

Deep Learning
with MATLAB

Doğan Mehmet
KILINÇ

Image Datastores

imageDatastores, bir veri kaynağına bağlanan bir MATLAB değişkenidir. Görüntü sınıflandırma için Derin Öğrenme gerçekleştirilirken, görüntülerinizi bir imageDatastore'da saklamanıza yardımcı olur. Burada dosya adı, formatı, sınıflandırma etiketi gibi bilgiler saklanır. Ayrıca bu formata çevrilmiş bir veri deposu ile görüntülerin tamamını önceden kolay bir şekilde işleyebilirsiniz.

① imageDatastore (Location)

Tüm görselleri bir arada kullanmak için veya görüntülenmek için "montage" kullanılır.

② montage(datastore)

Önceden eğitilmiş ağı ataması için aşağıdaki gibi yapılır.

③ net = googlenet;

imageDatastore formatına çevrilen bir format içinde, içerisindeki tüm görseller için basit ön işleme gerçekleştirilebilir. Bu yeni veri deposunu (imageDatastore) görüntü giriş boyutunu girip görüntüleme uygulamak için:

④ cmds = augmentedImageDatastore (['c'], inds)

"classify" ile bir görüntünün etiketlerini tahmin etmek için bir ağı kullanırsanız:

⑤ label = classify (net, ds)

Transfer Learning

Transfer öğrenimi, yeni bir görüntü kümesini sınıflandırmak için önceden eğitilmiş bir ağı yeniden eğitme sürecidir. Şunlar gereklidir;

- Network Layers (layers)
- Training Data (data)
- Algorithm Options (options)

Örneğin bir verisetindeki görüntülerin alt klasörlerde saklandığını varsayalım. Her klasörün adı o klasördeki görüntüler için karşılık gelen etikettir. Veri deposundaki tüm görüntüler bulmak ve etiketlenmek için "IncludeSubfolders" ve "folderNames" kullanılır.

⑥ `ds = ImageDatastore(location, ---
"IncludeSubfolders", true, ---
"LabelSource", "folderNames")`

Eğitim sırasında `ds`, eğitim görüntülerini ve etiketleri ilişkilendirmeyi öğrenir. Eğitim sırasında veriyi `train` ve `test` diye ikiye bölebiliriz.

⑦ `[ds1, ds2] = splitEachLabel(linds, p)`

p - oran (0-1) oranı değeri alır ve belirlenen oranda bölme yapıp `ds1`'e kaydeder. Kalan `ds2`'ye kaydedilir.

Algoritma seçenekleri bir ağı nasıl eğitildiğini kontrol eder. Bu seçenekler `"trainingOptions"` fonksiyonu ile oluşturulur.

⑧ `opts = trainingOptions(algorithm, ---
"InitialLearnRate", rate)`

İlk girdi algoritma adıdır. Olsa bir çok seçenek vardır. Bunu dilediğiniz gibi kontrol edebilirsiniz.

Oluşturulan, elde edilen parametreler ile bir sistem ağıdaki kod ile train edebilirsiniz.

9) `net=trainNetwork(trains, lgraph, options)`

Ağı Değerlendirme

Bu değerlendirme confusion matrisi (karşılık matrisi) ile olabilir.

Bir ağı yüksek eğitim ve test doğruluğuna sahip olması önemlidir. Test setindeki doğruluğu hesaplayarak ve karşılık matrisini görüntüleyerek bir sınıflandırma ağının etkinliğini değerlendirebilirsiniz.

Yeni görüntülerdeki etiketleri tahmin etmek için aşağıdaki kod kullanılır.

10) `predictedLabels=classify(net, inds)`

Test görüntüsü veri deposundaki etiketleri ağıdan tahmin eden etiketlerle karşılaştırarak test doğruluğunu hesaplayabilirsiniz.

11) `nnz(trueLabels == predictedLabels)/n`

Sıfır olmayan öğelerin sayısını veya gerçek etiketin tahmin edilen etikete eşit olduğu öğelerin sayısını sayar.

Test görüntülerinin sayısıdır.
Test görüntülerinin sayısını bulmak için

`length(testPred)`


Konfüzlik matrisi (confusion matrix), hangi etiketlerin yanlış sınıflandırıldığını gösterir.

② Confusionchart (known, predicted)

Burada x-ekseni ; tahmin edilen etiketi,
y-ekseni ; bilinen etiketi gösterir.

AG mimarisini ANLAMA

CNN mimarileri derinlik açısından çeşitlilik gösterir. Tüm CNN'ler görüntü giriş katmanı ve konvolüsyon katmanları gibi bazı ortak katmanlar içerir.



Yukarıdaki katmanlar basit bir derin AG mimarisini oluşturur. Ağdaki her katman, girdileri üzerine bazı işlemler gerçekleştirir ve yeni bir değer çıktısı verir.

İlk katman görüntünün giriş katmanıdır. Bu katman orijinal giriş boyutunu alır ve görüntüleri normalleştirir.

Varsayılan olarak, bir görüntü giriş katmanı eğitim veri setinin ortalama görüntüsünü çıkarır.

