntü kümelemesinde fiil ve isim kategorizasyonu açık şekilde birbirinden ayrılıyordu. Ayrıca canlı-cansız, insan-hayvan, avcı-yırtıcı gibi kategorilerde ayrılmıştı. (Elman, 1990). Şekil 3'te elman basit tekrarlayan sinir ağı örneği yer almaktadır (Şeker, 2017).




Şekil 3. Basit tekrarlayan ağ mimarisi

Tekrarlayan sinir ağları (RNN), sadece ağa giren giriş örneklerini değil daha önce zaman serisi içerisindeki giriş örneklerini de alırlar. Bu sinir ağının amacı ardıl şekilde gelen verilerin kullanılmasıdır. Geleneksel sinir ağlarında girişler birbirlerinden bağımsız olarak ağa giriş yapar. Ancak tekrarlanan sinir ağlarında dizideki her verinin çıktısı önceki hesaplamalara bağlıdır. Şekil 4'te tekrarlayan sinir ağının nasıl açıldığı gösterilmektedir.



Şekil 4. Tekrarlayan sinir ağının açılması

Tekrarlayan sinir ağları daha çok dil çevrimleri için kullanılmakla birlikte arka arkaya meydana gelen bir dizi yapıdan bir sonraki noktayı tahmin edilmesi işlemini yapar. Buna basitçe örnek vermek gerekirse finansal bir hareketin dizi şeklinde zaman serileri ile giriş verisi olarak kullanılarak sonraki bir zamanda hangi durumda olacağını tahmin edilmesi olarak gösterilebilir. Ya da kurulacak bir cümlede art arda gelen kelimelerin akabinde cümlenin devamının nasıl geleceğini gösteren kelimenin tahmin edilmesi işlemi örnek olarak verilebilir. İki tür RNN vardır bunlar; İki yönlü RNN'ler (Bidirectional RNNs) (Schuster ve Paliwal, 1997) ve Derin RNN'lerdir (Deep RNNs) (Schmidhuber, 1992).



Şekil 5. Tekrarlayan sinir ağı modeli

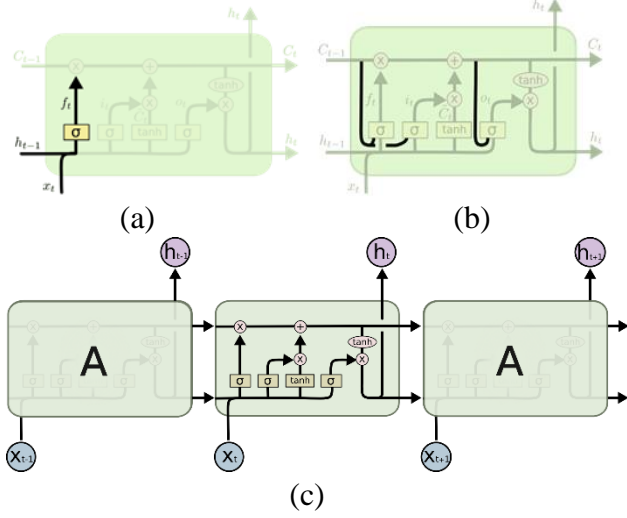
Şekil 5'te tekrarlayan sinir ağı modeli yer almaktadır.

### c) Uzun-Kısa Süreli Hafıza (LSTM- Long Short-Term Memory)

RNN mimarilerinde zaman dizeleri aralarında bağlam boşlukları olması halinde sonraki dizinin tahmin edilmesi çok zor bir durumdur (Bengio vd, 1994). Bu durum RNN'ler için oldukça dezavantajlı bir durumdur. Hochreiter ve Schmidhuber yapmış oldukları çalışmada bu durumu ortadan kaldıracak uzun ve kısa süreli

hafıza LSTM öne sürmüşlerdir (Hochreiter ve Schmidhuber, 1997).

LSTM ağlarının RNN ağlarından bir farkı yoktur. Fakat gizli durumu hesaplamak için LSTM ağlarında bir yapı kullanılır. LSTM içerisinde hafıza hücreleri yer alır. Önceki durumu ve girdi bilgisini tutan bir hücredir. Ağ mimarisi içerisinde yer alan bu hücreler hangi verinin tutulacağına ya da hangi verinin sileneğine karar verirler. Sonraki aşamada ise önceki durumu mevcut bellek ile giriş verisini birleştirirler. Böyle bir yaklaşımla uzun vadeli bağımlılıkların ortadan kaldırılarak veri dizilerinin devam ettirilmesi mümkün kılınır.



Şekil 6. (a)Unutma kapısı (b)Alan gözetleme (c)LSTM bloğu

Şekil 6'da LSTM bloğu yer almaktadır. Burada yer alan gözetleme ve unutma kapısında unutma kapısı durumu sıfırlamak, gözetleme kapısı bağlantıları öğrenmeyi kolaylaştırmak için kullanılmaktadır (Gers vd., 1999; Gers ve Schmidhuber, 2000).

#### d) Kısıtlı Boltzmann Makinesi (RBM-Restricted Boltzmann Machine)


1987 yılında Hinton, Sejnowski ve Ackley tarafından yayınlanan "A Learning Algorithm for Boltzmann Machines" adlı makale ile öğrenme algoritmalarının prensipleri anlatılmıştır. Simetri prensibiyle hücreler arası bağlantılarla yenilemeli kısıtları yapmanın Boltzmann

Makinesi ile olabileceğini ortaya atmışlardır (Ackley vd., 1987).

1993 yılında Kappen yayınladığı "Olasılık Tahmininde Boltzmann Makinelerini Kullanmak: Sinir Ağı Öğrenimi için Genel Bir Yapı" başlıklı makalesinde, Boltzmann Perceptron modeli ile bir uygulama yapmıştır. Bu uygulamada bileşik olasılıksal dağılımları tahmin edebileceğini belirtmiştir (Kappen, 1994).

Sınıflandırma, regresyon ve özellik öğrenimi işlemlerini yapan boltzman makinesi giriş veri seti üzerinde olasılıksal dağılımları öğrenebilen bir sinir ağıdır. İki katmanlı bir yapıya sahiptir. Girdi(görünür) katman ve gizli katman. Örnek bir boltzman makinesi katman yapısı şekil 7'de yer almaktadır.


Her bir düğüm bir nörondur. Ve hesaplamalar bu düğümlerde yapılır. Her düğüm gizli katmanda yer alan bir başka düğümler (nöron) ile bağlanır. Aynı katmandaki düğümler birbirleriyle bağlanmazlar. Yani katmanlar arası iletişim yoktur. Bu yüzden kısıtlı boltzman makineleri olarak adlandırılır. Görünür katmanda girdiler hesaplanır ve bir sonraki düğüme o girdiyi iletilip iletilmeyeceği rastgele olarak belirlenir (Hinton, 2012).



Şekil 7.Kısıtlı Boltzmann Makinesi


### e) Derin İnanç Ağı (DBN-Deep Belief Network)

Hinton RBM'i kullanarak Derin İnanç Ağları (DBN) yığını oluşturmuş ve bu ağın eğitilip eğitilebileceğini göstermiştir. Derin inanç ağları veri setinin hiyerarşik temsilini çıkarmayı amaçlayan grafiksel modellerdir. Örnek bir makine yapısı, şekil 8'de gösterilmiştir. Şekilde görünür giriş katmanını  $h$  ise gizli katmanı temsil eder. Art arda eklenen kısıtlı boltzman makineleri katmanlarından oluşan bir sinir ağı yaklaşımıdır. Kısıtlı boltzman makinelerinin sırasıyla eğitilerek öğrenilmesiyle gerçekleşir. Giriş uygulanan veri ile gizli katman arasında olasılıksal bir dağılım modellenir (Hinton, 2006).



Şekil 8. Ard arda gelen kısıtlı boltzman makineleri örneği


Grafiksel model katmanından oluşan hem yönlendirilmiş hem de yönsüz kenarlı bir sinir ağı sınıfıdır (Boureau, 2008). Örüntü tanıma ve üretme konularında etkindir (Huang vd., 2007; Bengio vd., 2007). Denetimsiz ön tanımlı bir sinir ağıdır. Derin inanç ağı modeli örneği şekil 9'da görülmektedir.



Şekil 9. Derin inanç ağı modeli

### f) Derin Oto-kodlayıcılar (Auto Encoder)

Yapay sinir ağı modellerinden biri olan derin oto kodlayıcılar denetimsiz öğrenme tabanlı makine öğrenme sistemidir. Bu sinir ağı diablo ağı olarak adlandırılmaktadır (Bengio, 2009; Lu, 2013). Yıllarca sinir ağlarının temel bir parçası olmuştur (Hinton ve Zemel, 1994). Derin öğrenme mimarilerinin ortaya çıkmasıyla beraber derin öğrenme mimarileri içerisinde yer almaya başlamıştır (Baldi, 2012). Oto kodlayıcılar giriş veri kümesini sıkıştırarak en az kayıpla en iyi öğrenmeyi amaçlar. İleri beslemeli bir sinir ağıdır (Krizhevsky ve Hinton, 2011). Temel olarak 3 katmandan oluşmaktadır. Girdi katmanı, gizli katman ve çıktı katmanı. Giriş ve çıkış katmanındaki nöron sayıları eşit olmakla birlikte gizli katmandaki nöron sayısı değişkenlik göstermektedir. Şekil 10'de bu durum gösteren oto kodlayıcı görülmektedir. Gizli katman içerisindeki nöronların sayısı giriş ve çıkış katmanında yer alan nöronlardan daha az olduğunda veri kümesi sıkıştırılır. Böylelikle daha az veri ağ içerisinde yer alır. Bu da ağın performansında etkili olmaktadır (Vincent vd., 2010; Vincent vd., 2008).



Şekil 10. Oto Kodlayıcı şeması

### Derin öğrenme katmanları

#### Giriş (Input) Katmanı

Veri giriş katmanı olarak bilinmektedir. Sinir ağlarında oluşturulacak olan veri seti ağın mimarisine göre belirlenmesi gerekmektedir. Sinir ağına girecek olan her bir örneklem giriş katmanına ağın eğitimi için girdi verisi olarak




kullanılır. Her bir öğeye ait veri arka arkaya gelerek bir veriseti oluşturmaktadır. Bu verisetinin boyutu ağı hızını, test süresini ve bellek ihtiyacını artırmaktadır (Inik ve Ulker, 2017; Tamura vd., 1997).

### Konvolüsyon(Convolution) katmanı

Konvolüsyonel sinir ağlarının temelini oluşturan katmandır. Bu katmanda girdi verisi üzerinde daha önceden belirlenmiş bir filtrenin girdi verisi üzerinde gezdirilerek girdinin belirgin özelliklerinin ortaya çıkmasını amaçlamaktadır. Filtreleme sonucunda giriş verisinden daha küçük bir matris elde edilmesini sağlar (Ciresan vd., 2011).

Derin öğrenme algoritmalarında farklı boyutlarda filtrelemeler kullanılarak konvolüsyon yapılmıştır. AlexNet'te kullanılan 11x11 boyutunda matrisler yer almaktadır. ZfNet'te ise 7x7 filtreler kullanılmıştır. GoogleNet, VggNet, ResNet derin öğrenme mimarilerinde ise 5x5, 3x3, 2x2, 1x1 şeklinde filtrelemeler kullanılmıştır. NxN boyutundaki bir matrise MxM boyutunda bir matris uygulanmaktadır. Şekil 11'de konvolüsyon işlemi yer almaktadır.




Şekil 11.Konvolüsyon işlemi

Konvolüsyon işlemi derin konvolüsyon sinir ağlarının önemli bir parçasıdır. Bu katmanda yapılan filtreleme işlemi ile öğeye ait özellikler

ağa daha iyi şekilde yansımış olacaktır. Tercih edilecek olan filtre ağı eğitim sürecini ve başarısını doğrudan etkileyecektir (Pang vd., 2017).

### Aktivasyon (Relu) katmanı

Genellikle konvolüsyon katmanından sonra aktivasyon katmanı gelir. Aktivasyon fonksiyonu olarak simoid, hiperbolik tanjant, sinüs, step, eşik değer fonksiyonları kullanılmaktadır. Çok katmanlı yapay sinir ağları içerisinde doğrusal olmayan dönüşümler kullanılmaktadır. Pek çok aktivasyon fonksiyonu olmasına karşın derin öğrenme mimarilerinde Relu (Rectified Linear Unit) (Nair ve Hinton 2010)  $f(x) = \max(0, x)$  fonksiyonu kullanılmaktadır (Krizhevsky vd., 2012).



Şekil 12.Relu Aktivasyon fonksiyonu


Aktivasyon işlemi sonucunda elde edilen değer negatif ise 0 pozitif ise 1 değerini alır. Bu durum şekil 12'te gösterilmiştir (Jarrett vd., 2009).

### Havuzlama (Pooling) Katmanı

Daha çok relu katmanı sonrasında yer alan havuzlama katmanı verilerin indirgenerek ağda sonraki katman için giriş boyutunu azaltır. Havuzlama işlemi ile veri üzerinde kayıplar oluşmaktadır. Ancak ağda dolaşacak olan veri miktarındaki azalma ağı daha hızlı olmasını sağlamaktadır. Ağdaki veri miktarının azalması ağdaki hesaplama miktarlarının ve kullanılacak olan bellek miktarının da azalması anlamına gelmektedir (Hinton vd., 2012).

Havuzlama katmanında uygun bir filtre kullanılarak işlem yapılır. Kullanılacak olan


$N \times N$  boyutlu bir filtre veri havuzunda gezdirilerek matris içerisinde kalan uygun değerlerin bulunmasını sağlar. Değerin elde edilmesi için en çok kullanılan ortalama (average pooling) ve en büyük değer (max pooling) işlemleridir. En büyük değer havuzlamasında  $N \times N$  boyutlu matris içerisinde kalan en büyük değer oluşturulacak olan yeni veri matrisinin  $1 \times 1$  boyutundaki yeni değeri olur. Bu durum şekil 13'de gösterilmektedir (Zeiler ve Fergus, 2013). Ortalama havuzlamada ise  $N \times N$  boyutundaki matris içerisinde kalan tüm değerlerin ortalaması alınarak elde edilecek yeni veri matrisinin  $1 \times 1$  boyutundaki değerini içerir.



