

Deep Learning
Onramp

Doğukan mehmet
kılıç

- ① `imread()` → Görseli okur,
 ② `imshow()` → Görseli ekrana yansıtır.

Önceden eğitilmiş, taramamız GoogleNet mimarisini kullanabilmek için

- ③ `net = googlenet;` atamasını yapabiliriz.

Bir görüntü üzerinde sınıflandırma yapabilmek için "classify" fonksiyonunu kullanabiliriz.

- ④ `pred = classify(net, img)`



GoogleNet ataması yaptığımız ③'te katmanları almak için aşağıdaki gibi nokta gösterimi kullanırız

- ③' kod → `net = googlenet;` idi.

- ⑤ `ly = net.Layers` kullanarak katmanları çekebiliriz

`ly` dizisi bir ağ katmanları dizisidir. `ly` içinde indexleme kullanarak tek bir katman incelenebilir.

- ⑥ `layer3 = ly(3)`

Her ağ katmanı, o katman türüne ilgili özelliklere sahiptir. GİRİŞ katmanının önemli olan özelliği, ağına giriş olarak beklediği görüntülerin boyutları olan "Input Size" dir. Nokta gösterimi ile özellik çekebiliriz.

Gri tonlamalı görüntüler MATLAB'de $m \times n$ dizi olarak ($m \times n$) ifade edilir. Her pikselin değeri, korşılı gelen görüntü pikselinin yoğunluğunu temsil eder. Renkli görüntüler $m \times n \times 3$ lük bir dizi olarak ($m \times n \times 3$) temsil edilir.

Bir çıktı katmanının "Classes" özelliği, ağı tahmin etmek üzere eğitildiği kategorilerin adını verir. Bu 1000 resim $224 \times 224 \times 3$ boyutundadır.
GOOGLENET INPUT SITE

"classify" ile, ağı en yüksek puanı çıkardığı çıktı ekrana verir. İkinci bir çıktı isteyecek sınıflar için tahmin edilen puanları alabiliriz.

⑦ `[pred, sors] = classify(net, img)`

Tüm skorları görmek için

Ardından bu elde edilen skorları bar grafik yardımı ile görselleştirebiliriz. Bazen çok fazla kategori olma olabilir. Bu konuda da grafiğin bir bölümü üzerine sınırlama yapabiliriz.

⑧ `bar(sors)`

Sınırlama yapmak, daha net bir grafik ortaya koymak için eşik değeri kullanabiliriz.

⑨ `highscores = scores > 0.01;`
(sors)

Ardından sors içerisinde highscores'i alıp bunu bar grafiğine yansıtırız.

⑩ `bar(score(highscore))`

Bu işlemler sonucu x-ekseninin isimlerini ilgili değerler için atamak istersek aşağıdaki komudu kullanırız

(11) x ticklabels (categorynames (highscores))

kategori isimleri arasında belirli
eşit değerlere ait olanları yaz
Bu eşit değere ait olan kategori isimlerini
x-ekseninde ilgili yere yazar

DATASTORE

MATLAB'da bir veri deposu oluşturmak için, klasör veya dosya adlarını girdi olarak belirterek "imageDatastore" işlevini kullanabiliriz. Birden fazla dosya belirtmek için (*) gibi diğer karakterler kullanılabilir.

(12) ds = imageDatastore ("foo*.png")

• foo1, foo2
ortak tem ad varılır.

↳ Bu dosya PNG dosyaları için foo ile başlayan adlara sahip bir veri deposu oluşturacaktır.

"read", "readimage" ve "readall" işlevi kullanarak verileri bir veri deposunda manuel olarak işe aktarabiliriz.

- read: Görüntüleri sırayla birer birer işe aktarır.
- readimage: Tek bir spesifik görüntüyü işe aktarır.
- readall: Tüm görüntüleri tek bir hücre dizine aktarır
her görüntü ayrı ayrı hücrededir.

(13) I = readimage(ds, n)

↳ Bu ds'teki n. görüntüyü I'ya aktarır.

Sınıflandırma için CNN işlemlerinde tek bir görüntü yerine bir görüntü veritabanı kullanılabilir.