Input Layer

convolution 2d Layer, katmanları giriş görüntüsüne kayan filtreler uygular. Bu katman CNN mimarisinde önemli bir katmandır, katmanlardan **relu Layer**, konvolüsyon katmanlarını genellikle düzeltilmiş doğrusal birim (Relu) gibi doğrusal olmayan bir aktivasyon katmanı takip eder. Bir Relu katmanı, girdinin her bir ögesi için bir eşik işlemi gerçekleştirir. Sıfırdan küçük herhangi bir değeri sıfıra eşitle.

maxpooling Layer, bir maximum havuzlama katmanı, girişi dörtörtegen havuzlama bölgelerine bölerek ve her bölgenin maximumunu hesaplayarak aşağı örneklemeye gerçekleştirir.

Havuzlama, ağ karmaşıklığını azaltır ve daha genel bir ağ oluşturur.

fully Connected Layer, ağdan geçen özellikler, tam bağlantı katmanına ulaşmaya kadar bir matris formatında saklanır. Tam bağlantı katmanında girdi, çıktı sınıfı ile eşleştirilebilmesi için "düzeltilir". Bu katman klasik bir sinir ağıdır. Bu katman için çıktı boyutu, sınıflandırma probleminin için sınıf sayısıdır.

softmax Layer, normalleştirilmiş istel fonksiyon kullanarak her çıktı sınıfının değerini normalleştirilmiş puanlara dönüştürür. Her değeri, giriş görüntüsünün her sınıfa ait olma olasılığı olarak yorumlanabilir.

classification Layer, sınıflandırma çıktı katmanı en olası sınıfın adını döndürür.

CNN'lerdeki konvolüsyon katmanları, öğrenilen filtreleri kullanarak konvolüsyon gerçekleştirir.

Konvolüsyon Oluşturma

Bir RGB görüntünün 3 farklı kanalı vardır. Konvolüsyon gerçekleştirmek için de iki boyutlu bir matrise ihtiyacımız vardır. İki nokta ist iste () operatörünü kullanarak kanallardan birinin tüm satır ve sütunlarını seçebiliriz.

(13) `image ( : , : , n )`

Daha önceden oluşturulmuş filtre matrisini görüntüye uygulamak için aşağıdaki kodu kullanırız

(14) `filteredim = conv2 ( filtre , im )`

Gri tonlamalı görüntüler görüntüler ekrana bastırırken imshow'un yamaç genelde ikinci bir argüman eklemek gerekir.

İkinci girdi olarak bazen portet kullanmak, görüntüde bulunan minimum ve maksimum değerlere göre ekran ölçeklendirecektir.

(15) `imshow ( im , [ ] )`

Farklı filtreler de uygulayabiliriz

Aktivasyon fonksiyonu ile bir CNN kullanarak bir giriş görüntüsünden özellikler çıkarabiliriz. Bu fonksiyon 3 girdi kabul eder. net, görsel ve özelliklerin çıkarılacağı katman.

(16) `features = activations ( net , img , layer )`

Bazen ~~birbirine~~ ^{ilgili}ilenen layer'da, katmanda birde fazla kanal vardır. Bu nedenle tüm kanalları ayrı ayrı incelemek zordur.

"showActivationsforChannel" fonksiyonu ile birlikte belirli bir katıldaki aktivasyonlar görüntülenir.

Beyaz bir piksel, kanalın o konumda pozitif olarak etkinleştirildiğini, Siyah piksel ise kanalın negatif olarak etkinleştirildiği yerdir.

(17) showActivationsforChannel(~~feature~~, img, feature, nth)

Konvolüsyon katmanının hiperparametreleri ve öğrenilebilir parametreleri vardır. Hiperparametreler ağı oluşturulduğunda ayarlanır ve eğitim sırasında değişmez. Öğrenilebilir parametreler eğitim sırasında güncellenir.

Bu değerler Weights'ta saklanır. Örneğin:

Convolution2DLayer with properties

Name: ~~~

Hyperparameters

Filtersize: [~]

Learnable Parameters

Weights: [7x7x3x64 single]

Bias: [~]

Bu özellikteki katmanın ağırlıkları dört boyutlu bir diziye saklanır. Dörtüncü boyut (64) kanal sayısı

Bu katmandaki tüm kanalları görmek için önce aktivasyon almamız gerekir.

(18) actvn=activation(net, img, Layer)

Aktivasyonlar herhangi bir değer alabilir bu nedenle aktivasyonları görüntülemeler için ölçeklendirme faydalı olacaktır. Bunu "mat2gray" ile yapabiliriz

$$(19) \quad \text{actunGray} = \text{mat2gray}(\text{actun})$$

Derin öğrenme ~~ve~~ ağırlık eğitme için en iyi yaklaşımlar TRANSFER LEARNING'dir. (Görseller RGB ve aynı boyutlarda değil)

Görseller Gray-Scale ve aynı boyutlarsa en iyi öğrenme yaklaşımı BİR AĞI ŞİFİRDAN EĞİTMEK (Train a Network From Scratch) tir

Grayscale görüntülerde $\Rightarrow a \times b \times 1$
 Renkli (RGB) görüntülerde $\Rightarrow a \times b \times 3$ kanal vardır.