Şekil 13. En büyük değer havuzlama örneği

#### Tam Bağlı (Full-Connected) Katman


Bu katmandaki tüm nöronlar bir dizi şeklinde görünür. Katmandaki nöronların tamamı bu katmana bağlı önceki katmandaki aktivasyonların hepsine tam bağlı durumdadır. Tam bağlı katmanın özelliği önceki katmana bağlı olarak ortaya çıkar. Nesneyi belirleyecek olan özelliklerin hangi sınıfla ilişkili olduğu belirlenir. Bir örüntü ele alınacak olursa; örüntüdeki bir insanın tespit edilmesini sağlayan özellikler aktivasyon haritalarında yüksek değere sahip nöronlarda yer alacaktır. Bir tam bağlı katman bir sınıfla ilişki derecesi yüksek olan yüksek seviyeli özelliklere bakar. Bu özellikleri belirten ağırlıkların olduğu nöronlara bakılarak hangi sınıfa ait olduğu ortaya çıkmış olur (Lin vd., 2013; LeCun ve Bengio, 1995). Şekil 14'de tam bağlı katman yapısı örneği görülmektedir.



Şekil 14. Tam bağlı (full connected) katmanı

#### Dropout Katmanı

Çok katmanlı yapay sinir ağlarında sinir ağı eğitilirken aşırı öğrenme adı verilen ağı ezberlenmesi olayı gerçekleşir. Bu istenmeyen bir durumdur. Ağı ezberlenmesinin önüne geçmek için ağda ezber yapan bazı düğümlerin ortadan kaldırılmasıdır. Böylelikle ağı ezberlenmesi ortadan kaldırılmaya çalışılır (Srivastava vd., 2014). Dropout katmanı tam bağlı katmanlar için bir düzenleme katmanı olarak Hinton ve arkadaşları tarafından önerilmiştir. Dropout işlemi, sinir ağının düzenlenmesi yeteneğini artırdığı yapılan test performanslarıyla ortaya konmuştur (Hinton vd., 2012). Şekil 15'de çok katmanlı sinir ağı ve dropout yapılmış sinir ağı yapısı gösterilmektedir. Dropout işlemi yapılmış olan sağdaki şekilde bazı düğümler ortadan kaldırılmış olarak görülmektedir.



Şekil 15. (a)Yapay sinir ağı (b)Dropout uygulanmış sinir ağı (Çarpı atılmış nöronlar ağdan çıkarılmıştır)

### *Sınıflandırma (Classification) katmanı*

Tam bağlı katmandan sonra gelen sınıflandırma katmanı sınıflandırılması yapılacak öge sayısı kadar sonuç üretir. Bu sonuçların her biri bir sınıfı temsil eder. Son katman olarak bilinen sınıflandırıcı katman için farklı türde sınıflandırıcılar kullanılsa da genellikle softmax sınıflandırıcı kullanılır (Ciresan, 2001).

### *Yumuşatma (Softmax) Katmanı*

Sınıflandırma katmanı olarak yer alan softmax katmanı kendisinden önce gelen tam bağlı katmandan girdi verisini alır ve sınıflandırmak için kullanır. Olasılıksal bir girdi verisinin belirli bir sınıfa ait olma durumunu ortaya koyar. Hangi sınıfa daha yakın olduğuna dair değer üretir. Derin öğrenme ağı içerisinde üretilen olasılıksal hesaplama gerçekleştirerek her bir sınıf için olasılık değerini çıkarır. Bu işlemler için çapraz etnropi kullanılır (Tang, 2013).

### *Normalizasyon (Normalization) Katmanı*

Derin konvolüsyonel sinir ağlarının eğitilmesi hesapsal olarak ciddi bir süreç almaktadır. Eğitim süresinin azaltılmasının bir yolu nöronların aktivasyonlarını normalize etmektir. Normalizasyon katmanı geri beslemeli ağlarda gizli katmanlardaki durumları stabil hale getirmede oldukça etkilidir. Genellikle Relu katmanı sonrasında normalleştirme gerçekleştirilir (Li vd., 2015).

Normalizasyon ağın performansını etkilemektedir. Bu sebeple katmanlardan gelen veriler belirli bir düzen içerisinde olmalıdır. Girdi verileri çok büyük ya da çok küçük içerebilir. Bu değerlerin normalize edilerek belirli aralıkta kullanılması eğitim ve süreç açısından önemlidir. Girdi verilerinin normalize edilerek belirli aralıkta temsil edilmesi gereklidir (Ioffe ve Szegedy, 2015).

### **Derin Öğrenme Algoritmaları**


Gradyan temelli Konvolüsyonel sinir ağları kullanılarak 0'dan 9'a kadar olan el yazısı sayılarını öğrenerek sayıların sınıflandırılmasını sağlayan ilk temel derin öğrenme ağı LeNet'tir. 2006 yılında derin öğrenme yapısı gösterilmiş olsa da (Hinton, 2006) derin öğrenme daha çok ImageNet yarışması ile popüler hale gelmiştir. ImageNet tarafından yapılan yarışmada görüntü tanıma için algoritmalar ortaya konmuştur. Bu algoritmalarda derin öğrenme mimarileri ön plana çıkmıştır. Derin öğrenme mimarileri ile nesne tanımda ortaya çıkan sonuçlar oldukça başarılı sonuçlar vermiştir. Derin öğrenme mimarileri örüntü tanıma, tespit, sınıflandırmanın yanı sıra gelecek tahmini, ilaç üretim, sözlük, sinyal işleme, tıbbi pek çok alanda, finans sektöründe, savunma sanayinde kullanılmaktadır. Elde edilen sonuçlara bakıldığında derin öğrenme yapılarının bilinen pek çok yöntemden çok daha iyi sonuçlar verdiği ortaya konmuştur.

#### *a. LeNet*

LeCun tarafından hazırlanmış ilk konvolüsyonel yapay sinir ağı olarak bilinmektedir. LeCun banka çekleri üzerindeki sayıları tanımlamak için geliştirdikleri bu ağa LeNet adını vermiştir (LeCun vd., 1998). 0-9 arasındaki sayıları sınıflandırdığı için 10 sınıflı bir yumuşatma katmanı kullanılmaktadır. Bu ağ içerisinde Average pooling (ortalama havuzlama) kullanılmıştır.

LeNet mimarisi içerisinde tambağlı bir katman, relu(aktivasyon) katmanı, havuzlama katmanı, yumuşak bağlı katmanlardan oluşmaktadır.

Şekil 16'da LeNet mimarisinin yapısı görülmektedir. Burada bir dijit verisinin sınıflandırılması için bir mimari örneği gösterilmektedir. Giriş verisi 32x32 piksellik bir görüntüyü içermektedir.



Şekil 16. LeNet mimarisi


LeNet mimarisi MNIST veritabanını kullanarak rakamların tanınması için kullanılmıştır. LeNet mimarisi şekil 16’de gösterilmiştir.

#### b. AlexNet

2012 yılında yapılan 2012 ILSVRC ImageNet Büyük ölçekli görsel tanıma yarışmasında AlexNet (Krizhevsky vd. 2012) derin öğrenme mimarisi birinci olmuştur. Örüntü tanımda hata oranını %26’lardan %15’lere indirmişdir. Bu başarıyı AlexNet’in en çok bilinen derin öğrenme mimarilerinden biri haline getirmiştir.

Doğrusal olmayan fonksiyonlar için aktivasyon fonksiyonu (Relu) kullanıldı. Bu aktivasyon fonksiyonu klasik tanh fonksiyonundan daha hızlı olduğundan eğitim süresini kısaltmak için kullanılmıştır. Eğitim sürecinde aşırı öğrenme ve takılmaları önlemek için bırakma(dropout) katmanı kullanıldı. Ağırlık gecikmeleri ve momentum değerleri için gradyan iniş modeli kullanıldı. 25 katmandan oluşan AlexNet derin

öğrenme ağı içerisinde 5 temel konvolüsyon katmanı yer almaktadır. Genellikle her konvolüsyon katmanından sonra bir aktivasyon katmanı olan relu katmanı kullanılmaktadır. Bununla beraber giriş katmanı, normalizasyon katmanı, havuzlama(pooling) katmanı, dropout katmanı, tam bağlı(full-connected) katman, yumuşak bağlı (SoftMax) katman ve çıkış katmanı yer almaktadır (Iandola vd., 2016; You vd., 2017; Krizhevsky vd., 2012).



Şekil 17. AlexNet Mimarisi


AlexNet mimarisi şekil 17’de görülmektedir. Bu çok katmanlı yapıda her katmanın kendi işlemini yaptıktan sonra bir sonraki katmana verileri aktarması gerekmektedir. Giriş verisi ağ içerisinde aktarılırken katmanlar arasında veri miktarları oldukça fazladır. Normal bir işlemci

ile bu işlemlerin yürütülmesi oldukça zaman almaktadır. Bu işlem sürecini düşürmek için GPU'lar kullanılması daha fazla işlemin aynı anda yapılması anlamına geleceğinden, derin öğrenme mimarilerinde GPU (Grafical Processing Unit) grafik işlemcileri kullanılmaktadır (Krizhevsky vd., 2012).

### c. ZF Net

Derin öğrenme mimarileri AlexNet ile popüler hale gelmeye başlamış ve 2012 yılından itibaren farklı mimariler ortaya çıkmaya başlamıştır. Matthew Zeiler ve Rob Fergus 2013 ILSVRC ImageNet yarışması için ZFNet adında bir mimari geliştirmiş ve bu yarışmada elde ettiği %11.2 hata oranı ile yarışmayı kazanmıştır.

Şekil 18'de yer alan ZFNet; AlexNet mimarisinin üzerinde değişiklikler yapılarak ortaya çıkan bir mimari yapısı vardır. AlexNet'te giriş katmanında bulunan konvolüsyon işlemi için 11x11 filtre kullanılırken ZFNet'te kullanılan filtre 7x7 matrislidir. Aktivasyon için RELUs fonksiyonu, eğitim için gradyan iniş, hata kaybı için çarpaz entropi kaybı kullanılmıştır. ZFNet mimarisinde Deconvolutional Network adında bir görselleştirme tekniği geliştirilmiştir. Bu teknik ile mimariye farklı bir boyut getirilmiş ve derin öğrenme mimarisini daha başarılı bir noktaya taşımıştır (Zeiler ve Fergus, 2013).



Şekil 18.ZFNet mimarisi

### d. VggNet

2014 yılında geliştirilen bir derin öğrenme modelidir. ImageNet 2014 yarışmasında %7.3 hata oranı ile oldukça başarılı bir performans sergilemiştir. Simonyan ve Zisserman tarafından oxford üniversitesinde tasarlanan bu mimari 6 farklı mimari ortaya koymuşlardır. Bu 6 farklı modelde 11, 13, 16, 19 konvolüsyon katmanlıdan oluşmaktadır (Simonyan ve Zisserman, 2015).

Önceki derin öğrenme mimarilerinde yer alan konvolüsyonlardan farklı olarak burada 2x2 ve 3x3'lük filtreler uygulanmıştır. Tablo 2'de bu filtreler gösterilmiştir.

**Tablo2.** VggNet model yapısı

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64 <b>conv3-64</b>	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 <b>conv3-128</b>	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256	conv3-256	conv3-256	conv3-256 <b>conv1-256</b>	conv3-256 <b>conv3-256</b>	conv3-256 conv1-256 <b>conv1-256</b>
conv3-256	conv3-256	conv3-256	conv3-256	conv3-256	conv3-256
maxpool					
conv3-512	conv3-512	conv3-512	conv3-512 <b>conv1-512</b>	conv3-512 <b>conv3-512</b>	conv3-512 conv3-512 <b>conv3-512</b>
conv3-512	conv3-512	conv3-512	conv3-512	conv3-512	conv3-512
maxpool					
conv3-512	conv3-512	conv3-512	conv3-512 <b>conv1-512</b>	conv3-512 <b>conv3-512</b>	conv3-512 conv3-512 <b>conv3-512</b>
conv3-512	conv3-512	conv3-512	conv3-512	conv3-512	conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

**Tablo3.** VGGNet tek bir test ölçeğinde hata oranları

VggNet Modeli (Tablo2)	smallest image side		top-1 valerror (%)	top-5 valerror (%)
	train (S)	test (Q)		
A	256	256	29.6	10.4
A-LRN	256	256	29.7	10.5
B	256	256	28.7	9.9
	256	256	28.1	9.4
C	384	384	28.1	9.3
	[256;512]	384	27.3	8.8
D	256	56	27.0	8.8
	384	384	26.8	8.7
	[256; 512]	84	25.6	8.1
C	256	256	27.3	9.0
	384	384	26.9	8.7
	[256; 512]	384	25.5	8.0

Bu mimaride art arda bağlı bulunan 3 tam bağlı(FC-FullConnected) katman yer almaktadır. Son tam bağlı katmanda 1000 nöron yer almakta olup çıkış için üretilecek sınıflandırma katmanında ise yumuşak bağlı(SoftMax) katmanı bulunmaktadır. Tablo 2’de yer alan modellerin elde etmiş oldukları hata oranları Tablo 3’te verilmiştir.

Bu modellerden Vgg-16(Han vd., 2015; Ren vd., 2015) ve Vgg-19 (Gatys vd., 2015) modelleri literatürde daha fazla yer almaktadır.


#### e. GoogleNet

2014 yılında yapılan ILSVRC yarışmasının galibi olmuştur. GoogleNet (Inception) (Szegedy vd, 2015) kompleks bir yapısı vardır. %5.7 gibi düşük bir hata oranı ile yüksek bir başarımla elde etmiştir. 22 katman derinliğe sahip olup GoogleNet 144 katmandan oluşan bir yapıya sahiptir. Inception modülü ile farklı boyutlarda filtreleme yaparak daha önce ortaya çıkan derin öğrenme mimarilerinden farklı bir oluşum ortaya koymuştur. Şekil 19’de GoogleNet naive ve inception modülü yer almaktadır.

