


SAĐLIKTA VERİ BİLİMİ



NECMİ GÜRSAKAL
Mart-2022

Teknoloji Çok Hızlı Gelişiyor

Teknoloji, verileri giderek daha erişilebilir hale getirdiğinden, *veri bilimi*, çeşitli endüstrilerdeki sorunlar hakkında nasıl düşündüğümüzü dönüştürmeye ve şekillendirmeye devam ediyor.

Veriler elektronik tıbbi kayıtlar (EMR), sigorta talepleri, hasta verileri, genetik bilgiler, klinik deneyler ve hatta sosyal medya aracılığıyla akarken, sağlık hizmetlerinde de veri bilimi çok sayıda alanda uygulanıyor. Kuruluşunuzun neresinde olursa olsun, veri bilimi bir dizi sorunu çözenize yardımcı olabilir.

Tıbbi Görüntüleme Nedir ve Tıbbi Görüntüleme ile Neler Yapılır?

- *Tıbbi görüntüleme*, genellikle vücudun içinin görüntülerini invaziv olmayan bir şekilde üreten teknikler seti olarak algılanır. Radyoloji, tomografi, endoskopi, termografi, tıbbi fotoğrafçılık ve mikroskopi bu çerçevede düşünülebilir.
- *Tıbbi görüntülemede neler yapılır*: Nesne, organ, bölge sınıflanır veya belirlenir; organlar veya lezyonlar segmente edilir. Segmente etmekten kasıt, ilgilendiğimiz bölgeyi belirlemektir.

WSI


Bilgisayar Destekli Tanı (CAD), patoloğların iş yükünü ve yanlış tanı oranını azaltabilir. Slaytın dijital sürümüne ise, “Tam slayt Görüntüsü (WSI)” adı veriliyor. WSI, patoloji slaytlarının bir bilgisayarda dijital olarak saklanması sağlar. *Sanal mikroskopi olarak da bilinen WSI, insan gözlemi ve otomatik görüntü analizi için dijital slaytlar yapmak üzere slaytları sayısallaştırmayı veya taramayı içerir.*

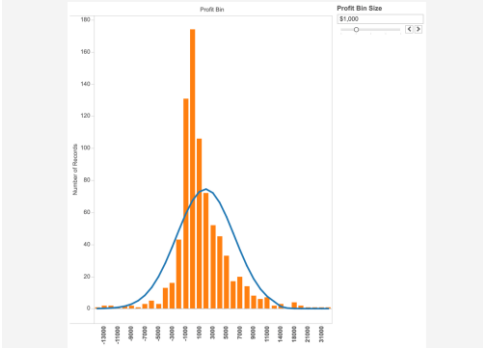
Li Xintong , Hu Weiming, Li Chen , Jiang Tao , Sun Hongzan , Li Xiaoyan , Huang Xinyu , Grzegorzek Marcin, “A State-of-the-art Survey of Artificial Neural Networks for Whole-slide Image Analysis: from Popular Convolutional Neural Networks to Potential Visual Transformers”, arXiv:2104.06243v3 [eess.IV] 26 Feb 2022

Veri bilimi nedir?

Veri bilimi, verilerden anlamlı içgörüler (kendi kendini anlama yeteneği) elde etmek için alan uzmanlığını, programlama becerilerini ve matematik ve istatistik bilgilerini birleştiren çalışma alanıdır.

Veri bilimi uygulayıcıları, normalde insan zekası gerektiren görevleri gerçekleştirmek için yapay zeka (AI) sistemleri üretmek için sayılara, metinlere, resimlere, videoya, sese makine öğrenmesi algoritmalarını uygularlar.





Veri Bilimi Klasik Bilimsel Yaklaşımdan Farklı mı?



- *Evet farklıdır, klasik bilimsel yaklaşımda önce hipotezler, kuramlar gelir. Bunlar daha sonra test edilir. Veri biliminde ise, veri önde gelir. Örneğin veriler normal dağılıma uymuyorsa, uydurmak için zorlanmaz, verinin bize ne anlattığı ile ilgilenilir.*
- Yine veri biliminde, verilerdeki aykırı değerlerin süreçleri, hastaları iyileştirmede, işimize yarayabileceği düşünülür.

Makine Öğrenmesi Tanımları

Makine Öğreniminin iki tanımını verelim. Arthur Samuel bunu "*bilgisayarlara açıkça programlanmadan öğrenme yeteneği veren çalışma alanı*" olarak tanımlamıştır. Bu tanım eski bir tanımdır.

Tom Mitchell ise daha modern bir tanım sunar: "Bir bilgisayar programının, P ile ölçülen çeşitli görevlerdeki performansı T, E deneyimi ile iyileşirse; o programın bazı görev sınıfları T ve performans ölçüsü P ile ilgili olarak E deneyiminden öğrendiği söylenir."

Denetimli ve Denetimsiz Öğrenme




Denetimli öğrenme algoritmaları, etiketlenmiş veri modeli ile çalışır. Denetimsiz ML algoritmaları, etiketlenmiş verileriniz olmadığında kullanılır.

Takviyeli öğrenme (Reinforcement Learning), bulunduğu ortamı algılayan ve kendi başına kararlar alabilen bir sistemin, hedefine ulaşabilmesinde ödüllendirme ve cezalandırma ile doğru kararlar almayı nasıl öğrenebileceğini gösterir.


Sınıflama ve kümeleme benzerdir. Ancak her iki tekniğin de bazı benzerlikleri olsa da, fark, sınıflandırmanın önceden tanımlanmış sınıfları kullanması, kümelemenin ise nesnelere arasındaki benzerlikleri tanımlaması, ortak özelliklere göre gruplaması ve onları diğerlerinden farklılaştırması gerçeğinde yatmaktadır. «Kestirim», bir algoritmanın geçmiş bir veri kümesi üzerinde eğitildikten sonra, bir müşterinin 30 gün içinde geri dönüp dönmeyeceği gibi belirli bir sonucun olasılığını tahmin eder.

Teşhis	Sınıflama
Yönetim	Kestirim
Keşif	Kümeleme

VERİLER



SINIFLAMA



KÜMELEME




Sınıflama ile kümeleme farkı

Sınıflama	Kümeleme
Model, verilen bir girdi için sınıflama yapar.	Model, verilen bir girdiyi veri kümelerinden birine atar.
Denetimli öğrenme kullanır.	Denetimsiz öğrenme kullanır.
Eğitim için etiketlenmiş veri gerekir.	Etiketlenmiş veri gerekmez.
Kategori sayısı bilinir.	Grup sayısı bilinmez.
Eğitim ve kestirim iki aşamalıdır.	Tek aşamalıdır.

SEGMENTASYON NEDİR?

BT taramaları, bir hastanın sađlığını anlamamıza yardımcı olabilecek çok sayıda bilgi içerir. *Veri bilimcilerin buradaki rolü, ölçülebilmesi veya nicelleştirilebilmesi için bilgiyi ortaya çıkarmaktır. BT veya MRI taramalarını analiz etmenin ilk adımı genellikle segmentasyondur.* Bununla, önemli yapılar segmentlere ayrılır. Segmentasyonlardan, bize hastalığın çeşitli yönleri hakkında bilgi veren organ hacmi, yüzey alanı, parlaklık ve doku desenleri gibi önemli özellikleri çıkarılır.

(Weston Alexander, "How to Segment a Pancreas CT", Towards Data Science, Jul 1, 2021, <https://towardsdatascience.com/how-to-segment-ct-pancreas-3a390acb3c70>)




Bilgisayar inekleri ya soldaki şekilde gibi siluetlerini belirleyerek (örnek segmentasyonu) ya da sağdaki şekilde gibi ineklerin etrafına sınırlayıcı kutular çizerek, nesne algılama yaparak sayacaktır. Kullanacağımız derin öğrenme modelini eğitmek için bu fotoğraflara benzer çok sayıda fotoğraf çekilecek ve çok sayıda kişinin bu fotoğrafları emek yoğun bir şekilde etiketlemesi gerekecek.



(Source: Nikolenko Sergey I., Synthetic Data for Deep Learning, Springer Optimization and Its Applications, 2021, 030-75178-4 (eBook)
<https://doi.org/10.1007/978-3-030-75178-4>, p. 3)

PENCERELEME (Windowing)

Segmentasyona başlamadan önce, taramanın kontrastının ayarlanması gerekir. Buna "pencereleme" denir. CT kontrastı, havaya (HU = -1000) ve suya (HU = 0) normalize edilen Hounsfield birimleri ile ölçülür.



Eksenel (sol), sagital (orta) ve koronal (sağ) düzlemlerde bitmiş pankreas segmentasyonu. Bu segmentasyon yaklaşık 20 dakika sürmüştür.



Bir görüntünün otomatik olarak alt yazılarını oluşturmak, bilgisayarla görmenin birincil hedeflerinden biridir. Altyazı oluşturma modelleri yalnızca bir görüntüde hangi nesnelerin bulunduğunu belirlemeye yönelik bilgisayarla görme zorluklarını çözecek kadar güçlü değil, aynı zamanda bunların ilişkilerini de doğal bir dilde yakalayıp ifade edebilmelidir.

(Xu Kelvin, Ba Lei Jimmy, Kiros Ryan, Cho Kyunghyun, Courville Aaron, Salakhutdinov Ruslan, Zemel Richard S., Bengio Yoshua, “Show, Attend and Tell: Neural Image Caption Generation with Visual Attention”, arXiv:1502.03044v3 [cs.LG] 19 Apr 2016)



A large white bird standing in a forest.



A woman holding a clock in her hand.



A man wearing a hat and a hat on a skateboard.



A person is standing on a beach with a surfboard.



A woman is sitting at a table with a large pizza.



A man is talking on his cell phone while another man watches.

CNN

Yapay Sinir Ađı Nedir?

Yapay bir sinir ađının temelinde iki bileşeni vardır: İşlem elemanları ve bunların arasındaki bağlantılar. İşlem elemanlarına nöron adı verilir. Nöronlar arasındaki her bağlantı ile ilgili bir ağırlık söz konusudur. Her bir nöron, komşu nöronlardan uyarı alır, enformasyonu işler ve bunu çıktıya dönüştürür.

Bir yapay sinir ađı katmanlardan oluşur:

Girdi katmanı, gizli katmanlar ve çıktı katmanı.

Farklı işlem elemanları (nöronlar) ve farklı bağlantılar kullanılarak farklı yapay sinir ađı mimarileri oluşturulabilir.

Konvolüsyon: Birinin şeklinin diğeri tarafından nasıl değıştirildiğini ifade eden üçüncü bir fonksiyon üretmek için iki fonksiyon (f ve g) üzerinde matematiksel bir işlemdir. Convolution terimi hem sonuç fonksiyonunu hem de onu hesaplama sürecini ifade eder.

1 _{x1}	1 _{x0}	1 _{x1}	0	0
0 _{x0}	1 _{x1}	1 _{x0}	1	0
0 _{x1}	0 _{x0}	1 _{x1}	1	1
0	0	1	1	0
0	1	1	0	0

Image

4		

Convolved
Feature

- *Konvolüsyonel sinir ağı*, çeşitli bilgisayar görme görevlerinde baskın hale gelen ve radyoloji de dahil olmak üzere çeşitli alanlarda ilgi çeken bir derin öğrenme yöntemleri sınıfıdır.
- *Konvolüsyonel sinir ağı*, konvolüsyon katmanları, havuzlama katmanları ve tam bağlantılı katmanlar gibi birden çok yapı taşından oluşur ve bir geri yayılım algoritması aracılığıyla özelliklerin hiyerarşilerini otomatik ve uyarlanabilir bir şekilde öğrenmek için tasarlanmıştır.
- *Konvolüsyonel sinir ağının* kavramları ve avantajları ile sınırlamalarına aşinalık, radyolog performansını ve nihayetinde hasta bakımını iyileştirme potansiyelinden yararlanmak için esastır.