Arzı Görüntü $\Rightarrow a \times b \times 4$ kanal vardır.
 Görüntülerinde
 Kırmızı
 Yeşil
 Mavi
 Yakın Kızılötesi

Evrizin katmanları, görüntüye farklı filtreler uygulayarak giriş görüntüsündeki özellikleri öğrenen Evrizin katmanını (convolution layer) oluşturma işi filtre boyutunu ve filtre sayısını belirtmek gerekir

$$(20) \quad \text{convolution2dLayer}([h, w], n)$$

$\hookrightarrow$ FilterSize $\rightarrow [h, w] \rightarrow h \times w$ boyutunda,

$\hookrightarrow$ Numfilters $\rightarrow n \rightarrow n$ tane filtreyi bir convolution layer.

Evrişim katmanlarını (~~conv~~ convolution layer) genellikle düzeltilmiş doğrusal birim (Relu) ve maksimum havuzlama katmanı tahmin eder. Relu katmanı tüm negatif değerleri sıfıra ayarlar.

(21) relulayer()

Maksimum havuzlama katmanları, dikdörtgen bölgeleri bir araya toplayarak ve her bölgenin maksimumunu hesaplayarak alt örnekleştirme gerçekleştirir. Havuzlama boyutu giriş olarak kullanılır.

(22) maxPooling2dLayer ([h w])

Evrişimsel sınır katmanlarının son 3. katmanı azğıdakti gibidir.

- fullyConnectedLayer
- softmaxLayer
- classificationLayer

Fully - Connected - Layer, ağız tahmin edebileceği sınıf sayısını temsil eden Outputsine 3telligine sahiptir.

Ufak Bir Örnek

trainingOptions ile yapılan eğitimi grafik üzerinde incelemek isterseniz aşağıdaki kodu yazınız

(23) `trainingOptions ("plots", "training-progress")`

Ağı eğitmek için hazır. Eğitim görüntülerini ve etiketleri XTrain ve YTrain olarak ayrı ayrı farklı değişkilere kaydedilir. Kod aşağıdaki gibidir

(24) `net = trainNetwork(X, Y, Layers, opts)`

Test verileri bir XTest değişkilinde saklanır ve ilgili etiketler YTest'te bulunur.

Ağda tahminlerde bulunmak için 'classify' kullanılabilir.

(25) `testpreds = classify(net, Xtest)`

Ardından karışık tablosunu görmek için (confusion matrix) aşağıdaki kodu kullanırız

(26) `confusionchart(known, predicted)`

↓
Bilinen

↓
Tahmin Edilen

Şimdiye kadar bir ağı eğitirken sonra bir test veriseti kullanarak değerlendirdik. Ayrıca bir doğrulama veriseti de kullanabiliriz. Doğrulama veriseti, eğitim sırasında ağı değerlendirmek için kullanılan verilerin ayrı bir bölümüdür

Training Data: ^{Eğitim,} ~~***~~ Öğrenme sırasında ağırlıklar güncellemek için kullanılır.

Validation Data: Performansı değerlendirmek için eğitim sırasında kullanılır.

Testing Data: Performansı değerlendirmek için eğitimden sonra kullanılır.

Doğrulama verileri, ağırlık ayarını uygun şekilde sağlamadığını tespit etmek için kullanılır. Eğitim kaybı azalsa bile doğrulama kaybı artıyorsa eğitim durdurulmalıdır. Çünkü ağırlık ayarları, eğitim verileri hakkında yeni görüntülerle ilgili olmayan ayrıntıları öğrenmektedir.

(24) $[trainds, valds, testds] = \text{splitEachLabel}(inds, 0.8, 0.1)$

↳ train data ↳ Validation data ↳ Test data

70% train 10% validation

Doğrulama verileri bir veri deposu, tablo veya hücre dizisi olabilir. Bu veri seti için görüntüler ve etiketler iki farklı değişkende saklandığından bir hücre dizisi oluşturmak basittir.

Doğrulama verilerinde oluşan bir hücre dizisinin iki ögesi olmalıdır; bunlardan ilki görüntüler, ikincisi ise etiketleri içerir.

(25) $\text{validationData} = \{X, Y\}$

X: Görüntüler Y: Etiketler

Doğrulamayı da görmek için "ValidationData" seçeneğini ekleyebiliriz.

Ağırlık çok sık bir şekilde eğitildiğinde, ağırlık daha sık doğrulamayı için doğrulama sıklığı da azaltılabilir.

(26) $\text{trainingOptions}('ValidationData', data, \dots, 'ValidationFrequency', freq)$


Validation doğruluğu, eğitim doğruluğuna benzer olduğuna dikkat edilmeli. Bu ağın aşırı uyum sağlamadığına işaret eder ve iyi bir durumdur.

AĞ PERFORMANSI İYİLEŞTİRMeye GENEL BAKIŞ

Derin öğrenme için 3a şeye ihtiyaç vardır.

- 1) Bilinen etiketlere sahip veriler (Data)
- 2) Ağ mimarisini temsil eden katmanlar (Layers)
- 3) Eğitim algoritması, parametreleri (Options)

Ağ eğitildikten sonra bir test verisi ile doğruluk hesaplanır. Performansın memnunsak bu ağ işletimde kullanılmaya başlanır.



Bazı sınıflandırma sonuçlarımızda istenilen sonucu veremeyebilir. Bunun sebebi ilgilenilen bölgenin istenilen bölge olmaması olabilir. İlgilendiği (sistemin) bölgeyi görmek için Occlusion hassasiyeti adı verilen kullanabiliriz.