(14) `preds = classify(net, ds)`

Sonuç her bir görüntü için (veri deposundaki) bir tane olmak üzere, tahmin edilen sınıfların bir dizisi olacaktır.

Görselleri Kullanıma Hazırlama

Giriş Görüntüleri Ayarlama:

Daha öncesinde önceden işlenmiş fotoğraflar kullanıldı. Burada görselleri GoogleNet ile sınıflandırılmasını için yeniden boyutlandırılmış olacaktır. Başlangıçta farklı boyutlara olabilirler fakat ağı eğitme için ağı uygun boyutlara olmalı.

Bir ağı giriş katmanı, ağı ihtiyacı duyduğu görüntü boyutunu verir.

(15) `expectedSize = inputLayer.InputSize`

UYUN-
HALI

(16) `net = googlenet;`

`inlayer = net.Layers(1);`

`inSize = inlayer.InputSize`

→ net'i yükle

→ ilk katmanı al.

→ input size ihtiyacı olan.

Bir görüntüyü beklenen giriş boyutuyla eşleştirecek şekilde yeniden boyutlandırmak için "imresize" kullanılır.

~~imresize(img, [inSize, inSize], 'nearest');~~


(17) `imrest = imresize(img, [inSize, inSize], 'nearest');`

Bu img'yi verilen boyutlara göre yeniden boyutlandırır. Artık görsel GoogleNet'in giriş katmanının beklenen boyutlarıyla eşleştiğine göre görsel sınıflandırılabilir.

GÖRÜNTÜ ÖNİŞLEME İÇ AKIŞI

Görüntüleri evrişimli bir sınıt ağıyla sınıtlandırmak için, her görüntünün ağına giret katmanları tarafından belirtilen boyutlara sahip olması gerekir. Görüntüleri genellikle sınıtlandırılmadan önce basit bir ön işleme gerekir. Her görüntü ayrı ayrı da işlenebilir fakat bu zaman alabilir. Bunun yerine ImageDatastore (görüntü veri deposu) kullanılır. Bunun için tüm verilerin bir ~~klasör~~ klasöre kaydetmek gerekir.

Görüntülerin evrişimli bir sınıt ağı ile sınıtlandırılması için her görüntünün ağına giret katmanındaki belirtilen boyutlara sahip olması gerekir. Görüntüleri tet tet sınıtlandırmakla bir klasörde ImageDatastore formatına, oradan da boyutlandırma işlemine ilerlemek daha faydalıdır.



Veri Deposundaki (ImageDatastore) Görüntüleri Yeniden Boyutlandırma

Her ImageDatastore formundaki veriyi basit ön işleme adımları gerçekleştirilebilir.

(18) `auds = augmentedImageDatastore([r c], inds)` ^{o ilgili ImageDatastore}

rows columns

Ardından bunu sınıflandırma aşamasına sokabiliriz.

(19) `preds = classify(net, auds)`

RGB Görüntüleme Dönüştürme

Biri tonluluğu görüntüler ($n \times m \times 1$) boyutundadır. GoogleNet gibi bir çok önceden eğitilmiş ağ ($p \times q \times 3$) boyutunda görüntü gerektirir. Resim gri tonluluğu GoogleNet ile kullanmak için 3 boyutlu dizilere dönüştürmek gerekir.

"montage" fonksiyonu ile tüm siyah-beyaz görüntüleri görüntüleyebiliriz.

(20) `montage(inds)`

Aktarılmış bir görüntü veri deposu (ImageDatastore) cluster edildiğinde "ColorPreprocessing" seçeneğini kullanarak 3 boyutlu bir diziye dönüştürebiliriz.

(21) `auds = augmentedImageDatastore([n m], ... inds, "ColorPreprocessing", "gray2rgb")`

Bu fonksiyon 1 boyutlu bir diziye dönüştürmek için gri tonluluğu bir görüntüyü 3 kez kopyalayacaktır. Ingray, gri tonluluğu bir görüntüyü temsil ederse, işlenen görüntü renkli (RGB) bir görüntüyü temsil eder 3 boyutlu bir dizi olacaktır.

Ardından "classify" ile sınıflandırma yapabiliriz

(22) `preds = classify (net, auds)`

imageDatastore fonksiyonu varsayılan olarak verilen klasördeki görüntü dosyalarını arar. Verilen klasörün alt klasöründeki görselleri aramak için "IncludeSubfolders" fonksiyonu kullanılabilir.