Yamashita Rikiya, Nishio Mizuho, Do Gian Kinh Richard, Togashi Kaori, “Convolutional neural networks: an overview and application in radiology”, [Insights into Imaging](https://insightsimaging.springeropen.com/articles/10.1007/s13244-018-0639-9#Sec3) volume 9, pages611–629 (2018),
<https://insightsimaging.springeropen.com/articles/10.1007/s13244-018-0639-9#Sec3>

Konvolüsyonel Sinir Ağı (CNN)

Bir Konvolüsyonel Sinir Ağı (CNN), bir girdi görüntüsünü alabilen, görüntüdeki çeşitli yönler/nesnelere önem (öğrenilebilir ağırlıklar ve önyargılar) atayan ve birini diğerinden ayırt edebilen bir Derin Öğrenme algoritmasıdır.

CNN'in mimarisi, insan beynindeki nöronların bağlantı modeline benzer ve görsel korteksin organizasyonundan ilham almıştır.

Perceptron






Tek katmanlı yapay sinir ağı olan perceptron, yapay sinir ağlarının temel bileşenidir. 1957 yılında Frank Rosenblatt tarafından icat edilen sınıflandırma algoritmasıdır. Yani bir girdinin hangi çıktı sınıfına ait olduğuna karar vermeye yarayan bir algoritmadır.

Perceptron Beş Bileşenden Oluşur:

1. *Girdiler*: Bunlar, sahip olduğumuz bağımsız değişkenlerdir (x).
2. *Ağırlıklar*: Ağırlık parametreleri (w) girdiler ve nöronlar arasındaki bağlantının gücünü kontrol eder. Bağımsız bir değişkenin sonuca etkisini temsil ettiği de söylenebilir.
3. *Bias değeri*(b): Çıkış değerinin kontrol edilmesini sağlayan sabit bir değerdir. Ayrıca tüm girdilerin sıfır olması halinde işlemin devam etmesini sağlar.
4. *Aktivasyon Fonksiyonları*: Aktivasyon fonksiyonu (f) nöronun çıkışını belirli koşullara göre tanımlar.
5. *Çıktı*: Bağımlı değişken (y), bulmak istediğimiz sonuçtur. Perceptron'larda sonuç, sınıf 1 ve 0 olmak üzere iki sınıfa ayrılır.

Aktivasyon Fonksiyonu

Bir aktivasyon fonksiyonu, ađın verilerdeki karmařık kalıpları öğrenmesine yardımcı olmak için bir yapay sinir ađına eklenen bir fonksiyondur. Beynimizde bulunan nöron temelli bir modelle karşılaştırıldığında, *aktivasyon fonksiyonu sonunda bir sonraki nörona neyin gönderileceđine karar verir. Bir yapay sinir ađında bir aktivasyon fonksiyonu, bir önceki hücreden gelen çıkıř sinyalinu alır ve onu bir sonraki nöronun girdi olarak alabileceđi bir forma dönüřtürür.*



AlexNet (2012)

AlexNet, ağırlıkları olan 8 katman içerir. 5 konvolüsyon katmanı ile 3 tam bağlantılı katmanı bulunur. Yapay sinir ağı AlexNet 9216 düğüme sahiptir. Her katmanın sonunda, sonuncusu hariç ReLu aktivasyonu gerçekleştirilir.

Modelin 62 milyon parametresi ve 600 milyon bağlantısı bulunmaktadır.

Modelin parametreleri, ağırlıklar ve bias'lardan oluşur.

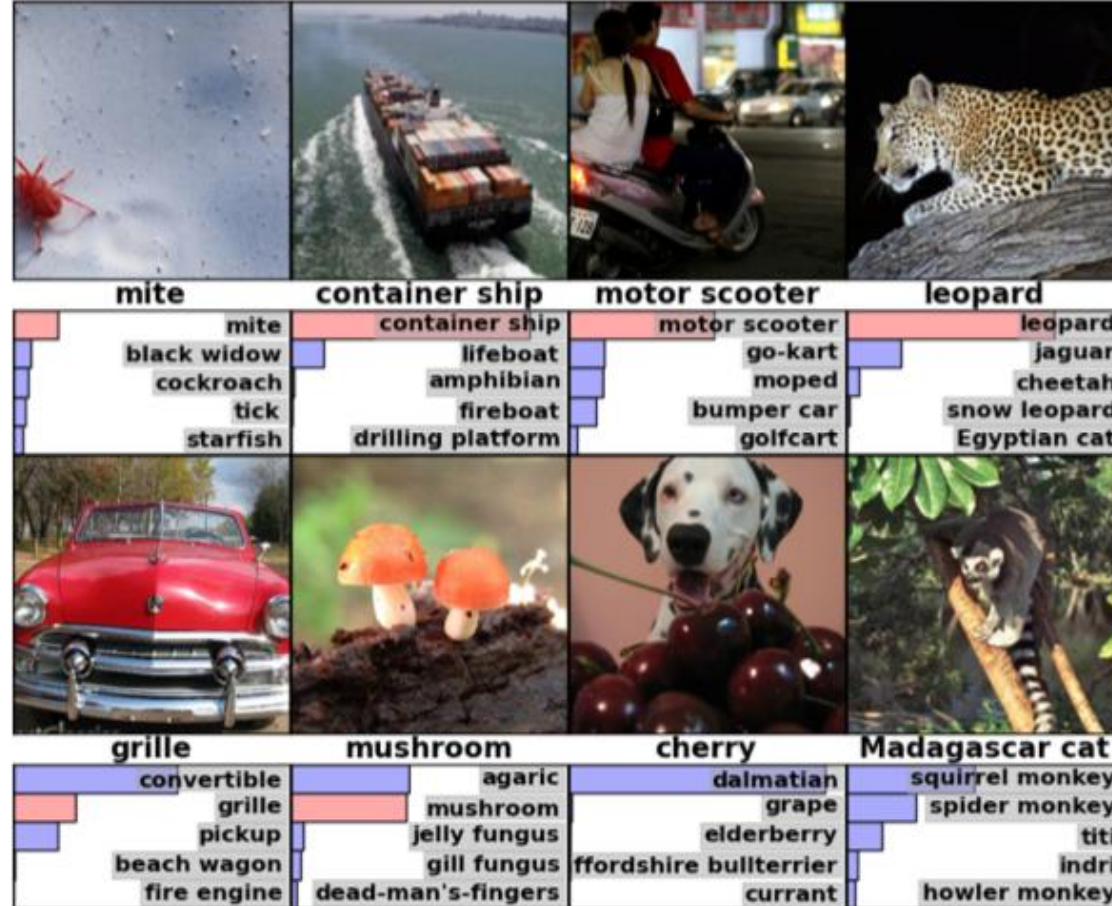
Krizhevsky Alex, Sutskever Ilya, Hinton E. Geoffrey, "ImageNet Classification with Deep Convolutional Neural Networks", [Advances in Neural Information Processing Systems 25 \(NIPS 2012\)](#)

Parametre sayısının hesaplanması için bkz.: <https://learnopencv.com/number-of-parameters-and-tensor-sizes-in-convolutional-neural-network/#:~:text=In%20a%20CNN%2C%20each%20layer,of%20all%20weights%20and%20biases.&text=%3D%20Number%20of%20weights%20of%20the,biases%20of%20the%20Conv%20Layer>