Occlusion hassasiyet haritasını hesaplamak için 29 girdiye ihtiyacı var.

(30) $m = \text{occlusionSensitivity}(\text{net}, I, \text{label})$

↳ pred, classify sonucu oluşan çıktı

Bu haritayı görüntülemek için ilgili resim üzerine oturtmamız gerekmektedir. Örnekle imshow ile ilgili resmi görüntüleriz.

(31) $\text{imshow}(img)$

Ardından hassasiyet haritasını (OcclusionSensitivity) kopyalamak için ~~copy~~ "imagesc" fonksiyonunu kullanarak bir alpha değeri ile kullanabiliriz.

(32) $\text{imagesc}(I, \text{"AlphaData"}, a)$

↳ 0-1 arasıdır.
0: saydam
1: opaktır.

Yani örnek kod aşağıdaki img gibidir.

(33) $m = \text{occlusionSensitivity}(\text{net}, I, \text{label})$
 $\text{imshow}(img)$
 hold on
 $\text{imagesc}(m, \text{"AlphaData"}, a)$
 hold off

Aşağıdaki kod ile hassasiyet haritasını görsel olarak görebiliriz. Ayrıca "colorbar" ile bir renk çubuğu da ekleyebiliriz.

(34) colormap get
colorbar

Bu haritada kırmızı ile görülen yerler classify'de tahmin edilen yerlerdir. Kırmızı renge tahmin edilen yer ilgilendiğimiz alan olmayabilir. Bunun için hassasiyeti değiştirebiliriz.

(35)

```
catmap = occlusionSensitivity (net, img, "labby")  
imshow(img)  
hold on  
imagesc (catmap, "AlphaData", 0.5)  
hold off  
colormap get  
colorbar.
```

Aşağıdaki şekilde
tahmin yaptığı
değerleri saklıyordu. Bu
değerler arasında "labby"
nereye denk geldiğini
isi haritasında görmek
aldık.

Image Augmentation

Görüntüler döndürme, yansıtma, kesme, öteleme kombinasyonlarıyla dönüştürmek için "augmentedImageDatastore" kullanılabilir.

Ağ, eğitim verilerinin tam ayrıntılarını etkilemediği için veri artırma, aşırı uyumu önler.

Ağ eğitilirken, veri deposundan sağladığımız örnekleri kullanarak görüntüleri rastgele artıracaktır. Dönüştürülen görüntüler bellekte saklanmaz, bu da büyük veri setleri üzerinde eğitim yaparken kullanışlıdır. "imageDataAugmenter" ile, büyütmeleri seçmek için kullanılabilir. Olası büyütmeler yansıtma, öteleme ve ölçeklendirme gibi dönüşümler içerir.

Verisetini büyütmek için görüntüleri rastgele bir miktarda döndürülmüştür.

(36) imageDataAugmenter("RandRotation", [min max]) = augmenter

Bir artırılmış görüntü veri deposu oluşturduğumuzda, çıktı görüntü boyutunun, dosyaların kaynağını ve augmenter'i (bir üst koddaki) belirtmeliyiz.

(37) augmentedImageDatastore(size, ds, "DataAugmentation", augmenter)

augInds "read" fonksiyonu ile tüm verileri okuyabilir, boyutlarını görebiliriz.

(38) data = read(augInds)

Yukarıdaki data'dan görüntü almak ve ekrana yazdırmak için -

(39) imshow(data{input{1}})

Hyperparametre Optimizasyonu

Olası eğitim parametrelerini keşfetmek için gerektiğinde MATLAB'da bir deneç oluşturabiliriz. "Experiment Manager" uygulaması, ağıbrın verilerini içinde uygun şekilde eğittiği ve sonuçların karşılaştırma için gösterildiği; değişen hyperparametrelerle bir diti derleme oluşturmanıza olanak tanır. Bunu Tools arasındaki Experiment Manager içinde gerçekleştirebilirsiniz.

Regresyon Nedir?

Konvolüsyonel sınıt ağıları genellikle görüntü sınıflandırması için kullanılır.

Daha genel olarak sınıflandırma, yeni veriler için ayrı bir yanıt öngören bir tahmin modeli oluşturmak için verilen ve bilinen yanıtları kullanma görevini ifade eder. Görüntü sınıflandırması için girdi verisi görüntüdür ve bilinen yanıt görüntü öanesinin etiketidir.

Regresyon

Derin öğrenme ile gerçekleştirilebilecek bir başka görevdir Regresyon, verilere ayrıt sınıflar yerine sürekli yanıt değerleri atamak anlamına gelir.

Regresyon için Veri Hazırlama

Regresyon için transfer öğrenimini gerçekleştirirken "trainNetwork" fonksiyonunu verilerinizi, mimarinizi ve eğitim seçeneklerini girdi olarak kullanabilirsiniz.

Etiketler kategorik olmadığı için regresyon gerçekleştirirken eğitim verilerinizi depolamak için imageDatastore kullanmayız. Uygun bir alternatif tablo veri türünü kullanmaktadır.

Tablonun ilk değeri her bir değişkenin doğru dizini ve adlarını içermektedir. İkinci ve sonrası yanıt elemanlarıdır.