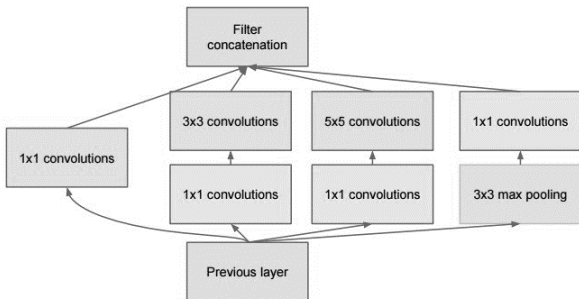
Inception modülü ile birlikte farklı boyutlarda filtrelemeler yapılmıştır. Bu filtrelemeler boyut azaltmak için kullanılan filtrelerdir. AlexNetten 12 kat daha az parametre içermektedir. Kullanılan katman sayısı bağımsız yapı taşlarına göre farklılık gösterebilmektedir.

Inception modülünde yer alan filtre elemanları 1x1, 3x3, 5x5 şeklindedir. Diğer derin öğrenme mimarilerinde yer alan art arda yer alan katmansal yapıdan farklılaşarak derinlikli bir yapı oluşturulmuştur. Bu derinliği oluşturan modüler bir filtreleme mantığı getirilmiştir.

GoogleNet mimari yapısı Şekil 20’de gösterilmiştir.

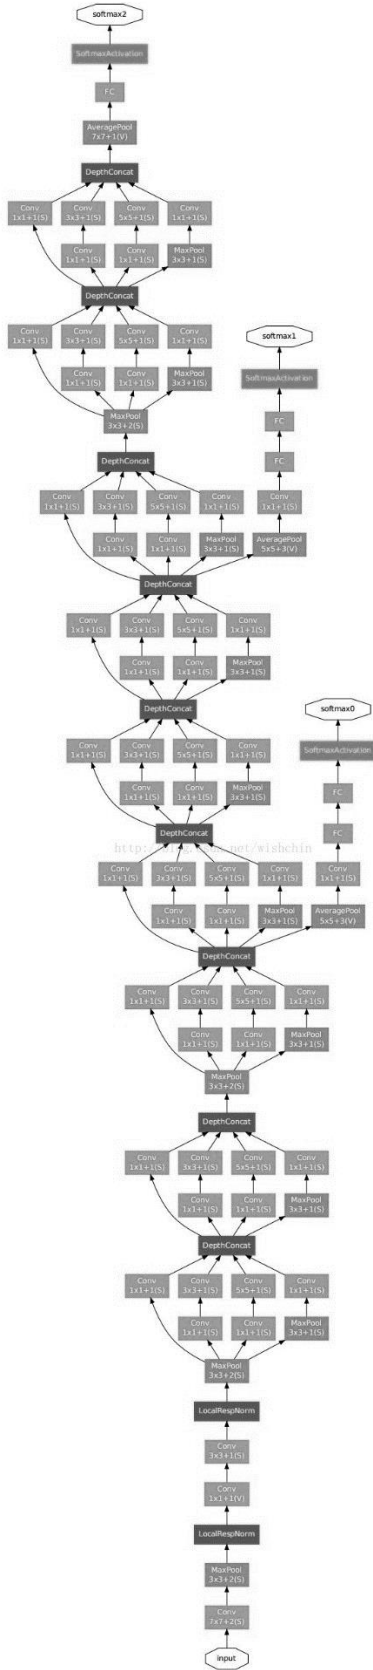


*Naive Modülü*



*Inception Modülü*

*Şekil 19. GoogleNet inception boyut azaltma modülü*




Şekil 20. GoogleNet mimarisi

f. ResNet

Microsoft Resnet 2015 yılında gerçekleştirilen ILSVRC ImageNet yarışması kazananı olmuştur. Bu yarışmada %3.6 gibi bir hata oranı yakalamıştır. İnsanlar ortalama %5-%10 hata oranı ile görüntüyü sınıflandırırken %3.6'lık bir hata oranı insandan daha iyi görsel tanıma yaptığını göstermiştir. Daha önceki mimarilerin üzerinde bir derinliğe sahip olan bu mimarinin katman sayısı diğer derin öğrenme mimarilerindeki katman sayılarından fazladır (Russakovsky, 2015).


Microsoft ResNet mimarisinde iki RELU ile doğrusal katman arasında bir kez kalıntı değeri (Residual Value) beslenen bir bloktan (Residual Block) oluşturulmuştur. Bu yapı ile öğrenme daha hızlı şekilde gerçekleşeceği düşünülmüştür. Şekil 21'de bu kalıntı modülü görülmektedir (He vd., 2016).



Şekil 21. ResNet kalıntı modülü

Resnet 152 katmandan oluşan bir mimaridir. Şekil 22'te örnek Resnet mimarisi görülmektedir.





Şekil 22. Resnet Mimarisi

Tablo 4. Derin öğrenme algoritmaları

Yıl	Derin öğrenme Algoritması	Geliştirici	Hata Oranı	Parametre sayısı
1998	LeNet	Yann LeCun ve ark		60 Bin
2012	AlexNET	Alex Krizhevsky, Geoffrey Hinton, Ilya Sutskever	% 15.3	60 Mil.
2013	ZFNet	Matthew Zeiler ve Rob Fergus	% 14.8	
2014	GoogLeNet	Google	% 6.67	4 Mil.
2014	VGG Net	Simonyan, Zisserman	% 7.3	138 Mil.
2015	ResNet	Kaiming He	% 3.6	

Tablo 4’te derin öğrenme algoritmalarının ortaya çıkış tarihleri parametre sayıları ve hata oranları yer almaktadır.

## Derin Öğrenme Kütüphaneleri


### a. TensorFlow

2011 yılında TensorFlow Google araştırma ekibi olan Google Brain tarafından geliştirilen bir derin öğrenme kütüphanesidir. Bu grup ilk olarak DistBelief makine sistemini oluşturmuşlardır (Abadi vd., 2016).

DistBelief ile öğretmensiz öğrenme, dil çevrimi (Mikolov vd., 2013; Vinyals vd., 2015), görüntü sınıflandırması ve nesne tespiti (Frome vd., 2013), video sınıflandırması (Karpathy vd., 2014), konuşma tanıma (Hinton vd., 2012; Zeiler vd., 2013), dizi tahmini (Sutskever, 2014), yaya saptama (Angelova vd, 2015), takviyeli öğrenme (Nair vd, 2015) gibi pek çok çalışmada kullanılmıştır.

Daha sonra makine öğrenimini daha etkin hale getirebilecek için ikinci nesil derin öğrenme kütüphanesi olan TensorFlow’u geliştirmişlerdir. Bu kütüphanedeki yapıda temel olarak bir dizi hesaplamalardan oluşan veri akış grafiklerinden oluşmaktadır. Bu akış grafikleri düğümlerin durumunu korumak, güncellemek için dallanma

ve döngü kontrolüne izin veren bir veri akışı hesaplamasını sunar. Her bir düğüm 0 veya daha fazla girişe ve 0 veya daha fazla çıkışa sahip olan işlem örneği gösterir. Şekil 23'te görülmektedir.




Şekil 23. Örnek bir akış grafiği

Açık kaynaklı yapısı ile geniş çaplı şekilde kullanılması amaçlanmıştır. Mobil cihazlar, tabletler, telefonlar, büyük ölçekli dağıtık sistemlerde, GPU kartları gibi pek çok hesaplama aygıtlarında herhangi bir değişiklik yapılmaksızın kullanılabilmesi mümkündür (Abadi vd., 2016).

#### b. Caffe

Berkley üniversitesinde geliştirilmiş olan Caffe (Convolution Architecture For Feature Extraction) açık kaynak kodlu bir derin öğrenme kütüphanesidir. Bununla beraber GPU kullanımına olanak verir. Ve açık kaynak kodlu olması sebebiyle ticari kullanıma olanak veren bir imkan sunar.

CaffeNet'te konvülyasyon, havuzlama, iç-gizli katmanlar, relu, normalizasyon, elemanlı işlemler, softmax ve hinge gibi bir dizi katman tipi sunmaktadır (Jia vd., 2014). Şekil 24'te bir CafeNet örneği gösterilmektedir.



Şekil 24. MNIST veritabanı sınıflandırmasını yapan bir cafe modeli

C++, CUDA, Python, Matlab yazılımlarında yer alan bir derin öğrenme kütüphanesidir. Model Zoo adında önceden eğitilmiş kütüphaneleri mevcuttur.

#### c. Theano

Makine öğrenim algoritmalarının verimli ve hızlı şekilde gelişimini desteklemek için LISA laboratuvarlarında yazılmıştır. Theano, bir yunan

matematikçisinden adını almıştır. Çok boyutlu matrisleri barındıran matematiksel ifadelerin optimize edilmesi ve verimli şekilde kullanılmasını sağlayan bir Python kütüphanesidir. Açık kaynak kodludur. Yapay sinir ağı sınıfları yerine sınıf oluşturmayı gösteren derin öğrenme öğreticisi mevcuttur (The Theano Development Team, 2016; Bastien vd., 2012).

*d. Torch*

Ronan Collobert ve arkadaşları tarafından derin öğrenme ve makine öğrenmesine destek olmak için geliştirilmiş açık kaynak kodlu bir kütüphanedir. Birkaç satır kod ile çok kolay şekilde derin öğrenme yapısı oluşturulabilmektedir. Sayısal optimizasyon yapılması mümkündür (Collobert vd., 2011). Açık kaynak kodlu olması sebebiyle ticari olarak kullanılabilir. Bunlara örnek olarak Facebook, twitter, Google DeepMind verilebilir. Pek çok üniversite ve araştırma merkezleri tarafından kullanılmaktadır.

*e. DeepLearning4j*

Derin öğrenme kütüphanelerinden biri olan DeepLearning4j(DL4J) Java ve Scala için yazılan açık kaynak kodları verilen bir derin öğrenme kütüphanesini içerir (Team D.J.D. 2016). Matlab, Python, C++ gibi dillerde yazılanların aksine java ortamında yer almaktadır. Pek çok derin öğrenme mimarilerine alternatif bir dil ile makine öğrenimine destek verir. Dağıtık CPU ve GPU platformlarında kullanılmak üzere tasarlanmıştır (Kochura vd., 2017).

*f. Keras*

Phyton dilinde yazılmış Theano ve TensorFlow için kullanılan bir kütüphanedir. Google yazılım mühendisi Francois Chollet tarafından yazılmıştır. Keras gelişmiş algoritmaları optimize eder, normalleştirme rutinleri ile destekleyen, aktivasyon fonksiyonları olan en iyi

seçim olanakları sunar. TensorFlow ve Theano desteklese de giriş verilerinin boyutları farklıdır bu yüzden her iki kütüphane içinde arka uçta çalışabilmesi için dikkatli şekilde tasarlanmalıdır (Chollet, 2016).

*g. Lasagne*

Python da yazılan ve Theano tepesini oluşturmak için geliştirilen bir kütüphanedir. Keras'a alternatif olarak geliştirilmiş bir kütüphanedir. Theano kütüphanesini kullanımını daha kolay hale getirmek için hazırlanmıştır. Performansı Theano ile aynıdır (Jones, 2015).

*h. Cognitive Network Toolkit (CNTK)*

Microsoft tarafından derin öğrenmeyi destekleyen Visual Studio da kullanılan açık kaynaklı kütüphanedir. İleri beslemeli derin sinir ağları, konvolüsyonel sinir ağları, tekrarlayan sinir ağları gibi çok bilinen ağ modellerinin kolayca gerçekleştirilmesini sağlar (Yu vd., 2014).

*i. DIGIT*


Nvidia firması tarafından geliştirilmiştir. Derin öğrenme ağlarını geliştirmek için oluşturulan web tabanlı bir araçtır. Bir metin dosyası kullanır. Bu metin dosyası ağı oluşturulması için parametrelerin tanımlanması için kullanılır. Bir programlama dili yoktur. Ağ görselleştirme aracına sahiptir. Öğrenme sürecini görselleştirir. Metin dosyasındaki hataları kolayca ortaya çıkarır. GPU desteği sağlar (Nvidia, 2016).

*j. Pylearn2*

Montreal üniversitesi LISA laboratuvarında geliştirilen makine öğrenme kütüphanesidir. Makine öğrenme algoritmalarının yanı sıra Pythonda yazılan derin öğrenme koleksiyonu sunar. Bu kütüphane ile genişletilebilirlik ve esnekliğe odaklanılmıştır. Hedef kullanıcıları makine öğrenimi üzerine çalışmalar yapan kişilerdir (Goodfellow vd., 2013).

### k. MXNET

MXNet, polyglot (çoklu dil) bir yapıya sahiptir. Farklı dilleri destekliyor olması derin öğrenme konusunda uğraşanlar için oldukça cezbedici bir durum oluşturmaktadır. Dağıtık durumda bulunan işlemci desteği vardır. Çoklu işlemci ya da çoklu Gpu desteği vardır. Veri akış grafikleri üzerine kuruludur. Kendi belleğini yönetir ve yeniden konumlandırabilir. Python, R, Julia, Go, Javascript gibi dilleri desteklemektedir. Mobil olarakta kullanılabilir. MXNet desteklediği yapılar-mimariler şekil 25’de yer almaktadır.