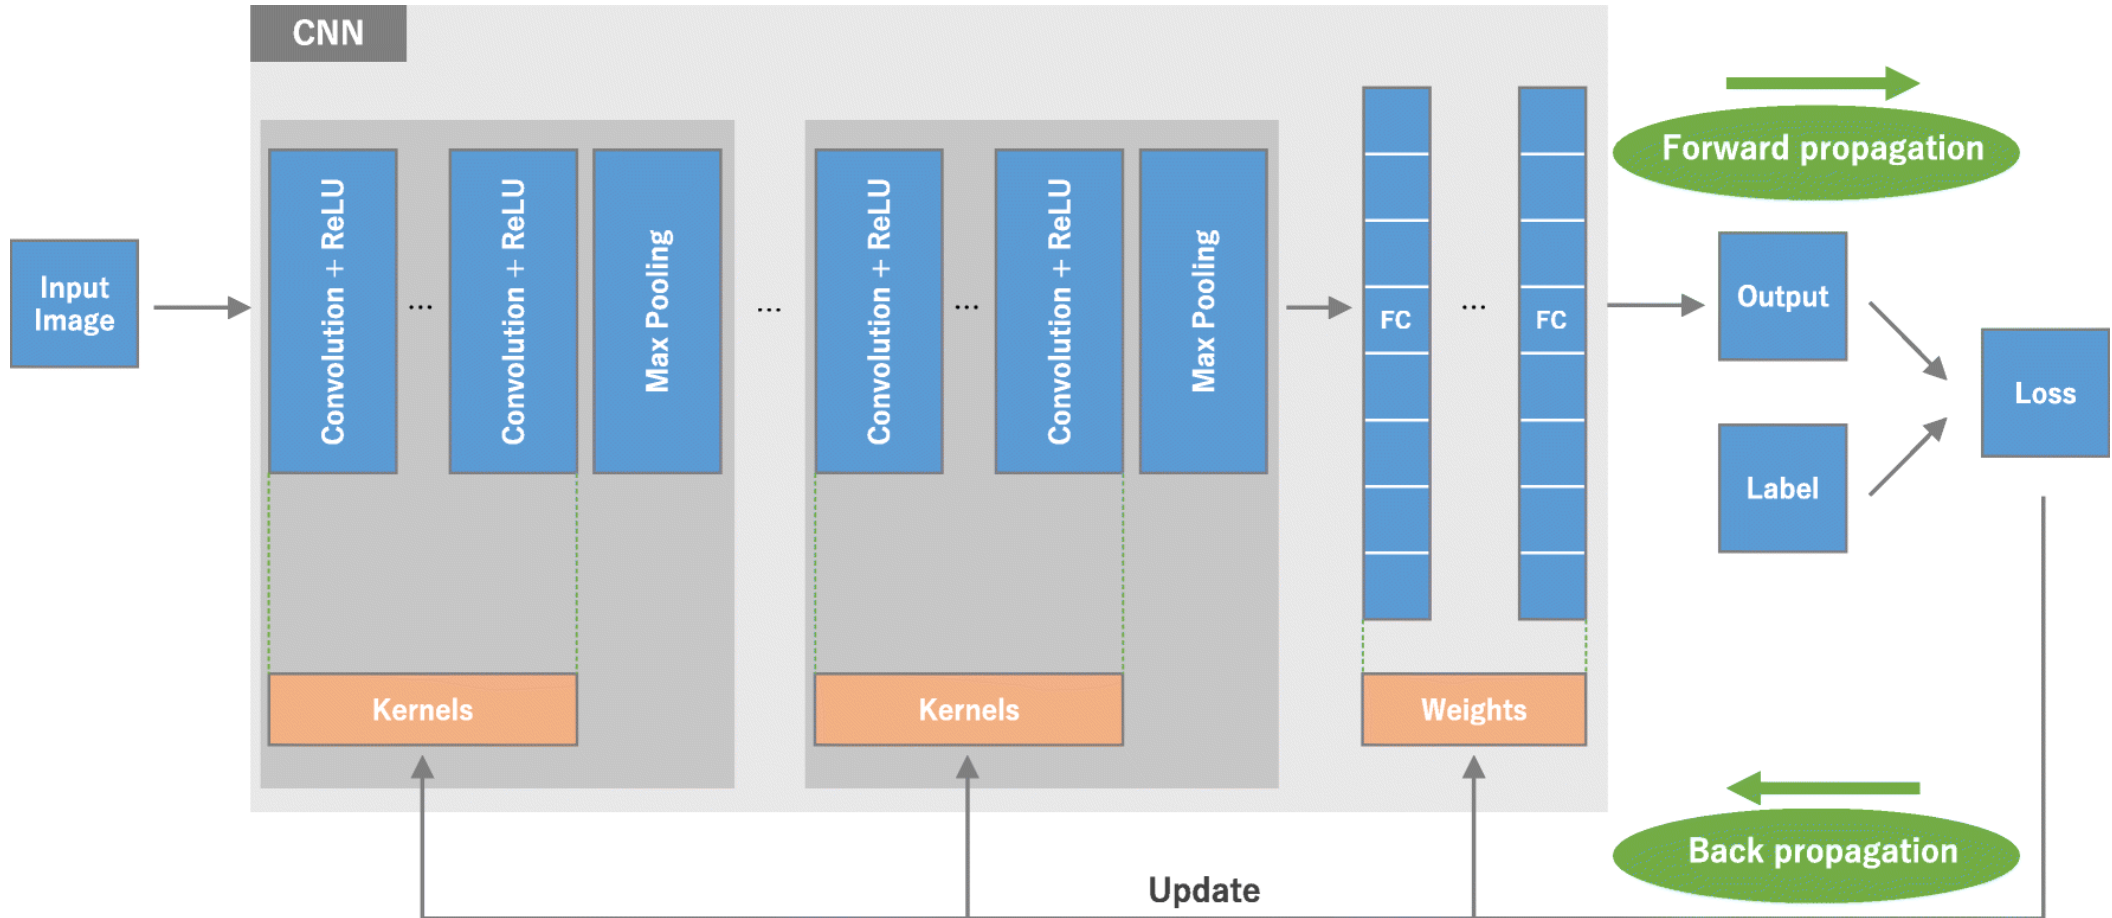


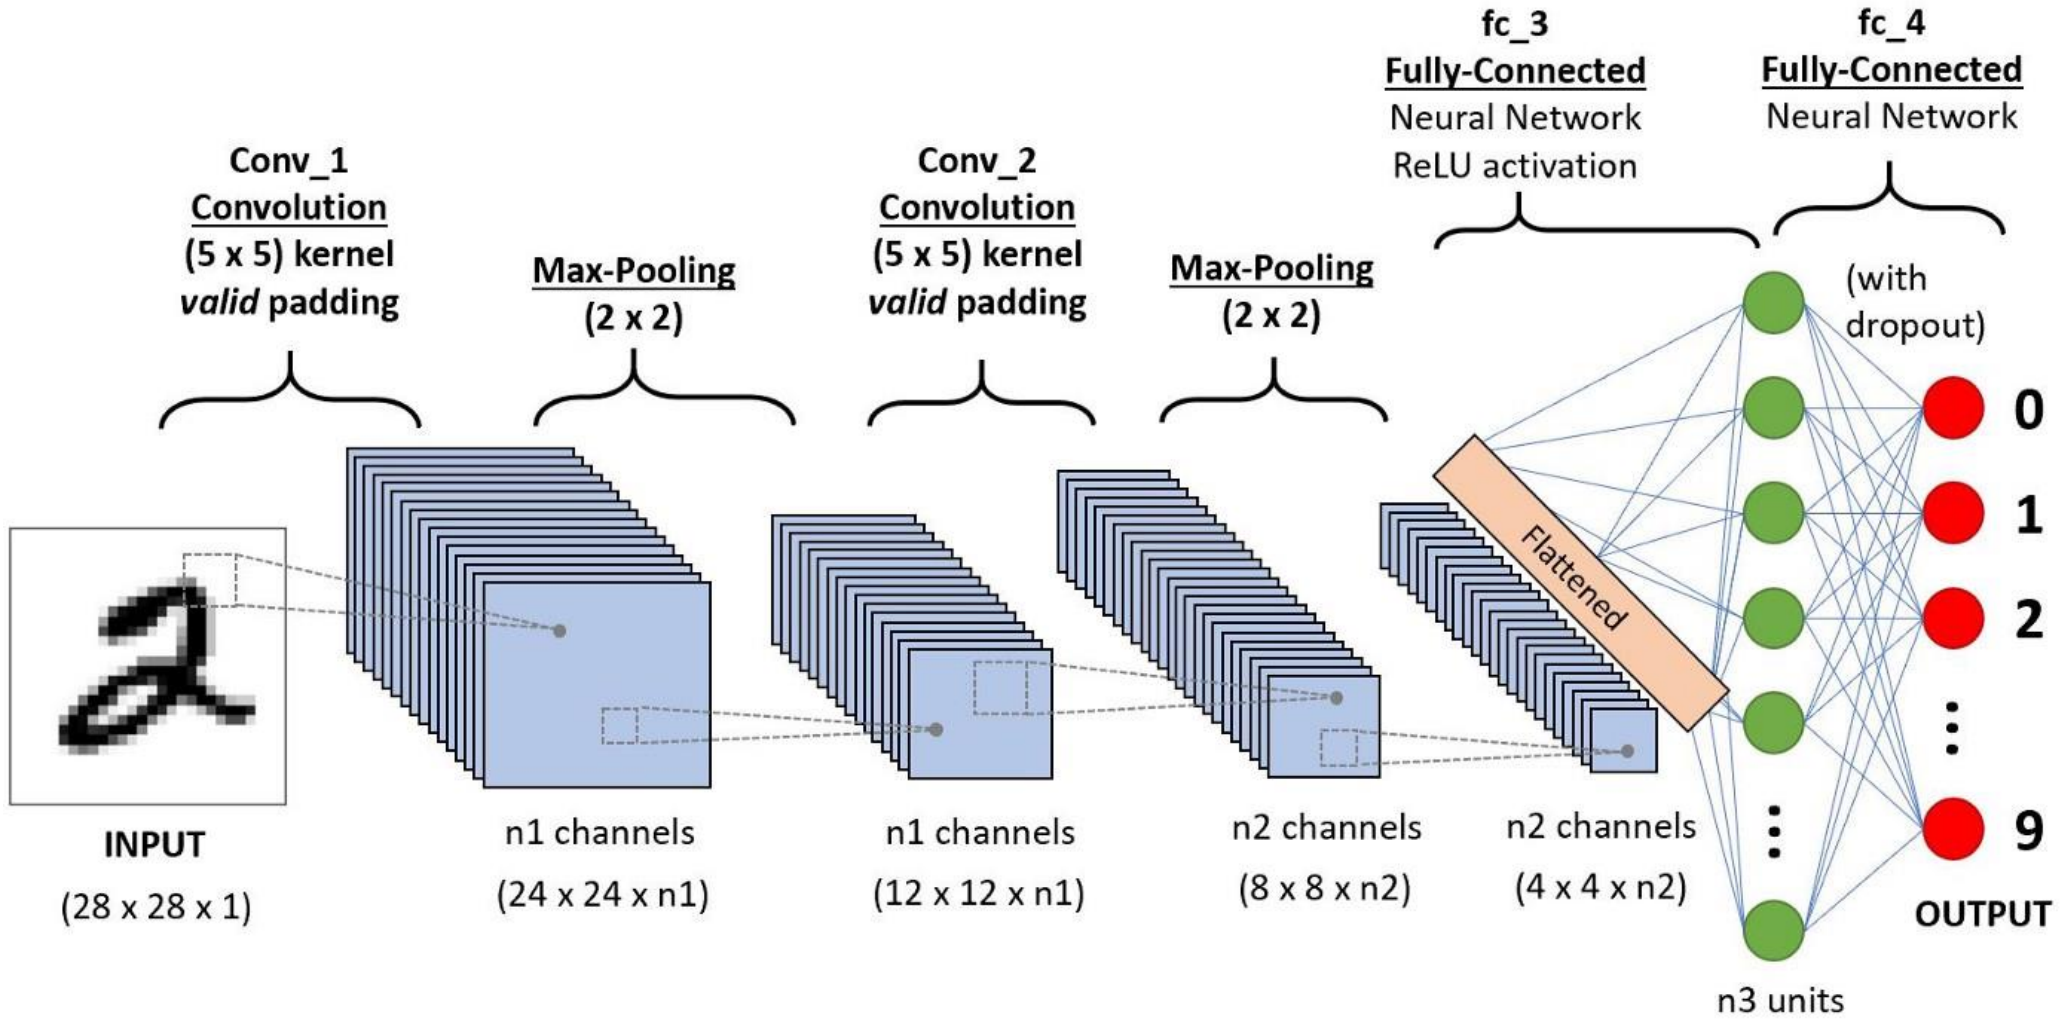
AlexNet Sonuçları

Sekiz ImageNet görüntüsünde
 AlexNet'in en olası etiketleri.
 Her görüntünün altına doğru etiket yazılır
 ve her etikete atanan olasılık da çubuklarla gösterilir.



CNN





Whole data



Training data Validation data Test data



Training a model



Monitoring model performance



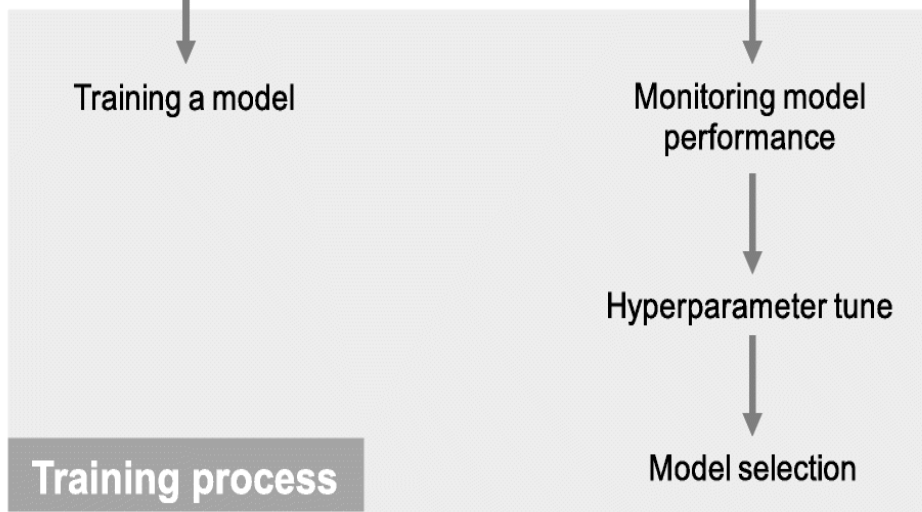
Hyperparameter tune



Model selection



Evaluation of final model performance



Training process

Tıbbi Görüntüleme Analizinde Derin Öğrenme

“Son zamanlardaki gelişmiş derin öğrenme teknolojileri, yüksek doğruluk, verimlilik, kararlılık ve ölçeklenebilirlik ile tıbbi görüntü analizinde büyük başarı elde etti. Yüksek kaliteli büyük ölçekli veri kümelerine yönelik yüksek talepleri azaltabilecek teknolojik gelişmeler, bu alandaki gelecekteki gelişmelerden biri olabilir”.

(Liu Xiaoqing et.al.,“Advances in Deep Learning-Based Medical Image Analysis”, Health Data Science, Volume 2021 | Article ID 8786793 | <https://doi.org/10.34133/2021/8786793>)

DeepPatient

Bu gelişmiş AI algoritması, Mount Sinai Hastanesi tarafından kullanılan Derin Hasta'dır. Doktor ziyaretleri ve hastanın test sonuçları da dahil olmak üzere 700.000'den fazla kişiden gelen veriler algoritmaya aktarıldı.

Mount Sinai ekibi etkinliğini test ettiğinde, AI algoritması, hasta kayıtlarına dayalı hastalıkları tahmin etmede oldukça doğruydü.

Ancak şaşırtıcı olan, bir kişinin gelecekte şizofreni veya başka psikiyatrik bozukluklara yatkın olup olmadığını da tahmin edebilmesidir. Ekibe liderlik eden Yeni Nesil Sağlık Enstitüsü Müdürü PhD Joel Dudley, bu tür gelişmiş AI modelleri oluşturabileceklerini ancak nasıl çalıştıkları hakkında hiçbir fikirleri olmadığını itiraf etti.