Bu görüntüleri görüntülemek için özel olarak tablo değeri doğru adlarını veriden almak gerekir. Bunun için nokta gösterimi kullanılır.

(42) `TableName.VariableName = trainFiles`

Hücre dizisinde veri almak için köşeli parantez kullanılır.

(41) `In = trainFiles {n}`

↳ Ardından bunu "imshow" ile görüntüleyebiliriz.

Eğer elimizde imageDatastore oluşturacak veriler varsa ve bir ilk 9 görüntüyü alıp 3x3 matrisde hepsini göstermek istersek

(42) `inds = imageDatastore(trainFiles(1:9));
montage(inds)`

Bu ilk 9 veriyi ve color değerlerini görmek için;

(43) `TableName(rows, cols)`

RENK için
ÖRNEK

↳ `subsetData = trainingData(1:9, :)`

↳ LİSTEDAKİ

file		Color		
		1	2	3
1. satır	0: / -	5	-10	-2
		↓	↓	↓
		Red	Green	Blue

kırmızı yeşil mavi
renk deneme

Toplu bagutlandırma için

(44) auds = augmentedImageDatastore (r c, table)

Regresyon problemlerinde "SoftmaxLayer"
- e "Classification" katmanlarını kaldırınız.
6 Bunun yerine "RegresyonLayer" katmanını
koyunuz.

Bir regresyon ağı eğitirken RMSE, Loss değerlerine
bakılır.

augmentedImageDatastore → Görüntüleri toplu bagutlandırır.

predict (net, ds) → Tahmin işlevi yapılır.

TestData - Color → TestData içerisinden Coloru çeker.

Tahmin edilen RGB değerinin kök-ortalama-kare-hatası
(RMSE) hesaplanacak. Bu yöntem regresyon ağının
doğruluğunu hesaplamak için uygun bir yöntemdir.



(45) error = rmse (pred, actual)

Tahmin edilen
değerler
(predict'ler)

Test veri
setinde elde edilen
değerler
(TestData - Color'dan)

Computer Vision Uygulamalarının Karşılaştırılması

Derin öğrenme teknikleri çeşitli uygulamalara uyarak farklı şekillerde görüntülere farklı şekillerde uygulanabilir. Hedefinize ve verileri nasıl etiketlediğinize bağlı olarak, aşağıda listelenen birçok örnek için aynı veri setini kullanacaksınız.



Eğitim Verisi Formatı	Network Analizi	Eğitim ve Test Fontları	Uygulama için Katman Tipleri
Nesne Algılama (Object Detection)	YoloV2 Layers	trainYOLOv2ObjectDetector detect	YOLOv2 ReLU Layer YOLOv2 Transform Layer YOLOv2 Output Layer
Arka plan Segmentasyonu (Semantic Segmentation)	segnet Layers unet Layers	trainNetwork semantic seg	image3d Input Layer convolution3d Layer pixel Classification Layer
Görüntüde Görüntüye Regresyon	unet Layers	trainNetwork predict	regression Layer transposed Conv2d Layer
Video Sınıflandırma	DAG Network Series Network Layer Graph	trainNetwork classify	sequence Input Layer biLSTM Layer sequence folding Layer sequence unfolding Layer



...../...../20.....

Önceden eğitilmiş bir Ground Truth'ın içerisindeki dosyalara erişmek için aşağıdaki kodu yazılır.

(46) `im = imread(petGroundTruth.imageFilename{1});`

n - görsel

Çıktı satır yalnızca bir sınırlayıcı kutu içerir. Ancak bazı (1x4 double) formatında veriler de içerebilir. Bunları görmek için aşağıdaki kodu kullanmalıyız.

(47) `b = groundTruth.Label(1)`
 ÇIKTI $\{ 1 \times 4 \text{ double} \}$
`b = groundTruth.Label{1}`
 ÇIKTI $\{ 65 \ 100 \ 150 \ 78 \}$

→ ÇIKTI' PARANTEZ İÇİNDİR

Görüntüyü etiketlerle birlikte görüntülenmek için görüntüye sınırlayıcı kutu ekleyebiliriz.

(48) `alteredImg = insertObjectAnnotation (image, --- "rectangle", bbox, label)`

→ Dikdörtgen etiket

→ Etiketlenecek koordinat

→ Görsel

→ Etiketlenen alanın isimlendirilmesi

(49) `imshow(alteredImg)`

İzlenmeye yararız

Bir çok nesne dedektörü görüntülerin aynı boyutta olmasını gerektirmez ancak eğitim verilerini tutan bir boyuta ölçeklendirmek, eğitim sırasında sorunların önlenmesine yardımcı olabilir. Sınırlayıcı kutular piksel konumlarıyla birlikte saklandığından, görüntüler ölçeklenince sınırlı kutuların da ölçeklendirilmesi gerekir.

Öncelikle imageDatastore oluştururuz.

(50) inds = imageDatastore (petGT, imageFilename)

↳ Dosya yolları alınarak imageDatastore oluşturulur

BoxLabelDatastore fonksiyonu, sınırlayıcı kutu etiketi verileri için bir veri deposu oluşturur.

(51) ds = boxLabelDatastore (tbl)

↳ Sınırlayıcı kutuları içeren bir tablodur. Her satır bir nesne sınıfını temsil eder.