Şekil 25. MXNET mimarisi

## Uygulama ve Başarımlar

### Derin Öğrenmenin Uygulama Alanları

#### a. Bilgisayar Görmesi (Computer Vision)

2015 yılında yayınlanan bir makalede bilgisayar görmesi ile konuşma sesleri birleştirilerek belirli bir videoya başka bir konuşmayı benzer bir yüz ve mimik hareketleriyle birleştirip söyleten bir tekrarlayan sinir ağları (RNN) uygulaması gerçekleştirilmiştir. Bu uygulamada Amerika birleşik devletleri eski başkanı Barack Obama’nın bir video görüntüsü alınıp daha önce yapmış olduğu farklı konuşmaları bu video görüntüsüne adapte etmişlerdir (Suwajanakorn vd., 2015). Iizuka, Simo-Serra, Ishikawa tarafından gerçekleştirilen çalışmada gri tonlamalı siyah beyaz görüntülerin başarılı şekilde renklendirilmesi sağlanmıştır. Bu çalışma konvolüsyonel sinir ağlarına dayanan

derin öğrenme algoritmalarına ek olarak bir füzyon katmanı kullanılmıştır. Genel ve bölgesel öncelikler içeren tüm çerçeveler uçtan uca doğru eğitilmiştir. Bu modelin eğitilmesi için geniş bir sahne sınıflandırma veritabanı kullanılmıştır. Yapılan çalışmada yüzlerce yıl öncesine ait görüntülerin otomatik olarak renklendirilmesi sağlanmıştır. Derin öğrenme ağları tarafından gerçekleştirilen bu çalışma kendisine verilen kalıpları öğrenir. Örneğin deniz mavidir, gökyüzü mavidir, bulutlar beyaz-gridir. Yapılan bu çalışmada gri renkli görüntüleri renklendirmek için farklı sonuçlar ortaya çıkabilmekte. Ancak bu insan tarafından da fark edilmesi pek mümkün değildir. Aynı resim için farklı renklendirmeler sunabilir. Ancak insan hangisinin gerçek olduğunu pek ayırt edemez (Iizuka, 2016). Derin öğrenme ile siyah beyaz görüntülerin renklendirilmesi için yapılmış farklı çalışmalarda literatürde yer almaktadır (Zang vd., 20016; Cheng vd., 2015; Larsson vd., 2016). Google Brain araştırmacılarından Dahl, Norouzi ve Shlens tarafından yapılan çalışmada çok düşük çözünürlüklü yüz görüntülerinden yola çıkarak bu yüzün nasıl göründüğünü bulmaya çalışan derin öğrenme tabanlı bir uygulama gerçekleştirmişlerdir. Video görüntülerinde yer alan insan yüzlerinin çok düşük çözünürlüklü olması sebebiyle seçilemiyor olması ve yüzün net şekilde görüntülenmemesinden dolayı bu durumu ortadan kaldıracak bir uygulama gerçekleştirmişlerdir. Düşük çözünürlük yüz görüntülerinin yüksek çözünürlüklü yüz görüntülerine çevrilmesi için olasılıksal derin öğrenme mimarileri kullanılmıştır (Dahl vd., 2017). Bilgisayar görmesi ile yapılan bir başka çalışmada animatörlere yardımcı olabileceği düşünülen insan hareketlerinin iskelet yapısını derin öğrenme yoluyla ortaya çıkarılmaya çalışılmıştır. Gerçek zamanlı video görüntülerinde pek çok insanın yer aldığı ortamda her insanın o anki iskelet yapısı insan üzerinde gösterilmiştir (Cao vd., 2017). Bilgisayar görmesinin sonucunda görüntünün yorumlanmasına yönelik yapılan bir çalışmada bir görüntüdeki pek çok alanın belirlenmesi ve bu alanlarda neler olduğunun tanımlanarak cümle

yazılması için derin öğrenme yapıları kullanılmıştır. Görüntülerin sınıflandırılması için konvolüsyonel sinir ağı bu sınıfların tanımlanarak cümle yapılarının oluşturulması için tekrarlayan sinir ağları kullanılmıştır (Karpathy ve Fei-Fei, 2015). Nguyen ve arkadaşları yapmış oldukları çalışmada derin öğrenme kullanılarak bir fotoğraftan yeni fotoğraflar oluşturmaya çalışmışlardır. Bu çalışmada bir görüntü içerisinde daha önceden yer almayan bir nesneyle nasıl oluşturulduğu gösterilmiştir (Nguyen vd., 2017). Isola ve arkadaşları haritalanmış bir görüntüden renklendirilmiş ve tamamlanmış yeni bir görüntü elde etmek için derin öğrenme ağlarını kullanmışlardır. Yapmış oldukları çalışmada pix2pix yazılımında bu derin öğrenme yaklaşımı kullanılmıştır (Isola vd., 2017).

#### b. Sınıflandırma (Classification)

Görüntü sınıflandırma ile yapılmış pek çok çalışma vardır. Sınıflandırma için kullanılan derin öğrenme algoritması ve yöntemleri başarı oranlarında kısmi farklılıklar oluşturmaktadır. Kullanılan farklı yöntemler sınıflandırma başarımına katkı sağlamışlardır. Trafik işaretlerinin sınıflandırılması (Ciregan vd., 2012), uydu görüntülerinin sınıflandırılması (Doğan ve Türkoğlu, 2017; Hu vd., 2015; Zou vd., 2015), yüz tanıma-sınıflandırma (Chan vd., 2015; Parkhi vd., 2015; Sun vd., 2014; Sun vd., 2015), hiperspektral verilerin sınıflandırılması (Chen vd., 2014; Zhao vd., 2016), üç boyutlu görüntülerin sınıflandırılması (Glorot vd., 2011; Qi vd., 2017), Kolon kanseri görüntülerinin sınıflandırılması (Sirinukunwattana vd., 2016), elektrodiyagram sinyallerinin sınıflandırılması (Al Rahhal vd., 2016), Toprak örtüsü ve mahsul türlerinin sınıflandırılması (Kussul vd., 2017), göğüs röntgenlerinin sınıflandırılması (Baltruschat vd., 2018), kötücül yazılımların sınıflandırılması (Dahl vd., 2013), arazi kullanımının sınıflandırılması (Luus vd., 2015), cilt kanserlerinin sınıflandırılması (Esteva, 2017), insan hücrelerinin sınıflandırılması (Chen vd., 2016), ses kayıtlarından sosyal sinyallerin

sınıflandırılması (Brueckner ve Schuler, 2014), gen verilerinden kanser sınıflandırma (Fakoor vd., 2011), cümle düzeyinde sınıflandırma (Kim, 2014), hafif bilişsel bozulma ve alzheimer hastalıklarının sınıflandırılması (Suk ve Shen, 2013), twitter'da duygu sınıflandırılması (Tang, 2014), derin inanç ağları ile ses verilerin sınıflandırılması (Lee vd., 2009), doku tabanlı medikal görüntü sınıflandırılması (Murugappan ve Sabeenian, 2017), tomografi görüntülerinden akciğer keseciklerinin sınıflandırılması (Hua vd., 2015), EEG verilerinin sınıflandırılması (An vd., 2014), video sınıflandırma (Ng vd., 2015), hastalık durumlarının sınıflandırılması (Tamilselvan ve Wang, 2013), iyi ve kötü huylu memem tümörlerinin sınıflandırılması (Zhang vd., 2016), çevresel seslerin sınıflandırılması (Piczak vd., 2015), proteinlerin sınıflandırılması (Asgari ve Mofrad, 2015) gibi derin öğrenme ile daha pek çok sınıflandırma çalışmaları yapılmıştır.

#### c. Nesne Tespiti (Object Detection)

Görüntü sınıflandırma ve nesne tespiti benzer bir yapıda gibi görünse de birbirinden farklıdır. Sınıflandırmada elde bulunan etiketlere göre görüntüler bir sınıfa alınır. Nesne tespitinde ise bir görüntü içerisinde bir nesne aranır. Bu nesne görüntü içerisinde nerede olduğu tahmin edilir (Guo vd., 2016). Yapılan bir çalışmada AlexNet mimarisinin son katmanı değiştirilerek DetectorNet adı verilen bir algoritma sunulmuştur. Bu çalışmanın gayet iyi sonuçlar ortaya koyduğu belirtilmiştir. Aynı çalışmada görüntüde aynı nesneden birden fazla tespit edilmesine olanak veren bir derin öğrenme mimarisi de DeepMultiBox sunulmuştur (Erhan vd., 2014). Daha sonra Girshick ve arkadaşları tarafından RCNN mimarisi önerilmiştir (Girshick vd., 2014). Bu yaklaşımda arama için nesne seçici kullanılır. Her seçim için konvolüsyonel sinir ağı özellikleri ayıklanır. Belirlenen aday nesne penceresi içerisinde nesnenin varlığının var olup olmadığına bakılır ve SVM sınıflandırıcı ile sınıflandırılır (Girshick, 2015). Bu algoritma ile bazı çalışmalar yapılmış

ve pek çok algoritma için temel oluşturmuştur (Zhu vd., 2015; Zhang vd., 2015). Nesne tespitinin daha hızlı şekilde gerçekleştirilmesi için yapılan bir çalışmada F-RCNN (Fast-Reccurent Convolution Neural Network - Hızlı tekrarlayan konvolüsyonel sinir ağı) (Ren vd., 2015). Nesne tespiti algoritmalarında daha çok nesnenin yerinin belirlenmesi konusunda çalışmalar yapılmıştır. Bunun için seçici arama, bağımsız nesne önerileri, kenar kutu belirleyici v.b. gibi pek çok yöntem geliştirilmiştir (Alexe vd., 2012; Uijlings vd., 2013; Zitnick vd., 2014; Cheng vd., 2014). Cruz-Roa ve arkadaşları bir tür deri kanseri bazal hücreli kanser tespiti için deri histopathology görüntülerinden kanserin tespit edilmesi için bir yöntem sunmuşlardır. Kanseri bölgenin tespit edilmesi, sınıflandırılması ve yorumlanması yapılmaktadır (Cruz-Roa vd., 2013). Başka bir çalışmada bir görüntü içerisinde yüz tespiti için yeni bir derin öğrenme yapısı önermişlerdir. Diğer yüz tespit yapılarından daha üstün bir performans sergilemişlerdir (Yang vd., 2015). Yayaların tespiti için yapılan bir çalışmada özellik çıkarımı, bozulma, oklüzyon ve sınıflandırma işlemlerinin bir arada kullanılabileceği bir derin öğrenme yapısı önerilmiştir (Ouyang vd., 2013). Chen ve arkadaşları uzaktan algılama ile elde edilen görüntülerden uçak tespit için bir yöntem önermişlerdir. Değişken boyutlar, renkler, karmaşık arkaplanlar nedeniyle yer yüzeyi üzerindeki nesnenin tespiti oldukça zordur. Bu çalışma geometrik merkezini, yönünü, konumunu çıkararak nesneyi tam olarak konumlandıran etkili bir uçak tespit yöntemi önerilmiştir. Derin inanç ağları kullanılarak iyi bir performans alınmıştır (Chen vd., 2013). Uzaktan algılama ile yapılan uçak, bina, hava alanı, araç gibi pek çok nesne tespiti çalışmaları yapılmıştır (Chen vd., 2016; Zhang vd., 2016; Vakalopoulou vd., 2015; Diao vd., 2015; Cheng ve Han, 2015).

#### d. Ses (Audi-Wave-Speech)

Google 2016 yılında ham ses verilerini oluşturmak için WaveNet'i tanıtmışlardır. Bu model olasılıksal ve otoregresif bir yapıya

sahipti. Metin konuşması uygulamalarında İngilizce ve çince olarak dönüştürme olanağı vermektedir (Oord vd., 2016). Ayrıca Baidu araştırmacıları tarafından ses için Deep Speech adında bir derin öğrenme mimarisi oluşturuldu. Deep Speech uçtan uca konuşma tanıma sistemidir. Gürültülü ortamlarda bile gayet iyi çalışmaktadır (Hannun, 2014). Video görüntülerinde yer alan nesnelere vurulduğunda ya da çizildiğinde bazı sesler çıkarmaktadır. Bu sesler nesnenin fiziksel olarak nasıl olduğu ve buna göre nasıl bir ses çıkaracağını ortaya koyar. Owens ve arkadaşları bir video sahnesinde oluşabilecek seslerin tahmin edilip bu seslerin çıkarılmasını sağlayacak bir derin öğrenme ağı sunmuşlardır. Buna örnek olarak bir davula vuran insanların sessiz videosu ile ses verilerinin sentezlenerek oluşturulacak bir örnek sunmaktadır (Owens vd., 2016). Assael ve arkadaşları bir konuşmacının ağzın hareketlerinden ne söylediğini ortaya çıkaran Lipreading yaklaşımını derin öğrenme mimarileri kullanarak LipNet'i sunmuşlardır. LipNet ile bir video görüntüsü üzerinden ağız hareketlerini çözmek için uzaysal eşzamanlı konvolüsyonel sinir ağı ve tekrarlayan sinir ağlarını kullanarak çözmeye çalışmışlardır. Cümle düzeyinde daha önce yapılan çalışmalardan daha iyi sonuçlar ortaya çıkarmıştır (Assael vd., 2016). Salamon ve Bello çevresel ses verilerini alarak derin öğrenme mimarileri ile sınıflandırma yöntemini sunmuşlardır. Bu kısa ses verileri için 10 farklı sınıf kullanmışlardır. Bunlar klima, araba korna, oynayan çocuklar, köpek havlaması, sondaj, araç motoru, silah sesi, çekiç, siren ve sokak müziği (Salamon ve Bello, 2017). Chamberlain ve arkadaşları basit bir stetoskop yardımı ile akciğer seslerini alarak sesleri analiz etmişlerdir. Farklı türde hasta ve sağlık kişilerden alınan bu ses verilerini derin öğrenme mimarileri ile değerlendirmişlerdir. Takviyeli öğrenme ile kullanılan bu ses verilerini sınıflandırmışlardır (Chamberlain vd., 2016). Fried ve Fiebrink çarpaz eşleşmeli ses haritalarını oluşturacak bir derin öğrenme yöntemi sunmuşlardır. Sesin tanımlanarak buna karşılık gelen görüntü

haritasının çıkarılması amaçlanmıştır. Sese karşılık gelen en uygun görüntü çarpaz eşleştirilmesi yapılmaya çalışılmıştır. Bu çalışmada derin öğrenme mimarilerinden oto kodlayıcılar kullanılmıştır (Fried ve Fiebrink, 2013). Bir başka çalışmada çevresel seslerin saptanması için derin öğrenme mimarileri kullanılmış ve bu mimarilerin başarımları karşılaştırılmıştır (Li vd., 2017). Döner makina parçalarından olan rulman pek çok makina için önem arz etmektedir. Lui ve arkadaşları bu makinalarda oluşan hataların tespit edilmesi için bir çalışma sunmuşlardır. Burada rulman makinalarından gelen 1 dakikalık sesleri alarak kısa zamanlı fourier dönüşümü uygulamış daha sonra derin öğrenme ağlarıyla hataları tespit etmeye çalışmışlardır. Hataların çıkarılması için Oto kodlayıcıları kullanmışlardır (Lui vd., 2016). Bunlar dışında derin öğrenme ile ses sinyalleri üzerine yapılmış pek çok çalışma vardır (Hinton vd., 2012; Graves vd., 2013)

#### e. *Medikal (Medical)*

Derin öğrenme çalışmaları ile insan sağlığını doğrudan etkileyecek pek çok yaklaşımlar ortaya konmuştur. İnsan sağlığı için önem taşıyan pek çok bulgular, sınıflandırma, tespit, resim bölütleme, görüntü üretimi gibi pek çok işlemlerde kullanılmakta. Bu işlemleri daha çok sinir sistemleri, akciğer, göz, patolojik görüntüler, hücreler, göğüs, kalp, karın, kas sistemleri üzerine yapılmıştır.