Burada, klinik tahmine dayalı modellemeyi kolaylařtıran EHR verilerinden genel amaçlı bir hasta modeli tretmek iin yeni bir denetimsiz derin zellik ğrenme yntemi sunuyoruz. zellikle, Mount Sinai veri ambarından yaklařık 700.000 hastanın toplu EHR'lerinde hiyerarřik dzenlilikleri ve baėımlılıkları yakalamak iin  katmanlı bir grlt giderici otomatik kodlayıcı yığını kullanıldı. Sonu, “DeepPatient” olarak adlandırdığımız bir model oldu. eřitli klinik alanlardan ve zamansal pencerelerden 78 hastalık ieren 76.214 test hastasını kullanarak deėerlendirme yapıldı. Sonularımız, ham EHR verilerine ve alternatif zellik ğrenme stratejilerine dayalı modeller kullanılarak elde edilenlerden nemli lde daha iyi performans gsterdi. řiddetli diyabet, řizofreni ve eřitli kanserler iin tahmin performansı en iyi performans gsterenler arasındaydı.


Miotto, R., Li, L., Kidd, B. *et al.* Deep Patient: An Unsupervised Representation to Predict the Future of Patients from the Electronic Health Records. *Sci Rep* **6**, 26094 (2016). <https://doi.org/10.1038/srep26094>



Electronic Health Records


- Clinical Notes
- Diagnoses
- Medications
- Laboratory Tests
- Demography
- Etc.

Raw Patient Dataset




A

Unsupervised Deep Feature Learning



C


Deep Patient Dataset



TEMEL KAVRAMLAR

- Etiketleme
- Bias
- Kernel
- Geri yayılım algoritması(Back propagation algorithm)
- Gradyan İniş (Gradient descent)
- Tensor
- Özellik Haritası
- Doldurma (Padding)
- Adım (Stride)
- Havuzlama Katmanı
- Maksimum Havuzlama (Max pooling)
- Kayıp Fonksiyonu

Etiketleme



Bias

Teknik olarak, bias ortalama model tahmini ile temel gerek arasındaki hata olarak tanımlanabilir. Ayrıca bias, modelin eğitim veri seti ile ne kadar iyi eşleştiğini açıklar. Daha yüksek bias'a sahip bir model, veri seti ile yakından eşleşmeyecektir.


Düşük sapmalı bir model, eğitim veri seti ile yakından eşleşecektir.

Yüksek bias'a sahip bir modelin özellikleri şunları içerir:

- Uygun veri trendlerini yakalayamama
- Düşük uyuma yönelik potansiyel
- Daha genelleştirilmiş/aşırı basitleştirilmiş bir model
- Yüksek hata oranı

Kernel


Makine öğrenmesinde, genellikle doğrusal olmayan bir sorunu çözmek için doğrusal bir sınıflandırıcı kullanma yöntemine verilen addır. Burada “kernel” (çekirdek), doğrusal olarak ayrılamayan verilerin doğrusal olarak ayrılabilenlere dönüştürülmesini sağlar. «Kernel» için bir tür matematiksel sihirbazlık da diyebiliriz.



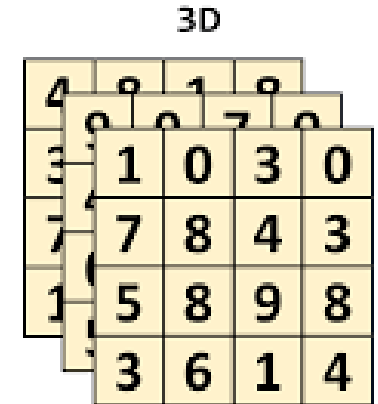

Tensor


Bir tensor, matematiksel bir veri yapısında verileri düzenlemenin bir yoludur ve bunlar üzerinde matematiksel işlemleri doğrusal cebirde tanımlayan bir dizi kuraldan başka bir şey değildir. Bir tensor, bir vektör veya verileri gösteren $n \times m$ boyutlu bir matristir

(3,2,5) tensor

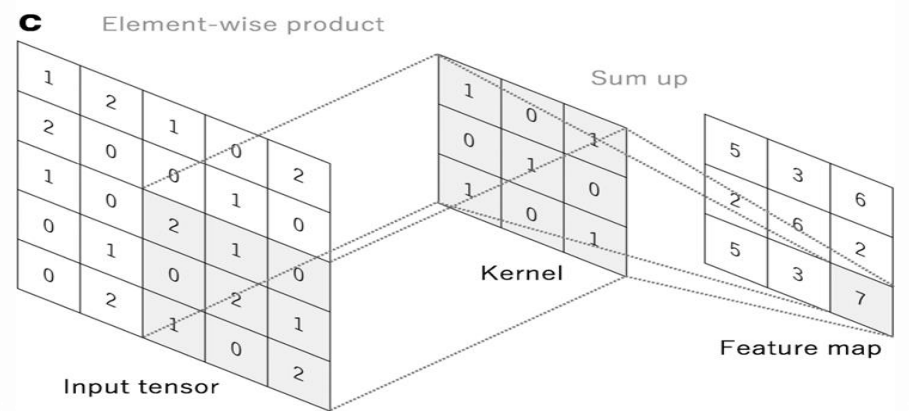
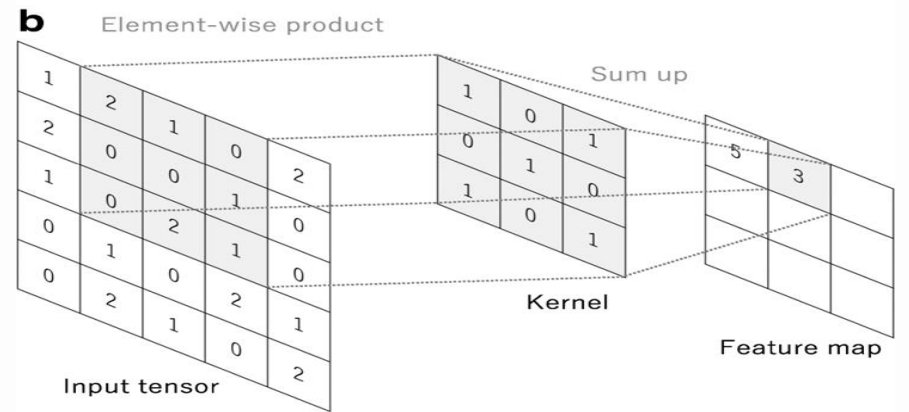



(3,2,4,5) Tensor





$$\begin{aligned} 0 \times 0 + 1 \times 1 + 3 \times 2 + 4 \times 3 &= 19, \\ 1 \times 0 + 2 \times 1 + 4 \times 2 + 5 \times 3 &= 25, \\ 3 \times 0 + 4 \times 1 + 6 \times 2 + 7 \times 3 &= 37, \\ 4 \times 0 + 5 \times 1 + 7 \times 2 + 8 \times 3 &= 43. \end{aligned}$$

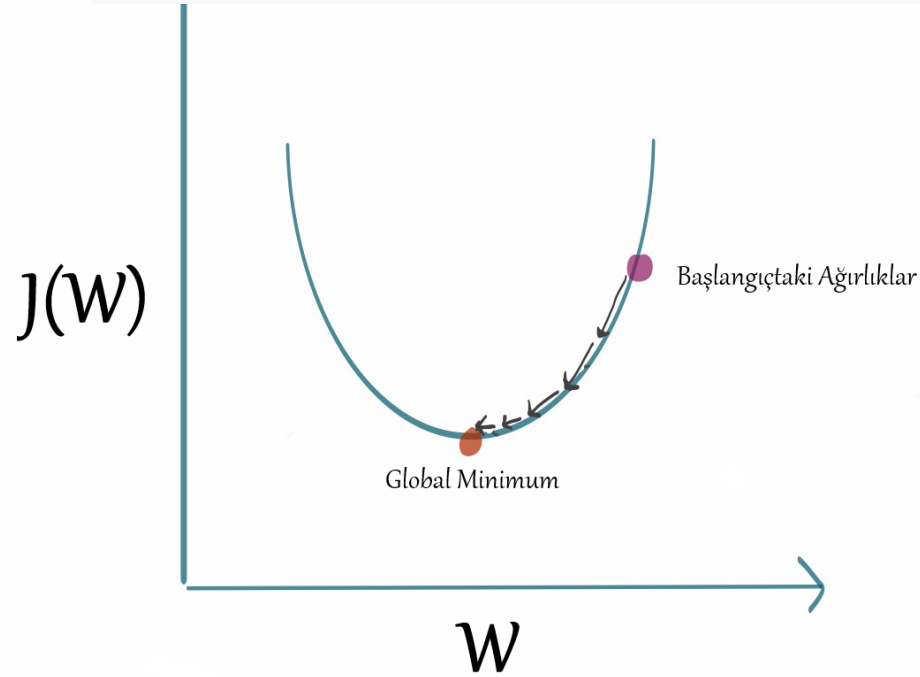


Geri yayılım algoritması(Back propagation algorithm)

Bu algoritma hataları çıktıdan girdiye doğru azaltmaya çalışmasından dolayı geri yayılım ismini almıştır. Gradyan azalma olarak adlandırılan bir teknik kullanarak ağırlık alanındaki hata fonksiyonunun minimum değerini arar.

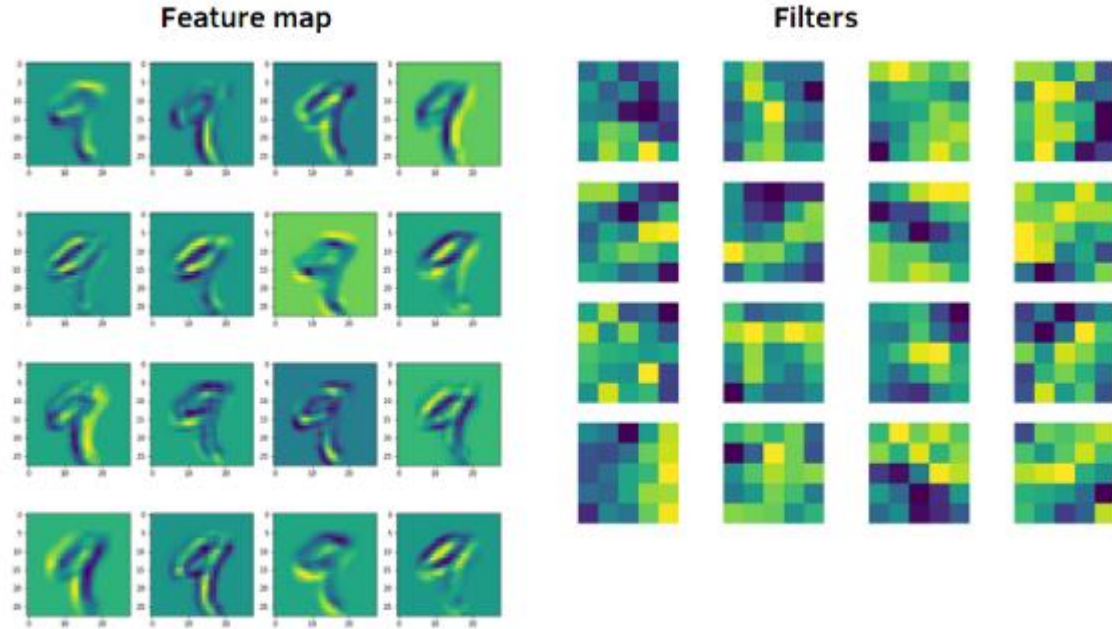
Gradyan azalma:

Gradyan azalma, bir maliyet fonksiyonunu (maliyet) en aza indiren bir fonksiyonun (f) parametrelerinin (katsayılarının) deęerlerini bulmak için kullanılan bir optimizasyon algoritmasıdır.




Özellik haritası (Feature map)

Özellik haritası, önceki katmana uygulanan bir filtrenin çıktısıdır ve çıktılar özellik haritasında toplanır.



Yüzler ve otomobillerin özellikleri



Padding (Doldurma):

Temel olarak, bir konvolüsyonel sinir ağının işlediği bir görüntünün alanını genişletir.