En başta dosya yolları olan table dosyasında 2'den sona kadar etiketleri boxLabelDatastore ile alacağız

(52) bxds = boxLabelDatastore (table (:, 2:end))

2'den en sona
olan tüm sütunları
alacağız

(51) ve (52) de görüntüler ve sınırlayıcılar saklanmaktadır. Birlikte işlemek için bunları ~~işlemeye~~ birleştirmemiz gerekir

(53) dsnew = combine (ds, bxds)

↓
ds1
görüntü
veri deposu

↓
ds2
kutu etiketi
veri deposu

Eğitim görüntülerin boyutları farklı olabilir. Görün-
teleri yeniden boyutlandırarak, ilgili sınırlayıcı
kutuları da yeniden boyutlandırmak gerekir
"transform" fonksiyonu mevcut veri depolarını
önceden isteyebilir.

(54) `dataout = transform(datain, @myfun)`

fonksiyonu labeled
 @ ile beraber
 kullanılır.

Bu kodda `scaleGT`
 görüntüleri `targetSize` olarak yeniden boyutlandırılır.
 Aynı ölçekte ilgili sınırlayıcı kutular da yeniden
 boyutlandırılmak için de kullanılır.

Örnek bir
 fonksiyon

4 elemanlı
 bit fonksiyon
 tanıtıcısı.

(55) `function data = scaleGT(data)`
`targetSize = [224 224];`
`% data{1} is the image`
`scale = targetSize ./ size(data{1}, [1 2]);`
`data{1} = imresize(data{1}, targetSize);`
`% data{2} is the bounding box`
`data{2} = bboxresize(data{2}, scale);`
`end`

(56) sonucu oluşan görüntüyü izlemek için
"preview" kullanılır.

(57) `p=preview(ds)`

Sonuç olarak 4 elemanlı bir hücre dizisi oluşur.

- 1) Scaled image (Öğütlendirilmiş Görüntü)
- 2) Scaled bounding box (Öğütlendirilmiş sınırlayıcı kutu)
- 3) Label (Etiket)

Sonucu görüntülemek için öklendirilmiş görüntüye açıklama ekleyebiliriz.

57 `alternedImg = insertObjectAnnotation (image, ---
"rectangle", bbox, label)`

Burada da

`im = insertObjectAnnotation (p{i1}, ---
"rectangle", p{i2}, p{i3})`

kullanırız

YOLO v2 mimarisi

You-only-look-once (YOLO) ağı, her görüntüye yalnızca bir kez bakan, tek aşamalı nesne tespiti gerçekleştirmek için kullanılır. Bir YOLO ağı, tespit edilen nesnelerin ölçeğini ve en-boy oranını karakterize eden bağlantı kutularına dayanır.

Bir YOLO v2, nesne algılama ağı iki alt ağıdan oluşur;

- 1) Özellik Çıkarma Ağı
- 2) Algılama Ağı

Ground Truth

Pretrained Network Layers

YOLO Layers

Önceden eğitilmiş bir ağı ve bağlantı kutuları verileri bir YOLO v2 nesne algılama ağı'na dönüştürmek için "yoloV2Layers" işlevini kullanırız.

58 `layerGraph = yoloV2Layers (imageSize, numClasses, anchorBoxes, ---
net, featureLayer, "ReorgLayerSource", reorgLayer)`

OUTPUTS :

- layer Graph : Birleştirilmiş YOLO v2 nesne algılama ağı

INPUTS :

- imageSize : Ağ için giriş görüntüsü boyutu
- numClasses : Veri setindeki nesne sınıflı sayısı
- anchorBoxes :
- net : Önceden eğitilmiş konvolüsyonel sınırlayıcı ağı
- featureLayer : Özellik çıkarma için kullanılacak ağdaki daha derin katmanlardan birinin adı (tipik olarak bir Relu katmanı)
- "ReorgLayerSource" : YOLO katmanının ağdaki farklı derinliklerden gelen özellikleri dikkate alınmasını sağlar. (İSTİFİYE BAĞLI GİRİŞLER.)
- reorgLayer : Ağda featureLayer'den önceki bir katmanın adı. (Genellikle başka bir Relu katmanı)

Bir nesne dedektörünü eğitmek için bağlantı kutularına ve bir ağ mimarisine de ihtiyacımız olacaktır. Bağlantı kutuları, veri setindeki nesnelerin ölçeğine ve el-bay oranını karakterize ederek nesne dedektörünün performansını artırır.

YOLO dedektörleri sınırlayıcı kutuları bulma için bağlantı kutularına güvenin sınırlayıcı kutuların boyutları biliniyorsa bunlar doğrudan ağ mimarisine aktarılabilir. Ancak genellikle durum böyle değildir. "estimateAnchorBoxes" fonksiyonu veri setimiz için uygun bağlantı kutularını bulacaktır.

(59) bxs = estimateAnchorBoxes(data, numBxs)

↓
Bağlantı kutu
sayısı
(5) Birisi

Aşağı Örnek :

```
net = resnet18;
numClasses = 5;
imageSize = [224 224 3];
```


Artık veri setine uygun bağlantı kutularına sahip olduğumuzda göre, YOLO mimarisi için balon görüntüleri oluşturulabilir.
YOLO v2 mimarisi aşağıdaki gibi eğitilir.