(23) `ds = imageDatastore ("folder", ...
"IncludeSubfolders", true)`

Bu Network'ü eğitmemiz için 3a şeye ihtiyacımız vardır.

- 1) layers
- 2) data
- 3) options

Bunlara sahipset sistemimizi kolayca aşağıdaki gibi eğitebiliriz.

(24) `newnet = trainNetwork (data, layers, options)`



Transfer öğrenimini gerçekleştirmek için üç bileşen oluşturmamız gerekir;

- Ağ mimarisini temsil eden bir dizi katman. Transfer öğrenimi için bu, GoogLeNet gibi önceden var olan bir ağ değiştirilerek oluşturulur. (LABELS)
- Eğitim verileri olarak kullanılacak bilinen etiketlere sahip görseller. Bu genellikle bir veri deposu olarak sağlanır. (TRAIN DATA)
- Eğitim algoritmasının davranışını kontrol eden seçeneklerini içeren bir değişken (TRAIN ALGORITHM)

Bu üç bileşen, eğitilmiş ağı çıktı olarak döndüren "trainNetwork" fonksiyonuna girdi olarak sağlanır. Yeni eğitilen ağın performansını test etmelisiniz. Yeterli değilse, genellikle bazı eğitim seçeneklerini ayarlamayı ve yeniden eğitimi denemelisiniz.

Bir klasör altında saklanan birden fazla klasör içinde eğitim verileri olabilir. Aynı klasördeki veriler aynı özelliklere sahiptir. "LabelSource" seçeneğini belirleyerek veri deposunun klasör adlarından etiketleri otomatik olarak belirlemesini sağlayabilirsiniz.

(25) `ds = imageDatastore (folder, ---
"IncludeSubfolders", true, ---
"LabelSource", "foldernames")`

Etiketler, klasör adlarından otomatik olarak okunur ve kategorik bir dizi olarak saklanır. Bu etiketler eğitim süreci açısından kritik öneme sahiptir.

Resim dosyalarımız bu şekilde organize ~~edilmemişse~~ edilmemişse, labels ~~etkiliğini~~ etkililiğini, kategorik bir resim etiketleri dizisi olarak şekilde manuel olarak değiştirmemiz gerekecek.

Bir veri deposundaki görüntüleri iki ayrı veri deposuna bölmek için "splitEachLabel" ilevini kullanabiliriz.

$$(26) \quad [ds1, ds2] = \text{splitEachLabel}(inds, p)$$

p oranı (0'dan 1'e kadar bir değer), $inds$ 'deki her etiketin $ds1$ 'de yer alması gereken görüntülerin oranını gösterir. Kalan dosyalar $ds2$ 'ye atanır.

Varsayılan olarak "splitEachLabel" dosyaları düzeli tutar. İsteğe bağlı "randomized" ekleyerek dosyaları rastgele seçim yapması için talimat verebiliriz.

$$(27) \quad [ds1, ds2] = \text{splitEachLabel}(inds, p, \text{"randomized"})$$

Dengesiz Eğitim Verileri

Bazı uygulamalarda bir sınıfta diğerine göre çok daha fazla görüntünün bulunması yaygındır. Örneğin kusurları elde etmeye çalışırken genellikle hatasız adı sayıda görüntü elde etmek kolaydır, ancak kusurlu görüntüleri elde etmek daha zordur. Eğitim verileri kusursuz görsellerden oluşursa bu durumda kusurlu verilerden yavaş bir öğreneme söz konusu olabilir.


Bunu önlemek için eğitim görüntülerinin her sınıftan eşit sayıda olması sağlayacak şekilde verileri bölmek yararlı olabilir.

" p ", 0'dan 1'e kadar bir değer olduğunda oranı olarak algılanır, yorumlanır. Daha sonra görüntüler, her etiketin oranlı olarak bölünmesini sağlayacak şekilde bölünür. Ayrıca $ds1$ 'e atamak yerine her etiketten alınacak tam sayıda dosya belirtilebiliriz.

$$(28) \quad [ds1, ds2] = \text{splitEachLabel}(inds, n)$$


Bu, kategorilerin tümü aynı sayıda görsel içermese bile dsl'deki her etiketin n-görsel sahip olmasını sağlar

SERIES NETWORK



DIRECTED ACYCLIC GRAPH NETWORK (DAG NETWORK)

DAG Network daha fazla kompleks mimariye sahiptir.