Görüntü üzerinde hareket eden kernel (çekirdek/filtre) her pikseli tarar ve görüntüyü daha küçük bir görüntüye dönüştürür.

Stride (adım)

Adım, görüntü veya video üzerindeki hareket miktarını değiştiren sinir ağının filtresinin bir parametresidir.

Örneğin, bir sinir ağının adımı 1'e ayarlanırsa, filtre bir seferde bir piksel veya birim hareket eder.

Havuzlama Katmanı

Havuzlama katmanı, konvolüsyon katmanından sonra eklenen yeni bir katmandır. Konvolüsyon katmanından sonra bir havuz katmanının eklenmesi, belirli bir modelde bir veya daha fazla kez tekrarlanabilen bir konvolüsyonel sinir ağı içindeki katmanları sıralamak için kullanılan yaygın bir modeldir.


- Özellik haritalarındaki özelliklerin algılanması için altörnekleme (downsampling) ile havuzlama yapılır. Altörnekleme bir sinyalin örnekleme oranını azaltma işlemidir. Bu genellikle veri hızını veya veri boyutunu azaltmak için yapılır.
- Konvolüsyonel bir sinir ağında bu işlem, ortalama ve maksimum havuzlama ile hesaplanır ve uygulanır.
- Ortalama Havuzlama: Özellik haritasındaki her bir yama için ortalama değer hesaplanır.
- Maksimum Havuzlama (veya Maksimum Havuzlama): Özellik haritasının her bir yaması için maksimum değer hesaplanır.

Maksimum Havuzlamanın Yapılması


1. Büyüklüğü 2 veya 3 olan bir pencere seç
2. Genelde büyüklüğü 2 olan bir adım seç
3. Bu pencere ile görüntüleri filtrele
4. Her pencerede maksimum değeri seç

Maksimum havuzlama (Max Pooling)

Maksimum havuzlama, her özellik haritasının her bir yamasındaki maksimum veya en büyük değeri hesaplayan bir havuzlama işlemidir.



Ortalama havuzlama



Kayıp Fonksiyonu

Matematiksel optimizasyon ve karar teorisinde, bir kayıp fonksiyonu veya maliyet fonksiyonu (bazen bir hata fonksiyonu olarak da adlandırılır), bir veya daha fazla deęişkenin bir olayını veya deęerlerini gerçek bir sayı üzerine eşleyen bir fonksiyondur. Bir optimizasyon problemi, bir kayıp fonksiyonunu en aza indirmeye çalışır.


MAKİNE ÖĞRENMESİ DEDIĞİMİZ İŞTE:

- Algoritmaların verileri modellemek için kullandıklarını,
- Makinenin verilerdeki desenleri belirlediğini ve bu desenleri bir model oluşturmak için kullandığını,
- Modeli, sürekli modelin tartılarını değiştirerek iyileştirdiğini,
- Ve bütün bunları minimum insan müdahalesi ile yaptığını unutmayalım.

A handwritten digit '3' in a cursive style, enclosed in a thin white rectangular border. The digit is white on a black background.A handwritten digit '3' in a cursive style, enclosed in a thin white rectangular border. The digit is white on a black background.A handwritten digit '3' in a cursive style, enclosed in a thin white rectangular border. The digit is white on a black background.




784



YouTube.com/learnandcode - Learn to code and grow your career.

Sistem verilen sayısının 9 olduğunu 0.97 olasılıkla düşünüyor.





=



+



=



+



=




+





+



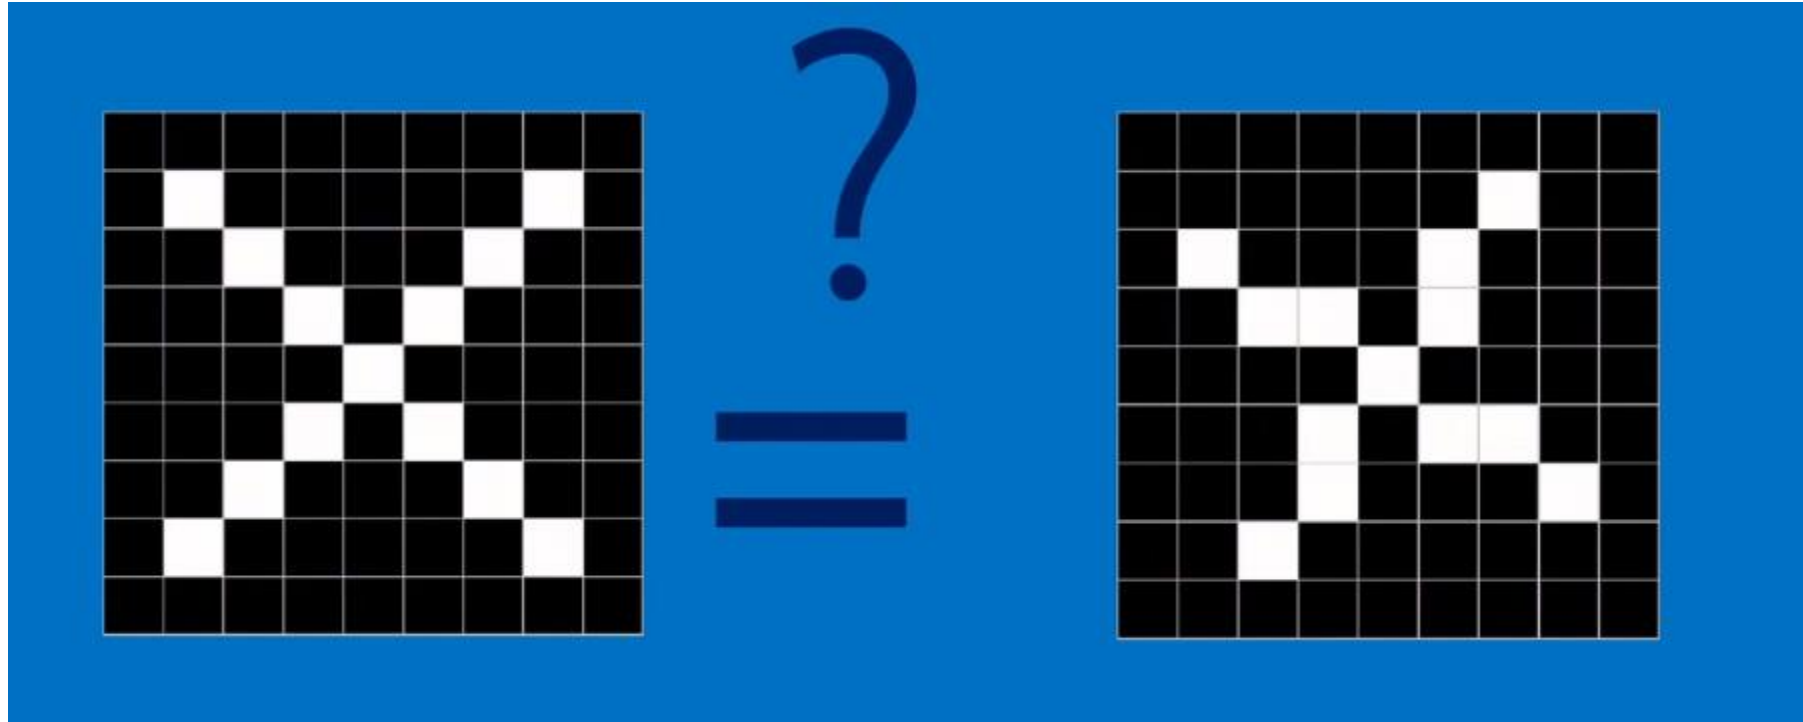
Varsayalım ki bilgisayarın sınıflama yapmasını istiyoruz:




Bu şekiller kaydırılmış, ölçeği değiştirilmiş, döndürülmüş veya tartılandırılmış olabilir