Bir çalışmada diz kireçlenmesi oranının, derin konvolüsyonel sinir ağlarını kullanarak radyolojik görüntülerden otomatik olarak ölçmeye çalışan bir yöntem üzerine çalışılmıştır. Bu uygulama için AlexNet ve VGG-16 derin öğrenme algoritmalarından faydalanılmıştır. Başarım oranını artırmak için kendi önerdikleri özellik çıkarım yöntemini kullanmışlardır (Antony vd., 2016). Plis ve arkadaşları MR görüntüleri kullanılarak Şizofreni ve Huntington hastalığının derin inanç ağları ile sınıflandırılması için bir çalışma yapmışlardır (Plis vd., 2014). Sarraf ve Tofighi fMRI görüntülerinden LeNet-5 derin öğrenme

mimarisi kullanarak alzaimer hastalığının sınıflandırmıştır (Sarraf ve Tofighi, 2016). İnsan beyninin mr görüntülerini anatomik bölgelere ayırmak için bir yaklaşım ortaya konmuştur. Bu yaklaşımda her vokselin (her pixelin 3 boyutlu görünümü) beyin mr görüntüsüne aktaran bir derin öğrenme mimarisi sunulmuştur. Bu bölütleme yöntemi daha önceki bölütleme yöntemlerinden daha iyi çalıştığı söylenmiştir (de Brébisson ve Montana, 2015). Yapılan bir başka çalışmada erken doğan bebeklerin beyin ağlarının bilişsel ve motor gelişimlerinin tahminlerinin yapılması üzerine olmuştur. Burada 27 ve 46. haftalar arasındaki çocukların gelişimi izlenerek sonraki süreçlerin nasıl olacağı tahmin edilmesi üzerine BrainNetCNN adında bir sinir ağı önerilmiştir (Kawahara vd., 2017). Derin öğrenme algoritmaları ile Multipl Sklerozun Belirtileri Olan Hastalarda Gelecekteki Hastalık Aktivitesini Tahmin Etmek için yapılan bir çalışmada beyin görüntülerinden faydalanılmıştır. Önerilen yöntem hastalığın ataklarının daha önceden tahmin edilmesini sağlamaktır (Yoo vd., 2016). Bir başka çalışmada, Difüzyon MR görüntüleri alınırken geçen yoğun sürenin indirgenmesi için bir yöntem önerilmektedir. Görüntü alma süresi optimize edilerek görüntü alım süresini 12 kat azaltmıştır (Golkov vd., 2016). Başka bir görüntü bölütleme çalışmasında özellikle beyin tümörleri ile MS lezyonlarının bölütlenmesinde oldukça iyi sonuçlar vermektedir (Havaei vd., 2016). Retina damarlarının segmentasyonuna ilişkin başarımının iyileştirilmesi için bir derin öğrenme çalışması yapılmıştır. Burada retina görüntüsünden elde edilen yetersiz damar görüntülerinin olasılıksal tahmini üzerine durulmuştur (Fu vd., 2016). Medikal görüntülerden fundus görüntüleri kullanılarak gerçekleşen kanamaların tespiti için van Grinsven ve arkadaşları bir çalışma yapmışlardır (van Grinsven vd., 2016). Bir başka çalışmada retina fundus görüntülerinden diyabetik retinopatinin saptanmasında derin öğrenme algoritmasının geliştirilmesi ve doğrulanması sunulmuştur (Gulshan vd., 2016). Derin öğrenme

ağlarından GoogleNet kullanılarak ön göğüs radyografilerinde anormalliklerin algılaması ve sınıflandırılması yapılmıştır. En çok görülen 5 anormallik üzerinde durulmuştur (Cicero vd., 2017). 17 hastalık türünün tespitinin nasıl yapıldığı sunulmuştur. Burada tekrarlayan sinir ağı ile göğüs röntgen görüntüleri değerlendirilmiştir. Daha sonra AlexNet ve GoogleNet ile kıyaslanmaktadır (Shin vd., 2016). Tarando ve arkadaşları akciğer doku örneklerini sınıflandırmak için derin öğrenme tabanlı bir tanı sistemi sunmuşlardır (Tarando vd., 2016). Mamografi görüntülerinden meme kanseri tespiti ve sınıflandırılması için R-CNN kullanan Akselrod-Ballin ve arkadaşları uzman radyologlarla birlikte yaptığı çalışmayı başarılı olarak görmüşlerdir (Akselrod-Ballin vd., 2016). Akciğer hastalıklarının tespiti için akciğer desenlerinin sınıflandırılması için bir yaklaşım sunulmuştur. Bu çalışma ile AlexNet, LeNet, VggNet mimarileri ile karşılaştırılmıştır (Anthimopoulos vd., 2016). Ramsundar ve arkadaşları ilaç keşfi için bir derin öğrenme yaklaşımı sunmuşlardır. Birçok farklı biyolojik kaynaktan bilgileri sentezlemiş, 200'den fazla biyolojik hedef için yaklaşık 40 milyon veriyi bir araya getirerek bir veriseti oluşturmuşlardır. İlaç keşfi için bir dizi araştırma yapmışlardır (Ramsundar vd., 2015). An ve arkadaşları beyinin sağ ve sol motorlarına ilişkin EEG sinyallerinin alınarak sınıflandırılması için derin inanç ağları ve boltzman makine öğrenimini kullanmıştır (An vd., 2014). Proteinin ikincil yapısının tahmini için kullanılan derin öğrenme çalışması ile daha önce yapılan çalışmalardan daha iyi bir sonuç çıkarılmıştır (Spencer vd., 2015). Bir başka çalışmada deri üzerindeki lezyonların derin öğrenme ile saptanması üzerine olmuştur. Deride yaşanan lezyonların ve melanoma kanser hastalığın tespit edilmesi için bu çalışma sunulmuştur (Jafari vd., 2016). Bir başka çalışmada uyuşturucuya bağlı karaciğerde meydana gelen kalıcı hasarların ortaya çıkarılması için derin öğrenme mimarisi kullanılmıştır (Xu vd., 2015).

f. *Endüstri (Industrial)*

Sanayi alanında kullanılacak olan derin öğrenme mimarili yaklaşımlar üretim, kullanım, kullanıcı, ergonomiklik açıdan oldukça önemlidir. Sanayinin her alanında kullanılacak olan bilgisayar destekli yaklaşımlar üretkenliği artırmaktadır. Endüstriyel süreç kontrolünde; anahtar değişkenler, ürün nitelikleri, teknik ve ekonomik sınırlamalar oldukça önemlidir. Shang ve arkadaşları bu verilerin etkili bir çözümü olarak veri odaklı yumuşak sensörler aracılığı ile bu verilerin güvenilir ve kararlı çevrim içi tahmin oluşturması için bir yaklaşım sunmuşlardır. Bu çalışmada yumuşak sensörler oluşturularak ağır dizel kesim noktasını tahmin etmek için bir derin öğrenme yaklaşımı üzerinde çalışmışlardır (Shang vd., 2014). Bir başka çalışmada, robotik sistemler için nesnelere duruş-poz tahmini yapmak, onları kavramak ve belirlenmiş bir hedefe doğru hareket eden bir robot görme sistemi sunulmuştur. Çalışmada ayrıca, nesne duruş ve pozisyonunu belirleyen bir derin öğrenme sistemi önerilmiştir (Yu vd., 2013). Pozlama tahmini ve robotik nesne tutma için bir başka çalışmayı da Zhihong ve arkadaşları yapmışlardır (Zhihong vd., 2017). Dönen makine parçası olan rulmanın ömrünün tahmini özellikle imalat sanayinde önemlidir. Rulman titreşim sinyallerinden çıkan özellikleri veri olarak alıp kalan ömür tahminini yapan bir derin öğrenme yaklaşımı sunulmuştur (Ren vd., 2017).

g. *Diğer çalışmalar*

Yukarıda belirtilen başlıkların dışında pek çok alanda derin öğrenme mimarilerini görmek mümkün. Bu çalışmalara örnek vermek gerekirse; Derin öğrenme kullanılarak big data ile trafik akış tahmini çalışması (Lv vd., 2015), derin öğrenme ile robotik davranışlarının tespit edilmesi (Lenz vd., 2015), büyük ölçekli duygu sınıflandırılması için alan adaptasyonu (Glorot vd., 2011), CpG modülü kullanılarak DeepCpG derin öğrenme ile tek hücreli DNA metilasyon durumlarının doğru tahmini (Angermueller vd., 2017). Robotların gerçek dünyadaki fiziksel metaryallere dokunuş anlayışını sağlayacak bir



derin öğrenme yaklaşımı önerilmiştir. Bu çalışmada, maddelerin yapısına bakarak robotun bu maddeyi tutmak için harcayacağı gücün nasıl olması gerektiğine karar verecek bir yapı araştırılmıştır. Görsel bir etkileşim üzerinden gidilen çalışma, temelde robotun hissetmesini sağlayacak bir yaklaşım sunmaktadır (Gao vd., 2016). Heaton ve arkadaşları finans sektöründe kullanılan klasik yaklaşımları ve bu yaklaşımların derin öğrenme nasıl gerçekleşeceğini sunmuştur (Heaton vd., 2016). Yapılan bir çalışmada robotlar için el göz koordinasyonunu sağlamak için derin öğrenme yaklaşımı kullanılmıştır. Nesnelerin tespit edilmesi ve yakalanmasını daha kolaylaştıracak bir yaklaşım sunulmuştur (Levine vd., 2016). Yapılan bir çalışmada bir aracın otomatik kullanılması için bilgisayarı bir stajyer olarak görmekte. Ve doğal insan öğrenmesini takip etmektedir. Bunun için birkaç aşamada gerçekleştirilen bir yöntem kullanılmıştır. Öğretmensiz özellik öğrenme, öğretmenli taklitli öğrenme, öğretmenli ödül indüksiyonu, emniyet modülü ve takviyeli öğrenme. Derin öğrenme ile gerçekleştirilen bu otomatik araç kullanımını bir oyun yazılımında kullanılmış ve sunulmuştur (Hilleli ve El-Yaniv, 2016). Sözlük, makine dil çevrimi, doğal dil çevrimleri için yapılan pek çok çalışma literatürde görülebilmektedir (Bahdanau vd., 2014; Cho vd., 2014; Jean vd., 2014; Sutskever vd., 2014; Kreutzer vd., 2015).

## Sonuçlar ve Tartışma

Yapay zeka mimarileri geçmişten günümüze gelindiğinde pek çok alanlarda kullanılmaktadır. Yapay zeka yaklaşımlarının tarihsel gelişimi makine öğrenmesinin ne denli bir hızla geliştiğini göstermektedir. Elektronik ve bilgisayar sistemlerinin hemen hepsinde kontrol, denetim, tahmin, modifikasyon, üretim, eğlence amaçlı bir yaklaşımı görmek mümkün. Caddede bilbordlarda, oyun salonlarında, araba, uçakta, dinlediğimiz bir müzikte, izlediğimiz bir filmde, televizyonlarda pek çok uygulamada, hava tahminlerinde, hastanede, güvenlik sistemlerinde, savunma sanayisinde, finansal

sektörlerde ve pek çok günlük yaşam aktivasyonlarında görmek mümkündür.

Derin öğrenme sistemlerinin bu kadar geliştiği bir ortamda şirketler, devletler, kurumlar arge için bu konuya ciddi şekilde eğilim göstermişlerdir. Pek çok büyük bilişim şirketi bu konuda atılımlar yapmış yeni yaklaşımlar getirmiştir. Konunun gelişimine göre yeni uygulamalar ve bakış açıları geliştirmişlerdir. Google, Microsoft, Baidu, IBM, Apple, Nvidia, Facebook, Twitter, Amazon ve daha birçok şirket derin öğrenmeyle ilgili çalışmalar yapmıştır.

Yapılan çalışmalara bakıldığında derin öğrenme mimarileri yapay zeka teknolojilerine yeni bir yaklaşım getirdiği ve çığır açtığı görülmektedir. Derin öğrenme mimarilerinin gelecek tahminlerine yönelik çalışmaları günümüz teknolojilerini birkaç yıl ileri taşıdığı düşünülmektedir. İnsan hayatını kolaylaştırmak, sağlıklı bir yaşam sürdürebilmek için derin öğrenme mimarilerinin çok etkin şekilde hayatımızda yer almaya başladığı görülmektedir.

Gelecekte günlük yaşamın her noktasında yer alacak olan bu mimarilerin otomot bir dünyanın kapısını aralayacağı düşünülmektedir. Kendi kendine gideceği yere varan araçlar, daha güvenli yollar, insansız hava ve kara araçları, taşıma alanında bir başkalaşıma doğru götürecektir. Tıp alanında; hastalık tanı ve teşhisin daha hızlı gerçekleşebileceği, doktorun yapmış olduğu ameliyatların bir kısmını robotların yapabileceği, kendi kendine hastaya cevap verebilecek sistemlerin oluşturulabileceği, hastanın sağlık merkezlerine uğramadan tanı-teşhis konabileceği sistemler üzerine çalışmalar yapılmaktadır.

Robotik sistemlerde farklı bir noktaya getirecek ve robotların insan yaşamında etkin bir rol oynayacağı bir dünya için pek çok çalışma yapılmaktadır. Pek çok özel şirket insan gücünün yerini robotik sistemlere bırakacağı öncü çalışmalar yapmaktadır. Tarımsal alanlarda sulama, bakım, gübreleme, toprak analizlerinin

otomatik yapılacağı ulusal sistemler için derin öğrenme tabanlı çalışmalar devam etmektedir.

Savunma sanayinde kullanılan pek çok yapay zeka teknolojisi bulunmaktadır. Günümüzde pek çok savunma araçları derin öğrenme mimarisi ile donatılmaktadır. Özellikle insansız hava ve kara araçlarında aktif rol almaktadır.

Bu makale ile derin öğrenme mimarileri hakkında bir derleme çalışması sunulmuştur.