60) $layers = yolo_v2Layers(sz, n, box, net, \dots, featurelayer, "reorglayerSource", reorglayer)$

sz: image size
n: numClasses
box: anchorBoxes
net: net

featurelayer: Özellik çıkarım katmanı
reorglayer: featurelayer'den önceki katmanın adı.

BURAYA KADAR LAYERGRAPH kütüphane ile oluşturulur.

61) BİR YOLO DEREKTÖRÜNÜN EĞİTİMİ

$detector = trainYolo_v2ObjectDetector(trainingData, layerGraph, options)$

OUTPUT: detector: Eğitilmiş YOLO ağı
INPUT: trainingData: Eğitim verisi katmanları
layerGraph: YOLO v2 içeren ağı mimarisi
options: Eğitim ayarları

Birde farklı görüntüyü test etmek istiyorsanız sayısal bir metrik hesaplamak faydalı olabilir.

Hasasiyet Hesaplaması:

Önceki sınıflandırma modellerinde, doğruluğu yalnızca yanlış sınıflandırmaya göre hesaplanırdı. Artık hem sınırlayıcı kutuya hemde etiketi dikkate alınmalıdır.

"evaluateDetectionPrecision" fonksiyonu, tahmin edilen ve gerçek sınırlayıcı kutular arasında bir örtüşme eğri kullanılarak bir keskinlik ölçütü hesaplanır.

$$\text{Gerçek değerler (Precision)} = \frac{\text{TRUE POSITIVE}}{\text{ALL POSITIVE}}$$

fx evaluate Detection Precision

Kayıp Oranı

Detektörün bir nesneyi bulmadığı durumları da göz önünde bulundurmalıyız. Buna miss rate denir. "evaluateDetectionMissRate" fonksiyonu kullanılır.

fx evaluate Detection Miss Rate

Veri deposu, birden fazla dosyada depolanan verilere erişmek için uygun bir yol sağlar. Sinyal verileri için bir sinyal veri deposu oluşturabiliriz.

62 `ds = signalDatastore ("folder", ---
"IncludeSubfolders", true)`

Verilen klasörün alt klasöründeki simgeleri de almak için

Verileri veri deposundaki bir dosyadan almak için "read" fonksiyonu kullanabiliriz.

`data = read(ds)`

↳ Datastore verisi girilir.

Okuma fonksiyonu ilk kez kullanıldığında veriler ilk dosyadan içeri aktarılır. İkinci kez kullanıldığında veriler ikinci dosyadan içeri aktarılır ve böyle devam eden koordinatları eklemek için

63 `ds = signalDatastore ("folder", "SignalVariableNames", ["Var1" "Var2"]
"ReadOutputOrientation", "row"
"columns")`

`data = read(ds)` ile okuduğumuz dosyanın formatı bir hücre dizi'dir. Singali görselleştirmek için "`cell2mat`" ile bir matrise dönüştürebiliriz.

(64) `datamatrix = cell2mat(datacell)`

Bu işlemler sonra `plot(datamatrix)` ile görselleştirebiliriz. Eğer ;

(65) `varnames = ["ax" "ay" "az"]`
`legend(varnames)`

ya da hem grafikçi çizerek hem de çizgilerin hangi renginin ne olduğunu gösterecektir.

Veri setine erişmek için `signalDatastore` kullanırız. Singali sınıflandırabilecek bir ağı eğitmek için verilerinin etiketlenmesi gerekir. Bu etiketlerin konumu veri setine bağlı olacaktır.

Her bir sinyalin etiketlerini almak için "`folders2labels`" fonksiyonu kullanılabilir.

(66) `lbs = folders2labels("folder")`

`lbs` değişkeni kategorik bir vektör içerir. Veri setinin hangi etiketlere sahip olduğunu ve sınıf başına düşen sinyal sayısını görmek için kategorik verilerle `ds`et işlevini kullanabiliriz.

(67) `lbs = folders2labels("folder")`
`summary(lbs)` Hangi kategoride kaç tane veri var onu gösterir.

Ağı eğitmeden önce etiketlerde değişiklik yapmak isteyebiliriz. Örneğin iki farklı sınıfı tek bir sınıfta birleştirebiliriz.

(68) `lbs = reneccats(lbs, ["class1" "class2"])`

LA KATEGORİLERİN ADINI
 DEĞİŞTİREBİLİRİZ.

Veri seti etiketlendiğine göre her birinden gelen sinyallere bakabiliriz. Her sınıftan bir sinyal bulmak için aşağıdaki komutu kullanabiliriz.

$$(69) \quad [lb, idx] = \text{unique}(lbs)$$

lb, sınıflarımızın adını ^{Etiket adları} $\rightarrow$ ilk değer kaçınca $\rightarrow$ ilk değerin kaçınca $\rightarrow$ indexte olduğunu verir. $\rightarrow$ indexte olduğunu verir.

Ardından bu ~~indexlerdeki~~ ^{indexlerdeki} sinyalleri ayıklamak için sinyal veri deposundaki "subset" işlevini kullanabiliriz.

$$(70) \quad dsidx = \text{subset}(sigds, idx)$$

Bit veri deposundaki tüm sinyalleri içe aktarmak için "readall" fonksiyonu kullanılır.

$$(71) \quad \text{data} = \text{readall}(ds)$$


dsidx

$\rightarrow$ Bunu kullanmamızın sebebi - sinyalleri görüntülememiz için sinyalleri dosyalardan çağırma alanına aktarmamızın gerekliliğidir.