SERIES NETWORKS



L LAYERS

DIRECTED ACYCLIC GRAPH NETWORK (DAG NETWORK)



L LAYERS
L CONNECTIONS

"trainingOptions" fonksiyonu kullanarak seçilen bir eğitim algoritması için mevcut seçenekleri görebiliriz.

(29) `opts = trainingOptions('sgdm')`

Çoğu zaman ilk önce seçeneklerin çoğunu varsayılan değerlerde bırakarak antrenman yapmayı denemek isteriz. Fakat en iyi sistemi elde etmek amacıyla çoğu zaman parametrelerle oynarız. Transfer öğrenimi amacı da mevcut bir ağda ince ayar yapmaktır. Bu nedenle genellikle ağırlıkları sıfırdan eğitime göre daha az agresif değiştirmek isteyebiliriz.

"trainingOptions" fonksiyonunda istediğimiz parametreleri istediğimiz şekilde değiştirebiliriz.

(30) `opts = trainingOptions('sgdm', 'Name', value)`

Değiştirmek
istenen parametre
adı

Parametre
değeri

Transfer Learning için "4" şey ihtiyac vardır.

- ✓ Network Layers
- ✓ Training Data
- ✓ Algorithm Options

(31) `newnet = trainNetwork(data, layers, opts)`

↳ Bu kod ile modelimizi eğitebiliriz. Ardından terminalde bir tablo çıkacak.

Epoch	Iteration	Time Elapsed (seconds)	mini Batch Loss	mini Batch Accuracy	Base Learning Rate
-------	-----------	------------------------------	-----------------------	---------------------------	--------------------------

"Mini-Batch" Nedir?

Her yinelemede ağırlıkları güncellemek için "mini-batch" olarak bilinen eğitim görüntülerinin bir alt kümesi kullanılır. Her yinelemede farklı bir "mini-batch" kullanılır. Eğitim setinin tamamında kullanıldığında buna "epoch" denir.

Maksimum dönem sayısı (MaxEpoch) ve mini grupların sayısı (MiniBatchSize), eğitim algoritmaları seçeneklerinde ayarlayabileceğimiz parametrelerdir.

trainingNetwork içerisinde "plots", "training-progress" yazarak train işlemi sürecinde train grafiğini bize gösterecektir.

Eğitimden Sonra Ağı Değerlendirme

Aşağıdaki info değişkeni eğitime ilişkin bilgiler içeren bir yapıdadır. TrainingLoss ve TrainingAccuracy alanları, her iterasyondaki eğitim verileri üzerinde oluşan ağı performansını bir kayıta alır.

Info



- TrainingLoss 
- TrainingAccuracy 
- BaseLearnRate 

② plot (info.TrainingLoss) fonksiyonu ile kayıp grafiğini çizilebilir.

İki dâtinin edilen değerin sayısını belirlemek için mantısal operatörleri ve nnt'yi kullanabiliriz.

(33) $\text{numequal} = \text{nnt}(a=z)$

↳ Buın tahmin edilen test sonuçları ile gerçek test sonuçları sonucu doğruluğun yüzde kaç olduğunu bulmak için kullanırız.

Ardından:

(34) $\text{fracCorrect} = \text{numCorrect} / \text{numel}(\text{flwrPreds})$
ile yüzde değeri buluruz.

Sınıfta Göre Performans

Kayıp ve doğruluk için performansının genel ölçümüne verir. Ancak için farklı görüntü sınıflarında nasıl performans gösterdiğini araştırmak bilgilendirici olabilir. Confusion matrix (karşılık tablosu, matrisi) işlevi, tahmin edilen sınıflandırmalar için karşılık matrisi hesaplar. ve görüntüler.

(35) $\text{confusion chart}(\text{known class}, \text{predicted class})$

↑
Bilinen sınıfların
adının
değeri

↓
tahmin edilen
sınıfların
değeri