## Kaynaklar

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., ... & Ghemawat, S. (2016). Tensorflow: Large-scale machine learning on heterogeneous distributed systems. arXiv preprint arXiv:1603.04467.
- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., ... & Kudlur, M. (2016). TensorFlow: A System for Large-Scale Machine Learning. In OSDI (Vol. 16, pp. 265-283).
- Ackley, D. H., Hinton, G. E., & Sejnowski, T. J. (1987). A learning algorithm for Boltzmann machines. In Readings in Computer Vision (pp. 522-533).
- Akselrod-Ballin, A., Karlinsky, L., Alpert, S., Hasoul, S., Ben-Ari, R., & Barkan, E. (2016). A region based convolutional network for tumor detection and classification in breast mammography. In Deep Learning and Data Labeling for Medical Applications (pp. 197-205). Springer, Cham.
- Al Rahhal, M. M., Bazi, Y., AlHichri, H., Alajlan, N., Melgani, F., & Yager, R. R. (2016). Deep learning approach for active classification of electrocardiogram signals. Information Sciences, 345, 340-354.
- Alexe, B., Deselaers, T., & Ferrari, V. (2012). Measuring the objectness of image windows. IEEE transactions on pattern analysis and machine intelligence, 34(11), 2189-2202.
- An, X., Kuang, D., Guo, X., Zhao, Y., & He, L. (2014). A deep learning method for classification of EEG data based on motor imagery. In International Conference on Intelligent Computing (pp. 203-210). Springer, Cham.
- Angelova, A., Krizhevsky, A., & Vanhoucke, V. (2015). Pedestrian detection with a large-field-of-view deep network. In Robotics and Automation (ICRA), 2015 IEEE International Conference on (pp. 704-711).
- Angermueller, C., Lee, H. J., Reik, W., & Stegle, O. (2017). DeepCpG: accurate prediction of single-cell DNA methylation states using deep learning. Genome biology, 18(1), 67.
- Anthimopoulos, M., Christodoulidis, S., Ebner, L., Christe, A., & Mougiakakou, S. (2016). Lung pattern classification for interstitial lung diseases using a deep convolutional neural network. IEEE transactions on medical imaging, 35(5), 1207-1216.
- Antony, J., McGuinness, K., O'Connor, N. E., & Moran, K. (2016). Quantifying radiographic knee osteoarthritis severity using deep convolutional neural networks. In Pattern Recognition (ICPR), 2016 23rd International Conference on (pp. 1195-1200).
- Asgari, E., & Mofrad, M. R. (2015). Continuous distributed representation of biological sequences for deep proteomics and genomics. PloS one, 10(11), e0141287.
- Assael, Y. M., Shillingford, B., Whiteson, S., & de Freitas, N. (2016). LipNet: end-to-end sentence-level lipreading.
- 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).
- Baltruschat, I. M., Nickisch, H., Grass, M., Knopp, T., & Saalbach, A. (2018). Comparison of Deep Learning Approaches for Multi-Label Chest X-Ray Classification. arXiv preprint arXiv:1803.02315.
- Bastien, F., Lamblin, P., Pascanu, R., Bergstra, J., Goodfellow, I., Bergeron, A., ... & Bengio, Y. (2012). Theano: new features and speed improvements. arXiv preprint arXiv:1211.5590.
- Bengio, Y. (2009). Learning deep architectures for AI. *Foundations and trends® in Machine Learning*, 2(1), 1-127.
- Bengio, Y., Lamblin, P., Popovici, D., & Larochelle, H. (2007). Greedy layer-wise training of deep networks. In *Advances in neural information processing systems* (pp. 153-160).
- Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE transactions on neural networks*, 5(2), 157-166.
- Boureau, Y. L., & Cun, Y. L. (2008). Sparse feature learning for deep belief networks. In *Advances in neural information processing systems* (pp. 1185-1192).
- Broomhead, D. S., & Lowe, D. (1988). Radial basis functions, multi-variable functional interpolation and adaptive networks (No. RSRE-MEMO-4148). Royal Signals and Radar Establishment Malvern (United Kingdom).
- Bruelckner, R., & Schuler, B. (2014). Social signal classification using deep BLSTM recurrent neural networks. In *Acoustics, Speech and Signal Processing (ICASSP), 2014 IEEE International Conference on* (pp. 4823-4827).
- Buczak, A. L., & Guven, E. (2016). A survey of data mining and machine learning methods for cyber security intrusion detection. *IEEE Communications Surveys & Tutorials*, 18(2), 1153-1176.
- Cao, Z., Simon, T., Wei, S. E., & Sheikh, Y. (2017, July). Realtime multi-person 2d pose estimation using part affinity fields. In *CVPR (Vol. 1, No. 2, p. 7)*.
- Chamberlain, D., Kodgule, R., Ganelin, D., Miglani, V., & Fletcher, R. R. (2016). Application of semi-supervised deep learning to lung sound analysis. In *Engineering in Medicine and Biology Society (EMBC), 2016 IEEE 38th Annual International Conference of the* (pp. 804-807).
- Chan, T. H., Jia, K., Gao, S., Lu, J., Zeng, Z., & Ma, Y. (2015). PCANet: A simple deep learning baseline for image classification?. *IEEE Transactions on Image Processing*, 24(12), 5017-5032.
- Chapelle, O., Scholkopf, B., & Zien, A. (2009). Semi-supervised learning (chapelle, o. et al., eds.; 2006)[book reviews]. *IEEE Transactions on Neural Networks*, 20(3), 542-542.
- Chen, C. L., Mahjoubfar, A., Tai, L. C., Blaby, I. K., Huang, A., Niazi, K. R., & Jalali, B. (2016). Deep learning in label-free cell classification. *Scientific reports*, 6, 21471.
- Chen, X., Xiang, S., Liu, C. L., & Pan, C. H. (2013). Aircraft detection by deep belief nets. In *Pattern Recognition (ACPR), 2013 2nd IAPR Asian Conference on* (pp. 54-58).
- Chen, Y., Lin, Z., Zhao, X., Wang, G., & Gu, Y. (2014). Deep learning-based classification of hyperspectral data. *IEEE Journal of Selected topics in applied earth observations and remote sensing*, 7(6), 2094-2107.
- Cheng, G., & Han, J. (2016). A survey on object detection in optical remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 117, 11-28.
- Cheng, G., Zhou, P., & Han, J. (2016). Learning rotation-invariant convolutional neural networks for object detection in VHR optical remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 54(12), 7405-7415.
- Cheng, M. M., Zhang, Z., Lin, W. Y., & Torr, P. (2014). BING: Binarized normed gradients for objectness estimation at 300fps. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3286-3293).
- Cheng, Z., Yang, Q., & Sheng, B. (2015). Deep colorization. In *Proceedings of the IEEE International Conference on Computer Vision* (pp. 415-423).
- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. arXiv preprint arXiv:1406.1078.
- Chollet, F. (2016). Xception: Deep learning with depthwise separable convolutions. arXiv preprint.
- Cicero, M., Bilbily, A., Colak, E., Dowdell, T., Gray, B., Perampaladas, K., & Barfett, J.

- (2017). Training and validating a deep convolutional neural network for computer-aided detection and classification of abnormalities on frontal chest radiographs. *Investigative radiology*, 52(5), 281-287.
- Ciregan, D., Meier, U., & Schmidhuber, J. (2012). Multi-column deep neural networks for image classification. In *Computer vision and pattern recognition (CVPR), 2012 IEEE conference on* (pp. 3642-3649).
- Ciresan, D. C., Meier, U., Masci, J., Maria Gambardella, L., & Schmidhuber, J. (2011). Flexible, high performance convolutional neural networks for image classification. In *IJCAI Proceedings-International Joint Conference on Artificial Intelligence (Vol. 22, No. 1, p. 1237)*.
- Collobert, R., Kavukcuoglu, K., & Farabet, C. (2011). Torch7: A matlab-like environment for machine learning. In *BigLearn, NIPS workshop (No. EPFL-CONF-192376)*.
- Cruz-Roa, A. A., Ovalle, J. E. A., Madabhushi, A., & Osorio, F. A. G. (2013). A deep learning architecture for image representation, visual interpretability and automated basal-cell carcinoma cancer detection. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*(pp. 403-410). Springer, Berlin, Heidelberg.
- Dahl, G. E., Stokes, J. W., Deng, L., & Yu, D. (2013). Large-scale malware classification using random projections and neural networks. In *Acoustics, Speech and Signal Processing (ICASSP), 2013 IEEE International Conference on* (pp. 3422-3426).
- Dahl, R., Norouzi, M., & Shlens, J. (2017). Pixel recursive super resolution. *arXiv preprint arXiv:1702.00783*.
- de Brébisson, A., & Montana, G. (2015). Deep neural networks for anatomical brain segmentation. *arXiv preprint arXiv:1502.02445*.
- Diao, W., Sun, X., Zheng, X., Dou, F., Wang, H., & Fu, K. (2016). Efficient saliency-based object detection in remote sensing images using deep belief networks. *IEEE Geoscience and Remote Sensing Letters*, 13(2), 137-141.
- Dogan., F., Turkoglu, I., (2017). Classification Of Satellite Images By Deep Learning. 8th International Advanved Teknologies Symposium.
- Eberhart, R., & Kennedy, J. (1995). A new optimizer using particle swarm theory. In *Micro Machine and Human Science, 1995. MHS'95., Proceedings of the Sixth International Symposium on* (pp. 39-43).
- Elman, J. L. (1990). Finding structure in time. *Cognitive science*, 14(2), 179-211.
- Erhan, D., Szegedy, C., Toshev, A., & Anguelov, D. (2014). Scalable object detection using deep neural networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 2147-2154).
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115.
- Fakoor, R., Ladhak, F., Nazi, A., & Huber, M. (2013). Using deep learning to enhance cancer diagnosis and classification. In *Proceedings of the International Conference on Machine Learning (Vol. 28)*.
- Fried, O., & Fiebrink, R. (2013). Cross-modal Sound Mapping Using Deep Learning. In *NIME* (pp. 531-534).
- Frome, A., Corrado, G. S., Shlens, J., Bengio, S., Dean, J., & Mikolov, T. (2013). Devise: A deep visual-semantic embedding model. In *Advances in neural information processing systems*(pp. 2121-2129).
- Fu, H., Xu, Y., Wong, D. W. K., & Liu, J. (2016). Retinal vessel segmentation via deep learning network and fully-connected conditional random fields. In *Biomedical Imaging (ISBI), 2016 IEEE 13th International Symposium on* (pp. 698-701).
- Fukushima, K. (1975). Cognitron: A self-organizing multilayered neural network. *Biological cybernetics*, 20(3-4), 121-136.
- Fukushima, K. (1986). A neural network model for selective attention in visual pattern recognition. *Biological Cybernetics*, 55(1), 5-15.
- Fukushima, K., & Miyake, S. (1982). Neocognitron: A self-organizing neural network model for a mechanism of visual pattern recognition. In *Competition and cooperation in neural nets* (pp. 267-285). Springer, Berlin, Heidelberg.
- Ganin, Y., Kononenko, D., Sungatullina, D., & Lempitsky, V. (2016). Deepwarp: Photorealistic image resynthesis for gaze manipulation. In *European Conference on Computer Vision*(pp. 311-326). Springer, Cham.
- Gao, Y., Hendricks, L. A., Kuchenbecker, K. J., & Darrell, T. (2016). Deep learning for tactile

- understanding from visual and haptic data. In *Robotics and Automation (ICRA), 2016 IEEE International Conference on* (pp. 536-543).
- Gatys, L., Ecker, A. S., & Bethge, M. (2015). Texture synthesis using convolutional neural networks. In *Advances in Neural Information Processing Systems* (pp. 262-270).
- Gers, F. A., & Schmidhuber, J. (2000). Recurrent nets that time and count. In *Neural Networks, 2000. IJCNN 2000, Proceedings of the IEEE-INNS-ENNS International Joint Conference on* (Vol. 3, pp. 189-194).
- Gers, F. A., Schmidhuber, J., & Cummins, F. (1999). Learning to forget: Continual prediction with LSTM.
- Girshick, R. (2015). Fast r-cnn. *arXiv preprint arXiv:1504.08083*.
- Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 580-587).
- Glorot, X., Bordes, A., & Bengio, Y. (2011). Domain adaptation for large-scale sentiment classification: A deep learning approach. In *Proceedings of the 28th international conference on machine learning (ICML-11)* (pp. 513-520).
- Goldberg, D. E., & Holland, J. H. (1988). Genetic algorithms and machine learning. *Machine learning*, 3(2), 95-99.
- Golkov, V., Dosovitskiy, A., Sperl, J. I., Menzel, M. I., Czisch, M., Sämann, P., ... & Cremers, D. (2016). q-Space deep learning: twelve-fold shorter and model-free diffusion MRI scans. *IEEE transactions on medical imaging*, 35(5), 1344-1351.
- Goodfellow, I. J., Warde-Farley, D., Lamblin, P., Dumoulin, V., Mirza, M., Pascanu, R., ... & Bengio, Y. (2013). Pylearn2: a machine learning research library. *arXiv preprint arXiv:1308.4214*.
- Graves, A., Mohamed, A. R., & Hinton, G. (2013). Speech recognition with deep recurrent neural networks. In *Acoustics, speech and signal processing (icassp), 2013 IEEE international conference on* (pp. 6645-6649).
- Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., ... & Kim, R. (2016). Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *Jama*, 316(22), 2402-2410.
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M. S. (2016). Deep learning for visual understanding: A review. *Neurocomputing*, 187, 27-48.
- Han, S., Mao, H., & Dally, W. J. (2015). Deep compression: Compressing deep neural networks with pruning, trained quantization and Huffman coding. *arXiv preprint arXiv:1510.00149*.
- Hannun, A., Case, C., Casper, J., Catanzaro, B., Diamos, G., Elsen, E., ... & Ng, A. Y. (2014). Deep speech: Scaling up end-to-end speech recognition. *arXiv preprint arXiv:1412.5567*.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). Unsupervised learning. In *The elements of statistical learning* (pp. 485-585). Springer, New York, NY.
- Havaei, M., Guizard, N., Chapados, N., & Bengio, Y. (2016). HeMIS: Hetero-modal image segmentation. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (pp. 469-477). Springer, Cham.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Heaton, J. B., Polson, N. G., & Witte, J. H. (2016). Deep learning in finance. *arXiv preprint arXiv:1602.06561*.
- Hebb, D. (1949). *The organization of behavior* John Wiley & sons. New York.
- Hilleli, B., & El-Yaniv, R. (2016). Deep Learning of Robotic Tasks using Strong and Weak Human Supervision. *arXiv preprint arXiv:1612.01086*.
- Hinton, G. E. (2012). A practical guide to training restricted Boltzmann machines. In *Neural networks: Tricks of the trade* (pp. 599-619). Springer, Berlin, Heidelberg.
- Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *science*, 313(5786), 504-507.
- Hinton, G. E., & Zemel, R. S. (1994). Autoencoders, minimum description length and Helmholtz free energy. In *Advances in neural information processing systems* (pp. 3-10).
- Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.

- Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. arXiv preprint arXiv:1207.0580.
- Hinton, G., Deng, L., Yu, D., Dahl, G. E., Mohamed, A. R., Jaitly, N., ... & Kingsbury, B. (2012). Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *IEEE Signal Processing Magazine*, 29(6), 82-97.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Holder, L. B., Haque, M. M., & Skinner, M. K. (2017). Machine learning for epigenetics and future medical applications. *Epigenetics*, 12(7), 505-514.
- Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the national academy of sciences*, 79(8), 2554-2558.
- Hu, F., Xia, G. S., Hu, J., & Zhang, L. (2015). Transferring deep convolutional neural networks for the scene classification of high-resolution remote sensing imagery. *Remote Sensing*, 7(11), 14680-14707.
- Hua, K. L., Hsu, C. H., Hidayati, S. C., Cheng, W. H., & Chen, Y. J. (2015). Computer-aided classification of lung nodules on computed tomography images via deep learning technique. *OncoTargets and therapy*, 8.
- Huang, F. J., Boureau, Y. L., & LeCun, Y. (2007). Unsupervised learning of invariant feature hierarchies with applications to object recognition. In *Computer Vision and Pattern Recognition, 2007. CVPR'07. IEEE Conference on* (pp. 1-8).
- Hubel, D. H., & Wiesel, T. N. (1968). Receptive fields and functional architecture of monkey striate cortex. *The Journal of physiology*, 195(1), 215-243.
- Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., & Keutzer, K. (2016). SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. arXiv preprint arXiv:1602.07360.
- Iizuka, S., Simo-Serra, E., & Ishikawa, H. (2016). Let there be color!: joint end-to-end learning of global and local image priors for automatic image colorization with simultaneous classification. *ACM Transactions on Graphics (TOG)*, 35(4), 110.
- İnik, Ö., & Ülker, E., (2017) Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In *International conference on machine learning* (pp. 448-456).
- Isola, P., Zhu, J. Y., Zhou, T., & Efros, A. A. (2017). Image-to-image translation with conditional adversarial networks. arXiv preprint.
- Jafari, M. H., Nasr-Esfahani, E., Karimi, N., Soroushmehr, S. M., Samavi, S., & Najarian, K. (2016). Extraction of skin lesions from non-dermoscopic images using deep learning. arXiv preprint arXiv:1609.02374.
- Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31-44.
- Jarrett, K., Kavukcuoglu, K., & LeCun, Y. (2009). What is the best multi-stage architecture for object recognition?. In *Computer Vision, 2009 IEEE 12th International Conference on* (pp. 2146-2153).
- Jean, S., Cho, K., Memisevic, R., & Bengio, Y. (2014). On using very large target vocabulary for neural machine translation. arXiv preprint arXiv:1412.2007.
- Jia, Y., Shelhamer, E., Donahue, J., Karayev, S., Long, J., Girshick, R., ... & Darrell, T. (2014). Caffe: Convolutional architecture for fast feature embedding. In *Proceedings of the 22nd ACM international conference on Multimedia* (pp. 675-678). ACM.
- Jones, M. S. (2015). Convolutional autoencoders in python/theano/lasagne. Blog post (retrieved February 17, 2016), April.
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.
- Kappen, H. J. (1994). Using boltzmann machines for probability estimation: A general framework for neural network learning. In *Machine Intelligence and Pattern Recognition* (Vol. 16, pp. 299-312). North-Holland.
- 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).
- Karpathy, A., Toderici, G., Shetty, S., Leung, T., Sukthankar, R., & Fei-Fei, L. (2014). Large-

- scale video classification with convolutional neural networks. In Proceedings of the IEEE conference on Computer Vision and Pattern Recognition (pp. 1725-1732).
- Kawahara, J., Brown, C. J., Miller, S. P., Booth, B. G., Chau, V., Grunau, R. E., ... & Hamarneh, G. (2017). BrainNetCNN: convolutional neural networks for brain networks; towards predicting neurodevelopment. *NeuroImage*, 146, 1038-1049.
- Kim, Y. (2014). Convolutional neural networks for sentence classification. arXiv preprint arXiv:1408.5882.
- Kochura, Y., Stirenko, S., Rojbi, A., Alienin, O., Novotarskiy, M., & Gordienko, Y. (2017). Comparative analysis of open source frameworks for machine learning with use case in single-threaded and multi-threaded modes. arXiv preprint arXiv:1706.02248.
- Kourou, K., Exarchos, T. P., Exarchos, K. P., Karamouzis, M. V., & Fotiadis, D. I. (2015). Machine learning applications in cancer prognosis and prediction. *Computational and structural biotechnology journal*, 13, 8-17.
- Kreutzer, J., Schamoni, S., & Riezler, S. (2015). Quality estimation from scratch (quetch): Deep learning for word-level translation quality estimation. In Proceedings of the Tenth Workshop on Statistical Machine Translation (pp. 316-322).
- Krizhevsky, A., & Hinton, G. E. (2011). Using very deep autoencoders for content-based image retrieval. In ESANN.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In Advances in neural information processing systems (pp. 1097-1105).
- Kussul, N., Lavreniuk, M., Skakun, S., & Shelestov, A. (2017). Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters*, 14(5), 778-782.
- Larsson, G., Maire, M., & Shakhnarovich, G. (2016). Learning representations for automatic colorization. In European Conference on Computer Vision (pp. 577-593). Springer, Cham.
- LeCun, Y., & Bengio, Y. (1995). Convolutional networks for images, speech, and time series. *The handbook of brain theory and neural networks*, 3361(10), 1995.
- 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., Pham, P., Largman, Y., & Ng, A. Y. (2009). Unsupervised feature learning for audio classification using convolutional deep belief networks. In Advances in neural information processing systems (pp. 1096-1104).
- Lenz, I., Lee, H., & Saxena, A. (2015). Deep learning for detecting robotic grasps. *The International Journal of Robotics Research*, 34(4-5), 705-724.
- Levine, S., Pastor, P., Krizhevsky, A., & Quillen, D. (2016). Learning hand-eye coordination for robotic grasping with large-scale data collection. In International Symposium on Experimental Robotics (pp. 173-184). Springer, Cham.
- Li, H., Lin, Z., Shen, X., Brandt, J., & Hua, G. (2015). A convolutional neural network cascade for face detection. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 5325-5334).
- Li, J., Dai, W., Metze, F., Qu, S., & Das, S. (2017). A comparison of deep learning methods for environmental sound detection. In Acoustics, Speech and Signal Processing (ICASSP), 2017 IEEE International Conference on (pp. 126-130).
- Li, T. L., Chan, A. B., & Chun, A. (2010). Automatic musical pattern feature extraction using convolutional neural network. In Proc. Int. Conf. Data Mining and Applications.
- Lin, M., Chen, Q., & Yan, S. (2013). Network in network. arXiv preprint arXiv:1312.4400.
- Lippmann, R. (1987). An introduction to computing with neural nets. *IEEE Assp magazine*, 4(2), 4-22.
- Liu, H., Li, L., & Ma, J. (2016). Rolling bearing fault diagnosis based on STFT-deep learning and sound signals. *Shock and Vibration*, 2016.
- Lu, X., Tsao, Y., Matsuda, S., & Hori, C. (2013, August). Speech enhancement based on deep denoising autoencoder. In Interspeech (pp. 436-440).
- Luus, F. P., Salmon, B. P., Van den Bergh, F., & Maharaj, B. T. J. (2015). Multiview deep learning for land-use classification. *IEEE Geoscience and Remote Sensing Letters*, 12(12), 2448-2452.
- Lv, Y., Duan, Y., Kang, W., Li, Z., & Wang, F. Y. (2015). Traffic flow prediction with big data: a deep learning approach. *IEEE Transactions on Intelligent Transportation Systems*, 16(2), 865-873.

- McClelland, J. L., Rumelhart, D. E., & Hinton, G. E. (1986). The appeal of parallel distributed processing. MIT Press, Cambridge MA, 3-44.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133.
- Michalski, R. S., Carbonell, J. G., & Mitchell, T. M. (Eds.). (2013). *Machine learning: An artificial intelligence approach*. Springer Science & Business Media.
- Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). Efficient estimation of word representations in vector space. arXiv preprint arXiv:1301.3781.
- Minsky, M., Papert, S. A., & Bottou, L. (1969). *Perceptrons: An introduction to computational geometry*. MIT press.
- Morris, R. J., & Rubin, L. D. (1991). U.S. Patent No. 5,060,276. Washington, DC: U.S. Patent and Trademark Office.
- Murugappan, V., & Sabeenian, R. S. (2017). Texture based medical image classification by using multi-scale gabor rotation-invariant local binary pattern (MGRLBP). *Cluster Computing*, 1-14.
- Nair, A., Srinivasan, P., Blackwell, S., Alcicek, C., Fearon, R., De Maria, A., ... & Legg, S. (2015). Massively parallel methods for deep reinforcement learning. arXiv preprint arXiv:1507.04296.
- Nair, V., & Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th international conference on machine learning (ICML-10)* (pp. 807-814).
- Ng, J. Y. H., Hausknecht, M., Vijayanarasimhan, S., Vinyals, O., Monga, R., & Toderici, G. (2015). Beyond short snippets: Deep networks for video classification. In *Computer Vision and Pattern Recognition (CVPR), 2015 IEEE Conference on* (pp. 4694-4702).
- Nguyen, A., Clune, J., Bengio, Y., Dosovitskiy, A., & Yosinski, J. (2017). Plug & play generative networks: Conditional iterative generation of images in latent space. In *Computer Vision and Pattern Recognition (CVPR), 2017 IEEE Conference on* (pp. 3510-3520).
- NVIDIA, 2016. NVIDIA deep learning gpu training system. <https://developer.nvidia.com/digits>. Erişim: 17.03.2018.
- Oord, A. V. D., Dieleman, S., Zen, H., Simonyan, K., Vinyals, O., Graves, A., ... & Kavukcuoglu, K. (2016). Wavenet: A generative model for raw audio. arXiv preprint arXiv:1609.03499.
- Ouyang, W., & Wang, X. (2013). Joint deep learning for pedestrian detection. In *Computer Vision (ICCV), 2013 IEEE International Conference on* (pp. 2056-2063).
- Owens, A., Isola, P., McDermott, J., Torralba, A., Adelson, E. H., & Freeman, W. T. (2016). Visually indicated sounds. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 2405-2413).
- Pan, Z., Rust, A. G., & Bolouri, H. (2000). Image redundancy reduction for neural network classification using discrete cosine transforms. In *Neural Networks, 2000. IJCNN 2000, Proceedings of the IEEE-INNS-ENNS International Joint Conference on* (Vol. 3, pp. 149-154).
- Pang, Y., Sun, M., Jiang, X., & Li, X. (2017). Convolution in convolution for network in network. *IEEE transactions on neural networks and learning systems*.
- Parkhi, O. M., Vedaldi, A., & Zisserman, A. (2015). Deep Face Recognition. In *BMVC* (Vol. 1, No. 3, p. 6).
- Piczak, K. J. (2015, September). Environmental sound classification with convolutional neural networks. In *Machine Learning for Signal Processing (MLSP), 2015 IEEE 25th International Workshop on* (pp. 1-6).
- Plis, S. M., Hjelm, D. R., Salakhutdinov, R., Allen, E. A., Bockholt, H. J., Long, J. D., ... & Calhoun, V. D. (2014). Deep learning for neuroimaging: a validation study. *Frontiers in neuroscience*, 8, 229.
- Qi, C. R., Su, H., Mo, K., & Guibas, L. J. (2017). Pointnet: Deep learning on point sets for 3d classification and segmentation. *Proc. Computer Vision and Pattern Recognition (CVPR), IEEE*, 1(2), 4.
- Quinlan, J. R. (1986). Induction of decision trees. *Machine learning*, 1(1), 81-106.
- Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 580-587).
- Ramsundar, B., Kearnes, S., Riley, P., Webster, D., Konerding, D., & Pande, V. (2015). Massively multitask networks for drug discovery. arXiv preprint arXiv:1502.02072.
- Ren, L., Cui, J., Sun, Y., & Cheng, X. (2017). Multi-bearing remaining useful life



- collaborative prediction: A deep learning approach. *Journal of Manufacturing Systems*, 43, 248-256.
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. In *Advances in neural information processing systems*(pp. 91-99).
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. In *Advances in neural information processing systems*(pp. 91-99).
- Robinson, J. A. (1965). A machine-oriented logic based on the resolution principle. *Journal of the ACM (JACM)*, 12(1), 23-41.
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., ... & Berg, A. C. (2015). Imagenet large scale visual recognition challenge. *International Journal of Computer Vision*, 115(3), 211-252.
- Sajikumar, N., & Thandaveswara, B. S. (1999). A non-linear rainfall-runoff model using an artificial neural network. *Journal of hydrology*, 216(1-2), 32-55.
- Salamon, J., & Bello, J. P. (2017). Deep convolutional neural networks and data augmentation for environmental sound classification. *IEEE Signal Processing Letters*, 24(3), 279-283.
- Sarle, W. S. (1994). Neural networks and statistical models. *Proceedings of the Nineteenth Annual SAS Users Group International Conference*.
- Sarraf, S., & Tofighi, G. (2016). Classification of alzheimer's disease using fmri data and deep learning convolutional neural networks. *arXiv preprint arXiv:1603.08631*.
- Scherer, D., Müller, A., & Behnke, S. (2010). Evaluation of pooling operations in convolutional architectures for object recognition. In *International conference on artificial neural networks* (pp. 92-101). Springer, Berlin, Heidelberg.
- Schmidhuber, J. (1992). Learning complex, extended sequences using the principle of history compression. *Neural Computation*, 4(2), 234-242.
- Schölkopf, B., Burges, C., & Vapnik, V. (1996). Incorporating invariances in support vector learning machines. In *International Conference on Artificial Neural Networks* (pp. 47-52). Springer, Berlin, Heidelberg.
- Schuster, M., & Paliwal, K. K. (1997). Bidirectional recurrent neural networks. *IEEE Transactions on Signal Processing*, 45(11), 2673-2681.
- Sebastiani, F. (2002). Machine learning in automated text categorization. *ACM computing surveys (CSUR)*, 34(1), 1-47.
- Şeker, A., Diri, B., & Balık, H. H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
- Shang, C., Yang, F., Huang, D., & Lyu, W. (2014). Data-driven soft sensor development based on deep learning technique. *Journal of Process Control*, 24(3), 223-233.
- Shin, H. C., Roberts, K., Lu, L., Demner-Fushman, D., Yao, J., & Summers, R. M. (2016). Learning to read chest x-rays: Recurrent neural cascade model for automated image annotation. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 2497-2506).
- Shipp, M. A., Ross, K. N., Tamayo, P., Weng, A. P., Kutok, J. L., Aguiar, R. C., ... & Ray, T. S. (2002). Diffuse large B-cell lymphoma outcome prediction by gene-expression profiling and supervised machine learning. *Nature medicine*, 8(1), 68.
- Simard, P. Y., Steinkraus, D., & Platt, J. C. (2003). Best practices for convolutional neural networks applied to visual document analysis. In *ICDAR (Vol. 3, pp. 958-962)*.
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Sirinukunwattana, K., Raza, S. E. A., Tsang, Y. W., Snead, D. R., Cree, I. A., & Rajpoot, N. M. (2016). Locality sensitive deep learning for detection and classification of nuclei in routine colon cancer histology images. *IEEE transactions on medical imaging*, 35(5), 1196-1206.
- Snoek, C. G., Worring, M., & Smeulders, A. W. (2005). Early versus late fusion in semantic video analysis. In *Proceedings of the 13th annual ACM international conference on Multimedia* (pp. 399-402). ACM.
- Sommer, R., & Paxson, V. (2010). Outside the closed world: On using machine learning for network intrusion detection. In *Security and Privacy (SP), 2010 IEEE Symposium on* (pp. 305-316).