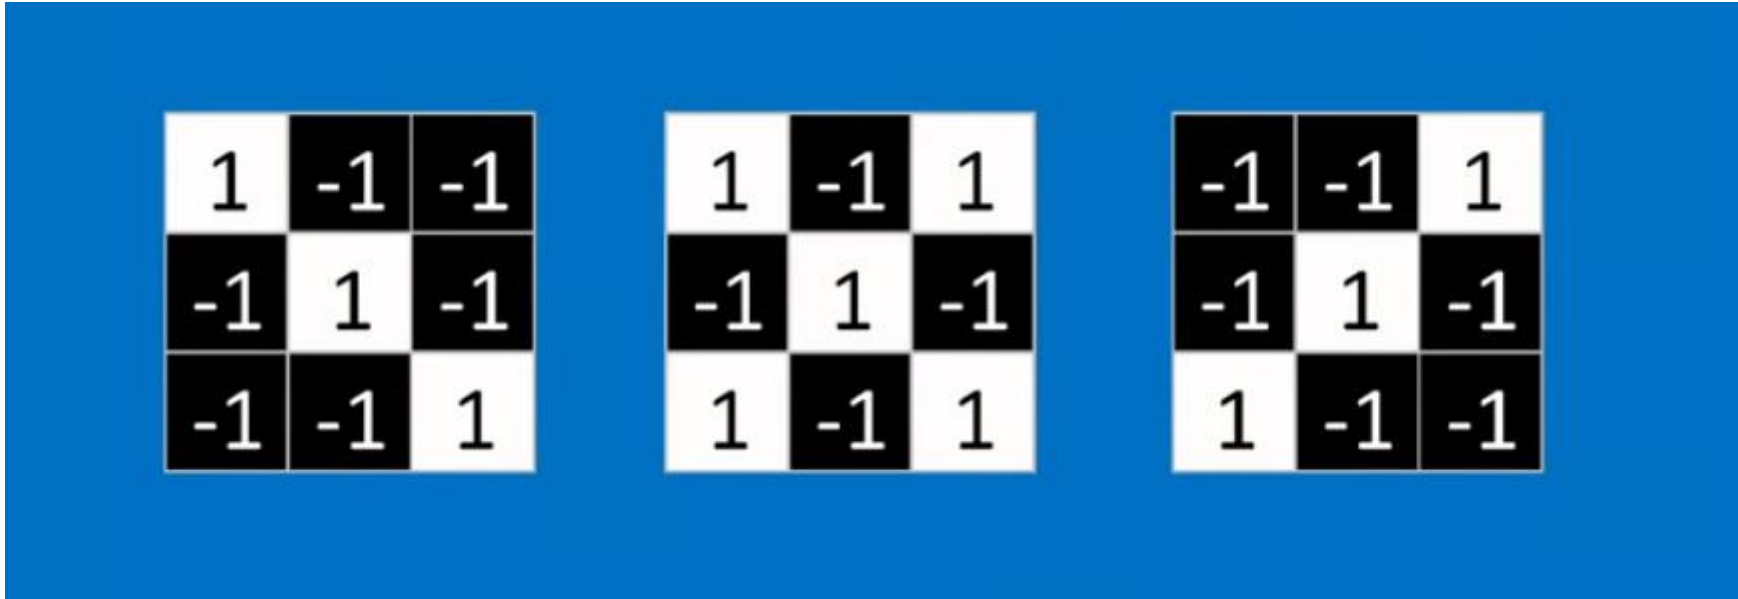
Bu nedenle karar vermek kolay deęildir



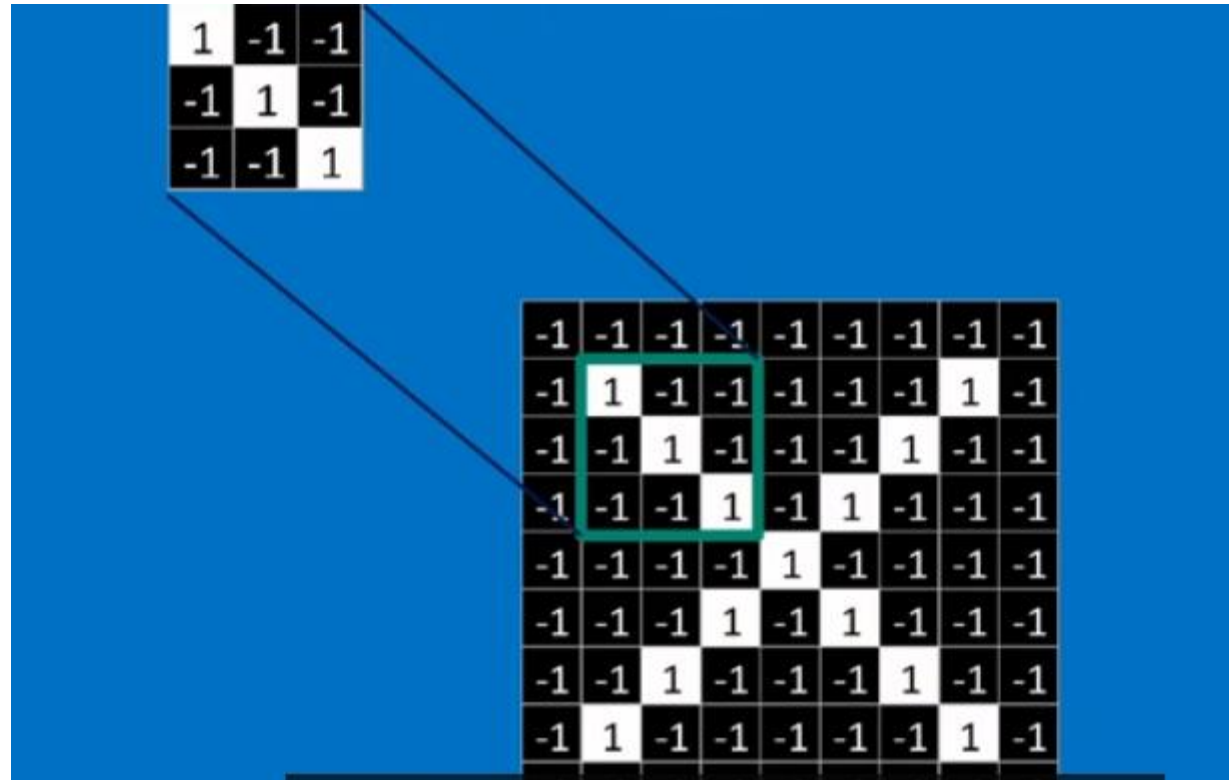
Convolution ağırları görüntünün parçalarını birbirine uydurarak çalışır.



Bu türden küçük parçalara görüntünün özellikleri (features) adı verilir ve bunlarla çalışılır.



Bu uyumu bulmaya «filtreleme» adı verilir.



Filtreleme nasıl yapılacak?

1. Özellik ile görüntünün ona karşı gelen parçasını alın,
2. Görüntü parçasının her bir pikselini ona karşı gelen özellik pikseli ile çarpın
3. Toplayın
4. Özellikteki toplam piksel sayısına bölün.

Bir konvolüsyonel sinir ağı bağlamında, bir konvolüsyon, girdi ile bir dizi ağırlıkların çarpılmasını içeren doğrusal bir işlemdir. Tekniğin iki boyutlu girdi için tasarlandığı göz önüne alındığında, çarpma işlemi bir dizi girdi verisi ile filtre veya çekirdek olarak adlandırılan iki boyutlu ağırlık dizisi arasında gerçekleştirilir. Filtre, girdi verisinden daha küçüktür ve girdinin filtre boyutlu bir yaması ile filtre arasında uygulanan çarpma türü bir nokta çarpımdır. Nokta çarpım, girişin filtre boyutundaki yaması ile filtre arasındaki eleman bazında çarpımdır, bu daha sonra toplanır ve her zaman tek bir değerle sonuçlanır.

Spesifik olarak, filtre, giriş verilerinin üst üste binen her parçasına veya filtre boyutundaki yamasına, soldan sağa, yukarıdan aşağıya sistematik olarak uygulanır. Filtre, girdideki belirli bir özellik türünü algılamak için tasarlanmışsa, bu filtrenin tüm girdi görüntüsüne sistematik olarak uygulanması, filtrenin bu özelliği görüntünün herhangi bir yerinde keşfetmesine olanak tanır.


Örneğin, aşağıda dikey çizgileri algılamak için elle hazırlanmış bir 3×3 eleman filtresi verilmiştir:

```
0.0, 1.0, 0.0  
0.0, 1.0, 0.0  
0.0, 1.0, 0.0
```

Bir yatay çizgi detektörü de oluşturulabilir ve görüntüye uygulanabilir, örneğin:

```
0.0, 0.0, 0.0  
1.0, 1.0, 1.0  
0.0, 0.0, 0.0
```

Ve bu işi her olası karşılaştırma için yapmamız gerekir



UYGULAMALAR

Andrew Ng diyor ki:



«Sağlık hizmetine bakın. Her hastanenin elektronik sağlık kayıtları için biraz farklı formatı vardır. Her hastane kendi özel yapay zeka modelini nasıl eğitebilir? Her hastanenin BT personelinin yeni sinir ağı mimarileri icat etmesini beklemek gerçekçi değildir. Bu ikilemden çıkmanın tek yolu, müşterilere verileri tasarlamak ve alan bilgilerini ifade etmek için araçlar vererek kendi modellerini oluşturmalarını sağlayan araçlar oluşturmaktır».

CİDDİ GÖĞÜS HASTALIKLARININ ÇOK KATEGORİLİ SINIFLANDIRICISI — FAST.AI

Ching Daniel, “Multi-category classification of various chest conditions from chest x-rays”,
Towards data Science, Dec 23, 2021,

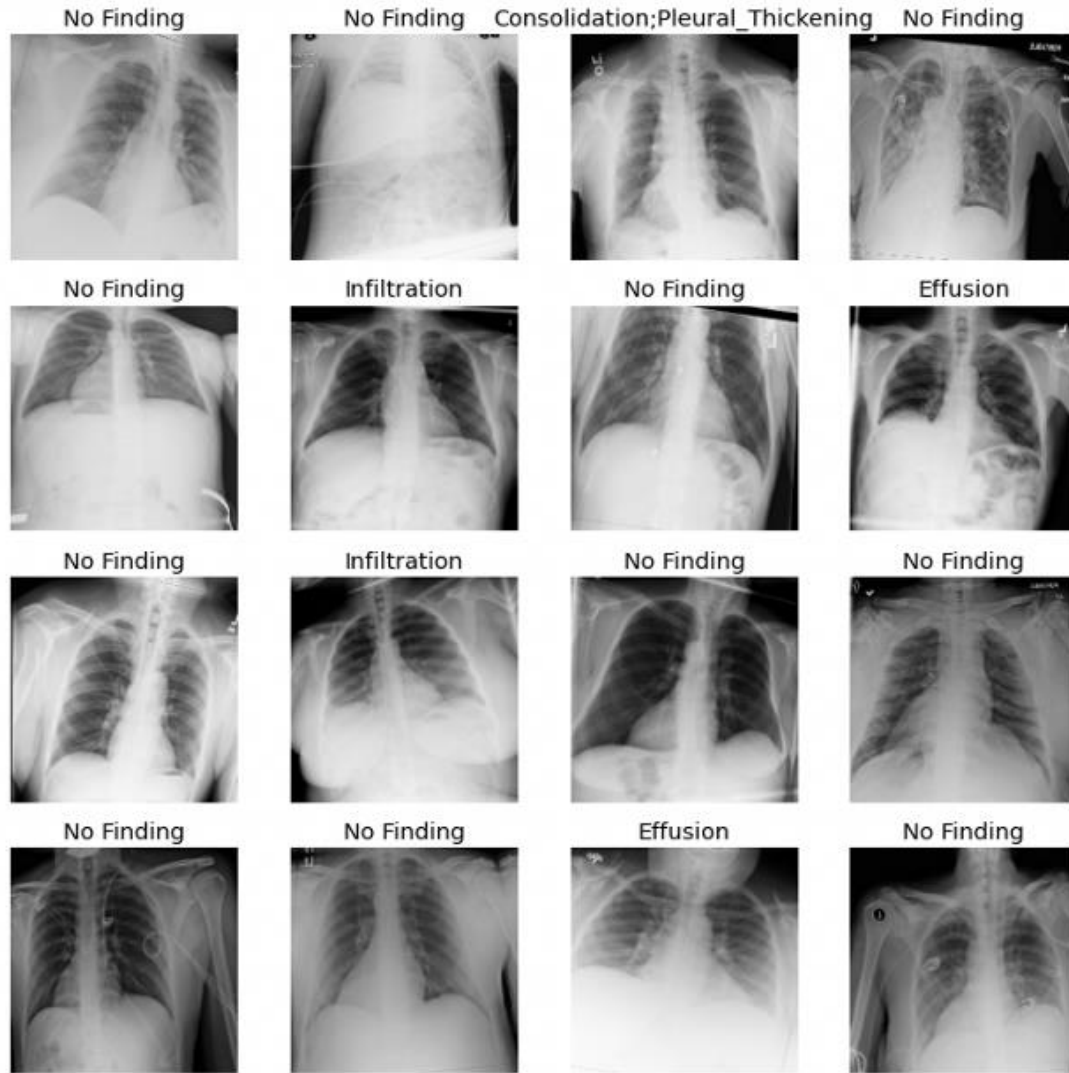
<https://towardsdatascience.com/multi-category-classification-of-various-chest-conditions-from-chest-x-rays-1d6428522997>

Teşhis insan gücü eksikliğini kısmen hafifletmek için, hastanın ön sınıflamasını yapmak için bir bilgisayarlı görme modeli kullanabiliriz. Bunun için, çok kategorili koşulları sınıflandırma arayışımızda bize yardımcı olması için fast.ai kitaplığını kullanabiliriz – yani, fast-ai ile birden fazla koşula sahip bir görüntü verildiğinde, model her bir koşulun ortaya çıkma olasılığını tahmin edebilir.

Modelimizi eğitmek için NIH Göğüs Röntgeni veri setinin daha küçük bir "örnek" versiyonunu kullanıyoruz. Veriler, orijinal 112.000 görüntüden 5606 görüntüye küçültüldü. Bununla birlikte, bu veri kümesi, çeşitli kategorilerdeki görüntülerin ana veri kümesiyle aynı yapısını ve görelî dağılımını korur <https://www.kaggle.com/nih-chest-xrays/sample>

Bu modelin eğitilmesi yaklaşık 19 ila 20 dakika sürdü ve yaklaşık %92.8 doğruluk sağladı.

▶ dls.show_batch(max_n=16)



Microsoft Azure Machine Learning kullanımı

Python not defterlerimizin amacı, Azure Machine Learning'in veri ve model yönetimi, dağıtım, deney izleme ve açıklanabilirlik gibi alanlarda tıbbi görüntülemeyi ve diğer kullanım durumlarını desteklemek için nasıl kullanılabileceğini göstermektir. Ayrıca, PyTorch ile manuel model geliştirmeden görüntüler için otomatik makine öğrenimine kadar çeşitli veri bilimi yaklaşımlarını ele alıyoruz.


[Kopp Andreas, Alkemade Harmke](https://towardsdatascience.com/medical-imaging-with-azure-machine-learning-b5acfd772dd5), "Medical Imaging with Azure Machine Learning",
Towards Data Science, Dec 20, 2021,
<https://towardsdatascience.com/medical-imaging-with-azure-machine-learning-b5acfd772dd5>

OTOMATİK MAKİNE ÖĞRENMESİ İLE KAN HÜCRESİ TESPİTİ

AutoML for Images daha sonra optimize etmek istediğimiz belirli bir performans metriği (ör. sınıflandırma doğruluğu) için ön işleme, sinir ağı mimarisi ve hiperparametrelerin en iyi kombinasyonunu bulmaya yardımcı olur. AutoML for Images şu anda aşağıdaki bilgisayarlı görü mimarilerine dayalı olarak çok sınıflı ve çok etiketli sınıflandırmayı, nesne algılamayı ve örnek segmentasyonu desteklemektedir.