- Specht, D. F. (1988). Probabilistic neural networks for classification, mapping, or associative memory. In *IEEE international conference on neural networks (Vol. 1, No. 24, pp. 525-532)*.
- Specht, D. F. (1991). A general regression neural network. *IEEE transactions on neural networks*, 2(6), 568-576.
- Spencer, M., Eickholt, J., & Cheng, J. (2015). A deep learning network approach to ab initio protein secondary structure prediction. *IEEE/ACM transactions on computational biology and bioinformatics*, 12(1), 103-112.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research*, 15(1), 1929-1958.
- Stein, J. Y. (1956). *Bibliography. Digital Signal Processing: A Computer Science Perspective*, 829-848.
- Suk, H. I., & Shen, D. (2013). Deep learning-based feature representation for AD/MCI classification. In *International Conference on Medical Image Computing and Computer-Assisted Intervention (pp. 583-590)*. Springer, Berlin, Heidelberg.
- Sun, Y., Chen, Y., Wang, X., & Tang, X. (2014). Deep learning face representation by joint identification-verification. In *Advances in neural information processing systems (pp. 1988-1996)*.
- Sun, Y., Liang, D., Wang, X., & Tang, X. (2015). Deepid3: Face recognition with very deep neural networks. *arXiv preprint arXiv:1502.00873*.
- Sutskever, I., Vinyals, O., & Le, Q. V. (2014). Sequence to sequence learning with neural networks. In *Advances in neural information processing systems (pp. 3104-3112)*.
- Sutskever, I., Vinyals, O., & Le, Q. V. (2014). Sequence to sequence learning with neural networks. In *Advances in neural information processing systems (pp. 3104-3112)*.
- Suwajanakorn, S., Seitz, S. M., & Kemelmacher-Shlizerman, I. (2017). Synthesizing obama: learning lip sync from audio. *ACM Transactions on Graphics (TOG)*, 36(4), 95.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. *Cvpr*.
- Tamilselvan, P., & Wang, P. (2013). Failure diagnosis using deep belief learning based health state classification. *Reliability Engineering & System Safety*, 115, 124-135.
- Tamura, S. I., & Tateishi, M. (1997). Capabilities of a four-layered feedforward neural network: four layers versus three. *IEEE Transactions on Neural Networks*, 8(2), 251-255.
- Tang, D., Wei, F., Qin, B., Liu, T., & Zhou, M. (2014). Coooolll: A deep learning system for twitter sentiment classification. In *Proceedings of the 8th International Workshop on Semantic Evaluation (SemEval 2014) (pp. 208-212)*.
- Tang, Y. (2013). Deep learning using linear support vector machines. *arXiv preprint arXiv:1306.0239*.
- Tarando, S. R., Fetita, C., Faccinetto, A., & Brillet, P. Y. (2016). Increasing CAD system efficacy for lung texture analysis using a convolutional network. In *Medical Imaging 2016: Computer-Aided Diagnosis (Vol. 9785, p. 97850Q)*. International Society for Optics and Photonics.
- Team, D. J. D. (2016). *Deeplearning4j: Open-source distributed deep learning for the JVM*. Apache Software Foundation License, 2.
- Team, T. T. D., Al-Rfou, R., Alain, G., Almahairi, A., Angermueller, C., Bahdanau, D., ... & Belopolsky, A. (2016). Theano: A Python framework for fast computation of mathematical expressions. *arXiv preprint arXiv:1605.02688*.
- Uijlings, J. R., Van De Sande, K. E., Gevers, T., & Smeulders, A. W. (2013). Selective search for object recognition. *International journal of computer vision*, 104(2), 154-171.
- Vakalopoulou, M., Karantzalos, K., Komodakis, N., & Paragios, N. (2015). Building detection in very high resolution multispectral data with deep learning features. In *Geoscience and Remote Sensing Symposium (IGARSS), 2015 IEEE International (pp. 1873-1876)*.
- van Grinsven, M. J., van Ginneken, B., Hoyng, C. B., Theelen, T., & Sánchez, C. I. (2016). Fast convolutional neural network training using selective data sampling: Application to hemorrhage detection in color fundus images. *IEEE transactions on medical imaging*, 35(5), 1273-1284.
- Vincent, P., Larochelle, H., Bengio, Y., & Manzagol, P. A. (2008). Extracting and composing robust features with denoising autoencoders. In *Proceedings of the 25th international conference on Machine learning (pp. 1096-1103)*. ACM.

- Vincent, P., Larochelle, H., Lajoie, I., Bengio, Y., & Manzagol, P. A. (2010). Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. *Journal of Machine Learning Research*, 11(Dec), 3371-3408.
- Vinyals, O., Kaiser, Ł., Koo, T., Petrov, S., Sutskever, I., & Hinton, G. (2015). Grammar as a foreign language. In *Advances in Neural Information Processing Systems* (pp. 2773-2781).
- Wan, L., Zeiler, M., Zhang, S., Le Cun, Y., & Fergus, R. (2013). Regularization of neural networks using dropconnect. In *International Conference on Machine Learning* (pp. 1058-1066).
- Werbos, P. (1974). Beyond regression: New tools for prediction and analysis in the behavior science. Unpublished Doctoral Dissertation, Harvard University.
- Xu, Y., Dai, Z., Chen, F., Gao, S., Pei, J., & Lai, L. (2015). Deep learning for drug-induced liver injury. *Journal of chemical information and modeling*, 55(10), 2085-2093.
- Yadav, N., Yadav, A., & Kumar, M. (2015). History of Neural Networks. In *An Introduction to Neural Network Methods for Differential Equations* (pp. 13-15). Springer, Dordrecht.
- Yang, S., Luo, P., Loy, C. C., & Tang, X. (2015). From facial parts responses to face detection: A deep learning approach. In *Proceedings of the IEEE International Conference on Computer Vision* (pp. 3676-3684).
- Yoo, Y., Tang, L. W., Brosch, T., Li, D. K., Metz, L., Traboulsee, A., & Tam, R. (2016). Deep learning of brain lesion patterns for predicting future disease activity in patients with early symptoms of multiple sclerosis. In *Deep Learning and Data Labeling for Medical Applications* (pp. 86-94). Springer, Cham.
- You, Y., Zhang, Z., Hsieh, C. J., Demmel, J., & Keutzer, K. (2017). 100-epoch ImageNet training with alexnet in 24 minutes. ArXiv e-prints.
- Yu, D., Eversole, A., Seltzer, M., Yao, K., Huang, Z., Guenter, B., ... & Droppo, J. (2014). An introduction to computational networks and the computational network toolkit. Microsoft Technical Report MSR-TR-2014-112.
- Yu, J., Weng, K., Liang, G., & Xie, G. (2013). A vision-based robotic grasping system using deep learning for 3D object recognition and pose estimation. In *Robotics and Biomimetics (ROBIO)*, 2013 IEEE International Conference on (pp. 1175-1180).
- Zeiler, M. D., & Fergus, R. (2013). Stochastic pooling for regularization of deep convolutional neural networks. arXiv preprint arXiv:1301.3557.
- Zeiler, M. D., Ranzato, M., Monga, R., Mao, M., Yang, K., Le, Q. V., ... & Hinton, G. E. (2013). On rectified linear units for speech processing. In *Acoustics, Speech and Signal Processing (ICASSP)*, 2013 IEEE International Conference on (pp. 3517-3521).
- Zhang, F., Du, B., Zhang, L., & Xu, M. (2016). Weakly supervised learning based on coupled convolutional neural networks for aircraft detection. *IEEE Transactions on Geoscience and Remote Sensing*, 54(9), 5553-5563.
- Zhang, Q., Xiao, Y., Dai, W., Suo, J., Wang, C., Shi, J., & Zheng, H. (2016). Deep learning based classification of breast tumors with shear-wave elastography. *Ultrasonics*, 72, 150-157.
- Zhang, R., Isola, P., & Efros, A. A. (2016). Colorful image colorization. In *European Conference on Computer Vision* (pp. 649-666). Springer, Cham.
- Zhang, Y., Sohn, K., Villegas, R., Pan, G., & Lee, H. (2015). Improving object detection with deep convolutional networks via bayesian optimization and structured prediction. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 249-258).
- Zhao, W., & Du, S. (2016). Spectral-spatial feature extraction for hyperspectral image classification: A dimension reduction and deep learning approach. *IEEE Transactions on Geoscience and Remote Sensing*, 54(8), 4544-4554.
- Zhihong, C., Hebin, Z., Yanbo, W., Binyan, L., & Yu, L. (2017). A vision-based robotic grasping system using deep learning for garbage sorting. In *Control Conference (CCC)*, 2017 36th Chinese (pp. 11223-11226).
- Zhu, Y., Urtasun, R., Salakhutdinov, R., & Fidler, S. (2015). segdeepm: Exploiting segmentation and context in deep neural networks for object detection. In *Computer Vision and Pattern Recognition (CVPR)*, 2015 IEEE Conference on (pp. 4703-4711).
- Zitnick, C. L., & Dollár, P. (2014). Edge boxes: Locating object proposals from edges. In *European Conference on Computer Vision* (pp. 391-405). Springer, Cham.

Zou, Q., Ni, L., Zhang, T., & Wang, Q. (2015).  
Deep learning based feature selection for  
remote sensing scene  
classification. *Geoscience and Remote  
Sensing Letters*, 12(11), 2321-2325.

## Deep Learning and Application Areas

### Extended abstract

*Deep learning is a part of learning a machine. From the beginning of the machine learning to the day-to-day, interest in artificial intelligence has increased steadily and has enabled the emergence of deep learning architects, the most commonly used artificial intelligence algorithms. Along with the deep learning architectures, many deep learning approaches have been developed for solving artificial intelligence problems. It produces intelligent solutions for a variety of fields such as industry, medicine, robotics, image processing, computer vision, object detection, sound processing-recognition, translation, future prediction, financial. In this study, deep learning architectures and algorithms were examined and their achievements were evaluated on the basis of their application areas in the literature. Deep learning architectures as well as libraries used for deep learning were included. However, there are deep learning architectures designed to solve different problems.*

*Machine learning involves computer-like approaches to decision-making. These decision-making approaches are situations that reflect human intellectual abilities such as visual, auditory, interpretation-based approaches, prediction, etc. At the base of machine learning is a mathematical modeling structure of a nerve cell. Artificial intelligence approaches have evolved from a neural cell to artificial human approaches called modern learning systems with many different approaches.*

*Deep learning has been put on top of previous approaches and results have been obtained with high accuracy. These deep learning approaches that were launched in 2006 and gradually become widespread in the following years bring together different architects. LeNet, AlexNet, VggNet, ZfNet, GoogleNet and many other deep learning architectures. Every architecture has moved towards achieving higher performance. The layered structures found in the architects have increased day by day and quite high-tier architects have been created.*

*Deep learning libraries have been developed with the purpose of enabling deep learning architects*

*to be used on different platforms and software. In these libraries, source code is provided to make architects more comfortable, to make additions to architects, to increase performance and to develop these approaches. There are libraries that can be used in many programming languages. Both the application software and the internet library are available. Open source libraries provide convenience for users dealing with deep learning. TensorFlow, Caffe, Theano, Torch, Deeplearning4j, Keras, Lasagne, Digit, Cognitive Network Toolkit, Pylearn2, Mxnet are some of the deep learning libraries. These libraries provide support for different programming languages. There are language support such as C / C ++, C #, Python, Matlab, Java, R programming, Javascript, Lisp, .Net, Julia, Haskell, Lua.*

*Deep learning architects use many areas. The most common areas are computer vision, classification, object detection, sound, medical, future prediction, finance, robotics. Many studies in these areas are used in today's technology. Studies such as translation systems, disease diagnostics, financial forecasting, drug production, robot vision, robot learning, voice recognition, image recognition, image classification, new image generation, image classification, object detection and image interpretation have been studied. It is included in many structures with the successful results obtained. Unmanned weather and land vehicles are one of the most obvious examples.*

*He has been actively involved in many aspects of human life. Hospitals are used in security systems, defense industry, production, financial systems. Many large companies are doing serious research to develop deep learning architects. Google, Microsoft, Baidu, IBM, Apple, Nvidia, Facebook, Twitter, Amazon are some of these companies.*

**Keywords:** *Deep learning, Artificial neural networks, Deep CNN, Convolutional neural networks.*