Veri: <https://www.kaggle.com/surajitmbccd-dataset>

En iyi kan hücresi nesne algılama modelimizi çalışırken görmek için aşağıdaki gibi birkaç test örneğine dayalı tahminler sunuyoruz:



Felç konusunda iki Örnek

Felç, dünya çapında önde gelen ölüm ve sakatlık nedenlerinden biri ve sağlık sistemleri için çok büyük bir yük oluşturuyor. Son çalışmalar felç lezyonu segmentasyonunda muazzam bir başarı sağladı. Chen ve arkadaşları, akut iskemik lezyonları segmentlere ayırmak için girdi olarak difüzyon ağırlıklı görüntüleme (DWI) kullandılar ve 0.67'lik bir ortalama Dice skoru elde ettiler. (Bu skor genellikle görüntü segmentasyon yöntemlerinin performansını ölçmek için kullanılıyor).

(L. Chen, P. Bentley, and D. Rueckert, "Fully automatic acute ischemic lesion segmentation in dwi using convolutional neural networks," *Neuroimage Clin*, vol. 15, pp. 633–643, 2017).

Clerigues ve arkadaşları ise, multimodal MRI görüntülerini kullanarak akut ve subakut felç lezyonu segmentasyonu için bir derin öğrenme metodolojisini önerdiler ve iki segmentasyon görevinin Dice skorlarını sırasıyla 0.84 ve 0.59 olarak buldular.

(A. Clèrigues, S. Valverde, J. Bernal, J. Freixenet, A. Oliver, and X. Lladó, "Acute and sub-acute stroke lesion segmentation from multimodal MRI," *Computer Methods and Programs in Biomedicine*, vol. 194, article 105521, 2020).

Kalp Konusunda

Ekokardiyografi, CT ve MRI, kardiyovasküler sistemin işlev ve yapısının değerlendirilmesinde yaygın olarak kullanılan tıbbi görüntüleme yöntemleridir. Bunlardan alınan görüntülerin otomatik analizi, doktorların kalp kasının yapısını ve işlevini incelemesine, hastanın kalp yetmezliğinin nedenini bulmasına, olası doku hasarlarını belirlemesine yardımcı olabilir.

Vigneault ve arkadaşları, 10 kurumu kapsayan çok merkezli bir araştırmada, tam otomatik tam kalp segmentasyonu için Ω -Net adında yeni bir derin CNN mimarisi oluşturdular. Ağ, elde edilen verilerle beş ön plan sınıfını (dört kardiyak oda artı LV miyokardı) segmentlere ayırmak için eğitildi.

D. M. Vigneault, W. Xie, C. Y. HodDavid, D. A. Bluemke, and J. A. Noble, “ Ω -Net (Omega-Net): fully automatic, multi-view cardiac MR detection, orientation, and segmentation with deep neural networks,” *Medical Image Analysis*, vol. 48, pp. 95–106, 2018.

Karaciğer Konusunda

Karaciğer Lezyonu belirlenmesi ve segmentasyonunda Vorontsov ve arkadaşları karaciğer tümörlerini saptamak ve segmentlere ayırmak için derin CNN'ler kullandılar.

E. Vorontsov, M. Cerny, P. Régnier et al., "Deep learning for automated segmentation of liver lesions at CT in patients with colorectal cancer liver metastases," *Radiology: Artificial Intelligence*, vol. 1, no. 2, article 180014, 2019.

Kemik Konusunda

Ortopedik travma olarak da adlandırılan kemik kırığı yaygın bir hastalıktır. X-ışını görüntülerinde kemik kırığı tanıma, derin öğrenme teknolojisinin gelişmesiyle 2017'den beri umut verici bir araştırma yönü haline geldi. Genel olarak bu konuda, kemik kırığı tanıma için sınıflandırma tabanlı yaklaşım ve nesne tanıma tabanlı yaklaşım olmak üzere iki ana yaklaşım vardır.

Sınıflandırmaya dayalı yaklaşım için, arařtırmacılar genellikle tüm görüntü için “kırık yok” ve “kırık var” etiketlerini kullanırlar. Sınıflandırma boru hattının öncü çalışması Olczak ve arkadaşları tarafından yapıldı. Sınıflandırma hattının omurgası olarak VGGNet'i benimseyerek modeli, kırıkları tanımak için bileklerin, ellerin ve ayak bileklerinin 256.000 iyi etiketlenmiş görüntüsü ile eğittiler. Büyük miktarda doğrulayıcı veri ile model, %83 doğruluk için güçlü ve güvenilir bir temel oluşturdu.

J. Olczak, N. Fahlberg, A. Maki et al., “Artificial intelligence for analyzing orthopedic trauma radiographs,” *Acta Orthopaedica*, vol. 88, no. 6, pp. 581–586, 2017.

Veri Bilimi öğrencileri Blake Allen, Tony Di Sera, Simon Li, Kevin Martin ve Victor Wang, Screen Ahead Rx projesi ile, kanser ilacının altında yatan özelliklere ve kanser hücrelerinin DNA'sındaki değişikliklere dayalı olarak *bir ilacın belirli bir kanseri tedavi etmede ne kadar etkili olacağını başarılı bir şekilde tahmin eden bir makine öğrenmesi modeli geliştirdiler.*

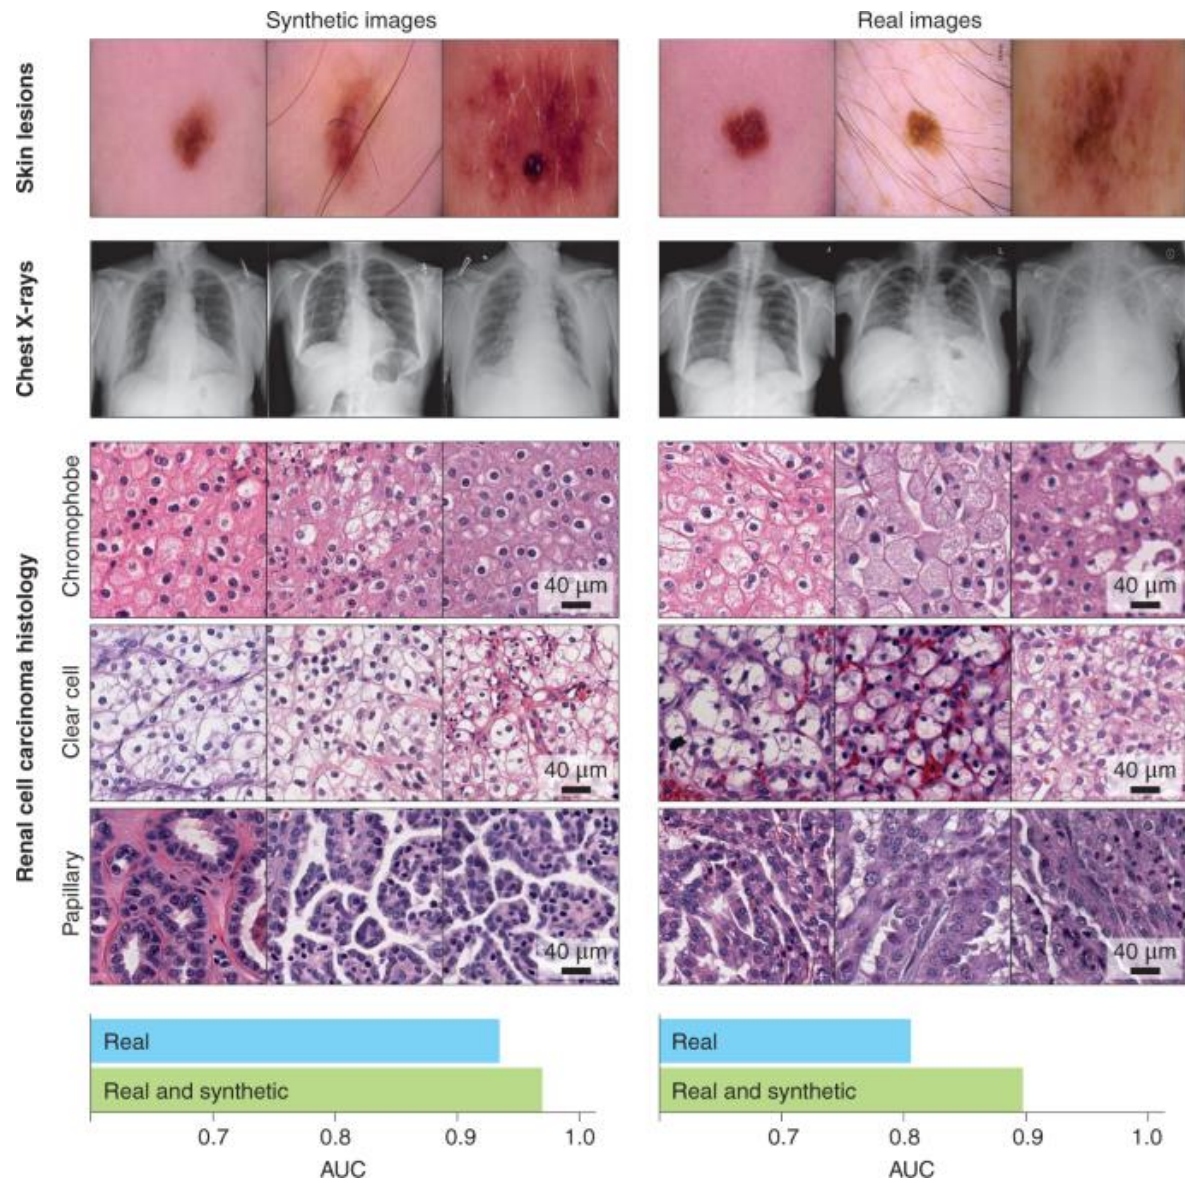
“Project Uses Machine Learning to Predict Cancer Drug Efficacy”, Sept 7, 2021, <https://medium.com/berkeleyischool/project-uses-machine-learning-to-predict-cancer-drug-efficacy-4dadef1f8ac>

Sentetik tıbbi veriler

Üst: Deri lezyonlarının ve ön göğüs röntgenlerinin sentetik ve gerçek görüntüleri. Orta: renal hücreli karsinomun üç alt tipinin sentetik ve gerçek histoloji görüntüleri.

Alt: histoloji görüntülerinin bağımsız bir veri kümesinin sınıflandırma performansı için, her bir alt türün 10.000 gerçek görüntüsü ile eğitilmiş bir derin öğrenme modeli ve gerçek görüntü veri kümesiyle eğitilmiş aynı model tarafından yapılan sınıflandırma performansı için (AUC) altındaki alanlar her alt türün 10.000 sentetik görüntüsüyle zenginleştirilmiştir.


(Chen J.Richard, Lu Y.Ming, Chen Y.Tifany, Williamson F. K. Drew, Mahmood Faisal , “Synthetic data in machine learning for medicine and healthcare”, Nature, Vol 5, 15 June, 2021, <https://www.nature.com/articles/s41551-021-00751-8.pdf>, p.494)



Denetimsiz özellik öğrenme ve sınıflandırmanın, heterojen bir GBM doku kesitlerine uygulanması. Sol ve sağ görüntüler sırasıyla orijinal ve sınıflandırma sonuçlarına karşılık gelir. Renk kodlaması siyah (tümör), pembe (nekroz) ve yeşildir (nekroza geçiş).

(Nayak [Nandita](#), [Chang Hang](#), [Borowsky Alexander](#), [Spellman paul](#), [Parvin Bahram](#), "Classification of tumor histopathology via sparse feature learning", Proc IEEE Int Symp Biomed Imaging. 2013 Apr;


2013, doi: 10.1109/ISBI.2013.6556499)



BEYİN GERÇEKTEN YAPAY SİNİR AĞLARI GİBİ Mİ
ÇALIŞIR?

DERİN SİNİR AĞI


Derin bir sinir ağı, her katmanın girdi verilerini daha soyut temsillere dönüştürdüğü bir katmanlar hiyerarşisinden oluşur (örneğin, kenar->burun->yüz)






Jeff Hawkins 1986 yılından başlayarak birkaç yıl Intel’de yazılım mühendisi olarak çalışmış. Sonra DNA’nın çifte sarmalını bulan F.H.C. Crick’in, “Beyini Düşünmek” adlı bir denemesi onun hayatını değiştirmiş ve sinirbilim ile ilgilenmeye başlamış. Şimdilerde Silikon Vadisi’nde biyolojik beyin ve yapay zeka konusunda çalışan, neokorteksi incelemeye odaklanmış Numenta adlı bir şirketi yönetiyor ve 2021 yılı Mart ayı başında, “Bin Beyin: Yeni Bir Zeka Teorisi” adlı bir kitabı çıktı.

Hawkins, “eski beyin” ile “yeni beyin” arasında bir ayırım yapıyor. Ona göre “yeni beyin” memeli neokorteksi. Neokorteks insanlarda insan beyninin dışını saran, yaklaşık 2.5 mm. kalınlığında, büyük bir yemek peçetesi boyutunda, buruşuk bir tabaka. Eğer genel yapay zekaya ulaşmak istiyorsak, neokorteksi anlamalıyız. Yine Hawkins’e göre neokorteks, zeka organı. Zeka olarak düşündüğümüz tüm yetenekler, görme, dil, müzik, matematik, bilim, mühendislik neokorteks tarafından yaratılmış durumda. Zekayı anlamak istiyorsak, neokorteksin ne yaptığını ve nasıl yaptığını anlamalıyız.



Hawkins'e göre "derin öğrenme" temelde eksik, ona göre zekanın en azından dört önemli niteliği var: Hareket ederek öğrenmek, her biri dünyanın kısmi bir resmini içeren on binlerce kortikal sütun, sürekli öğrenme ve bilgiyi referans çerçevelerini kullanarak yapılandırmak. "Bin beyin" deyimini on binlerce kortikal sütundan geliyor. Üç mm. uzunluğunda ve 1 mm² alanında kortikal sütunlar aşağıda görülüyor.



KISITLAMALAR VE BİR EK

2B görüntüler bilgisayarla görmede sıklıkla kullanıldığı için, *2B görüntüler (2B-CNN) için geliştirilen derin öğrenme ağları, radyolojide elde edilen 3B görüntülere [ince dilimli BT veya 3B manyetik rezonans görüntüleme (MRI) görüntüleri] doğrudan uygulanmaz. Derin öğrenmeyi 3B radyolojik görüntülere uygulamak için özel mimariler gibi farklı yaklaşımlar kullanılır.*

- Tıbbi görüntüleme teknikleriyle birlikte kullanılan optik çözünürlükler genellikle 100.000 pikseldir ve günümüzün bilgisayarlı görme sinir ağı mimarilerinin kapasitesini çok aşmaktadır.
- Tıbbi hasta bilgileri aklımıza gelen en hassas verilere aittir. Bu nedenle, gizlilik büyük bir endişe kaynağıdır. Korunan hasta verilerine dayalı makine öğrenmesi modellerini kullanmanın veya eğitmenin düzenleyici ve mahremiyet üzerindeki etkileri konusunda sağlık kuruluşları arasında çok fazla belirsizlik vardır.

([Kopp Andreas, Alkemade Harmke](#), “Medical Imaging with Azure Machine Learning”, Towards Data Science, Dec 20, 2021, <https://towardsdatascience.com/medical-imaging-with-azure-machine-learning-b5acfd772dd5>)


Konvolüsyonel sinir ađları 3 boyutlu da olabiliyor

“Yöntemimiz, 3B konvolüsyonel sinir ađına beslenen, 3B çerçevede ele alınan protein yapılarının tensor tabanlı bir temsilini kullanır ve giriş yapılarında bağlanma 'sıcak noktaların' olasılık puanları ve koordinatları ile sonuçlanır”.

Kozlovskii Igor, Popov Petr, “Protein–Peptide Binding Site Detection Using 3D Convolutional Neural Networks”, J. Chem. Inf. Model. 2021, 61, 8, 3814–3823, Publication Date: July 22, 2021, <https://doi.org/10.1021/acs.jcim.1c00475>

Yapay zeka ile protein yapısının çözülmesi

- Önce Go oyununda şampiyonu yenen DeepMind, araştırmacıların 50 yıldır çözmeye çalıştığı biyolojideki en önemli ve karmaşık bulmacalardan biri olan proteinlerin yapısını tahmin etmek ile uğraşüyor. Proteinlerin üç boyutlu yapısı, vücutta nasıl davrandıklarını ve etkileşime girdiklerini belirler. Ancak çok sayıda önemli protein, biyologların henüz bilmediği yapılara sahiptir. Bunları doğru bir şekilde tahmin etmek için AI'yı kullanmak, kanserden covid'e kadar hastalıkları anlamaya yardımcı olacak paha biçilmez bir araç sunacaktır. Örneğin, SARS-CoV-2'nin sivri uçlu proteininin yapısı, virüsün hücrelerinize bağlanmasını sağlar.
- Protein veritabanında şu anda yaklaşık 800.000 giriş var ve DeepMind, gelecek yıl 100 milyondan fazla - bilimin bildiği neredeyse her proteini - ekleyeceğini söylüyor.



«Son on yılda Amerikan hastanelerinin yüzde doksanından fazlası bilgisayarlarla donatıldı ve Amerikalıların yarısından fazlasının sağlık bilgileri Epic sisteminde bulunuyor.

Epic ile ilgili bir eğitim seansında, cerrahların yaşları otuz ile yetmiş arasında değişiyordu. *Tahminen cerrahların yaklaşık yüzde altmışı erkek ve yüzde yüzü hastaları görmek yerine orada olmak zorunda olmaktan rahatsızdı».*

(Gawande Atul, “Why Doctors Hate Their Computers”, New Yorker, [November 12, 2018 Issue](https://www.newyorker.com/magazine/2018/11/12/why-doctors-hate-their-computers), <https://www.newyorker.com/magazine/2018/11/12/why-doctors-hate-their-computers>)

KAYNAKLAR

- <https://www.youtube.com/watch?v=PC2W9AZfUwk>
- <https://www.youtube.com/watch?v=aircAruvnKk>
- Liu Xiaoqing et.al., “Advances in Deep Learning-Based Medical Image Analysis”, Health Data Science, Volume 2021 | Article ID 8786793 | <https://doi.org/10.34133/2021/8786793>
- L. Chen, P. Bentley, and D. Rueckert, “Fully automatic acute ischemic lesion segmentation in dwi using convolutional neural networks,” *Neuroimage Clin*, vol. 15, pp. 633–643, 2017
- A. Clèrigues, S. Valverde, J. Bernal, J. Freixenet, A. Oliver, and X. Lladó, “Acute and sub-acute stroke lesion segmentation from multimodal MRI,” *Computer Methods and Programs in Biomedicine*, vol. 194, article 105521, 2020
- D. M. Vigneault, W. Xie, C. Y. HodDavid, D. A. Bluemke, and J. A. Noble, “ Ω -Net (Omega-Net): fully automatic, multi-view cardiac MR detection, orientation, and segmentation with deep neural networks,” *Medical Image Analysis*, vol. 48, pp. 95–106, 2018.
- E. Vorontsov, M. Cerny, P. Régnier et al., “Deep learning for automated segmentation of liver lesions at CT in patients with colorectal cancer liver metastases,” *Radiology: Artificial Intelligence*, vol. 1, no. 2, article 180014, 2019.
- J. Olczak, N. Fahlberg, A. Maki et al., “Artificial intelligence for analyzing orthopedic trauma radiographs,” *Acta Orthopaedica*, vol. 88, no. 6, pp. 581–586, 2017.
- <https://spj.sciencemag.org/journals/hds/2021/8786793/>
- <https://www.ama-assn.org/practice-management/digital/machine-learning-101-promise-pitfalls-and-medicine-s-future>
- <https://www.intechopen.com/chapters/72044>
- <https://www.nature.com/articles/s41746-019-0148-3>
- <https://bmcmedresmethodol.biomedcentral.com/articles/10.1186/s12874-019-0681-4>
- <https://europepmc.org/backend/ptpmcrender.fcgi?accid=PMC6109989&blobtype=pdf>
- <https://www.youtube.com/watch?v=FmpDlaiMleA>

- Crick F. H. C., “Thinking about the Brain”, Scientific American, Vol. 241, No. 3 (September 1979), s. 219-233.
- Hawkins Jeff, A Thousand Brains A New Theory of Intelligence, Basic Books, New York-2021.
- Heaven Douglas Will, “We’ll never have true AI without first understanding the brain”, MIT Technology Review, March 3, 2021, <https://www.technologyreview.com/2021/03/03/1020247/artificial-intelligence-brain-neuroscience-jeff-hawkins/>
- Ching Daniel, “Multi-category classification of various chest conditions from chest x-rays”, Towards data Science, Dec 23, 2021, <https://towardsdatascience.com/multi-category-classification-of-various-chest-conditions-from-chest-x-rays-1d6428522997>
- Gawande Atul, “Why Doctors Hate Their Computers”, New Yorker, November 12, 2018 Issue, <https://www.newyorker.com/magazine/2018/11/12/why-doctors-hate-their-computers>
- Kopp Andreas, Alkemade Harmke, “Medical Imaging with Azure Machine Learning”, Towards Data Science, Dec 20, 2021, <https://towardsdatascience.com/medical-imaging-with-azure-machine-learning-b5acfd772dd5>
- Weston Alexander, “How to Segment a Pancreas CT”, Towards Data Science, Jul 1, 2021, <https://towardsdatascience.com/how-to-segment-ct-pancreas-3a390acb3c70>
- <https://uit.stanford.edu/service/techtraining/class/data-science-and-using-image-processing-healthcare-professionals>
- <https://medium.com/datasciencearth/basic-structure-of-artificial-neural-networks-9aef29df9d>
- <https://www.bmc.com/blogs/bias-variance-machine-learning/>
- Nayak Nandita, Chang Hang, Borowsky Alexander, Spellman paul, Parvin Bahram, “Classification of tumor histopathology via sparse feature learning”, Proc IEEE Int Symp Biomed Imaging. 2013 Apr; 2013, doi: 10.1109/ISBI.2013.6556499.
- Li Xintong , Hu Weiming, Li Chen , Jiang Tao , Sun Hongzan , Li Xiaoyan , Huang Xinyu , Grzegorzec Marcin, “A State-of-the-art Survey of Artificial Neural Networks for Whole-slide Image Analysis: from Popular Convolutional Neural Networks to Potential Visual Transformers”, arXiv:2104.06243v3 [eess.IV] 26 Feb 2022
- Xu Kelvin, Ba Lei Jimmy, Kiros Ryan, Cho Kyunghyun, Courville Aaron, Salakhutdinov Ruslan, Zemel Richard S., Bengio Yoshua, “Show, Attend and Tell: Neural Image Caption Generation with Visual Attention”, arXiv:1502.03044v3 [cs.LG] 19 Apr 2016
- Heaven Douglas Will, “This is the reason Demmis Hassabis started DeepMind”, MIT Technology Review, February 23, 2022, <https://www.technologyreview.com/2022/02/23/1045016/ai-deepmind-demis-hassabis-alphafold/>
- “Project Uses Machine Learning to Predict Cancer Drug Efficacy”, Sept 7, 2021, <https://medium.com/berkeleyischool/project-uses-machine-learning-to-predict-cancer-drug-efficacy-4dadef1f8ac>
- Strickland Eliza, “Andrew Ng: Unbiggen AI”, Spectrum.ieee, 9 Feb, 2022, <https://spectrum.ieee.org/andrew-ng-data-centric-ai>