Veri deposu, verileri yüklemeye başlamak için iyi bir yoldur çünkü derin öğrenme için veri setleri genelde çok büyüktür.

Bit sinyal veri deposu, sinyallerin hepsini belleğe yüklemeye erişmeyi sağlar. Derin ağı eğitmek için girdi olarak bir signal datastore kullanabiliriz fakat bunun dezavantajı da olmaktadır. Bu da dosyaları bilgisayarımızdan MATLAB'a okutmanın yavaş olabilmesidir.

Veri Seti'nin Bir Hücre Dizisinde Saklanması



- Ağı bir hücre dizisi ile eğiteceksek tüm veri seti tek sütunlu bir hücre dizisinde saklanacaktır.
- Yukarıdaki hücre dizisindeki her bir öge birer gözlem veya dizi'dir. Bu gözlemler sayısal matrisi oluşturur.
- Her gözlemdaki sütunlar zaman adımlarıdır. Her gözlem farklı sayıda zaman adımına sahip olabilir. Ancak sinyaller eğitim için aynı uzunluğa sahip olacak şekilde kesilecek veya doldurulacaktır. (TIME STEPS)
- Satırlar, gözlemlerin özellik boyutuna karşılık gelir. Veri setindeki farklı kanallar, farklı sensörlerden gelen sensör sinyalleridir. Tüm gözlemlerin aynı sayıda kanala sahip olması gerekir. (CHANNELS)

VERİ SETİNİ DÖNÜŞTÜRME

Örnekle aşağıdaki fonksiyonu tanımlayalım:

```

(72) function sig = prepsig(sigin)
      sig = cell2mat(sigin);
end

```

Bu fonksiyon görselleştirme için dönüştürme yapar. Sinyal veri deposu bir dönüştürme fonksiyonu kullanarak dönüştürülebilir.

→ @prepsig gibi yazılır.

```

(73) dst = transform(ds, @function)

```

← signalDatastore

→ Bir fonksiyonun başka bir fonksiyona nasıl aktarılacağını gösteren bir fonksiyon tanıtımı.

Tüm veri setini içe $\Rightarrow$ `readall(ds)` kullanılır.
aktarmak için

"readall" sonrası tüm gözetimler büyük bir matrise aktarılır. Gözetimleri birbirinden ayırmak için istenirse sinyali hücrede saklayabiliriz.

Bu duruma başvurumuzun sebebi bir LSTM eğitilirken, ağı bunu onbinlerce kanala sahip tek bir gözetim olarak düşünür olmasıdır.

(74) `sigout = {sigout}` $\rightarrow$ fonksiyonun sonuna ekleriz (prepsig)

Sigout'taki hücrelerin boyutları x,y,z yönündeki üçüncüye karşılık gelen 24 sütunlu bir matris olabilir.

Kanallar sütunlarda saklanır ancak bu verileri, bir ağı eğitmek için kullanmak için SATIRLARDA saklanması gerekir. Bunu matrisin transpose (') ederek düzenleyebiliriz.

(75) `row = col'` $\rightarrow$ `sigout = sigout'` bunu function içinde (74) inter örneği kullanılır.

Eğitim sırasında ağı, eğitim sinyallerini ve etiketleri ilişkilendirmeği öğrenir. Ağı, yetersiz bir eğitim doğruluğuna sahip olabilir. Ancak ağı, yeni sinyallere genelleme yapabiliyorsa kullanışlıdır. Ağı henüz görmediği sinyalleri sınıflandırıp sınıflandıranamayacağını değerlendirmek için aynı bir doğrulama ve test veri seti kullanmalıyız. Veri setini "splitlabels" kullanarak bölebiliriz.

(76) `idx = splitlabels(labels, [0.9, 0.05])`

~~Test veri setinin etiketi~~
Eğitim verisi
oran

validation, doğrulama
verisi oranı

Kalan 1.5'te test için otomatik atanır.

İndisler her bir elemanın sırasıyla eğitim, doğrulama ve test indislerini içerdiği bir hücre dizisinde saklanır. Örneğin eğitim indislerini şu şekilde alabiliriz.

(77) $\text{idx}\{1\}$

İndisleri çıkarttıktan sonra, bunları indexleme kullanarak veri kümesini bölmek için kullanabiliriz. data ve labels dizileri aynı filders2labels işlevi dosyaları signal datastore ile aynı hızda olur. Bunları görüntü-
lemek için;

(78) $\begin{aligned} \text{trainidx} &= \text{idx}\{1\} \\ \text{validx} &= \text{idx}\{2\} \\ \text{testidx} &= \text{idx}\{3\} \end{aligned}$

Eğitim verilerini ve ~~onları~~ etiketleri normal dizi indexleme ile çıkarabilirsiniz.

(79) $\text{training} = \text{dataset}(\text{idx})$

Eğitim verileri genellikle veri setinin en büyük oranıdır çünkü ağı eğitmek için kullanılır.

Ağ, doğrulama verileri kullanarak eğitmez, ancak ağı yeni sinyallere genelleme yapıp yapmadığını öğrenmek için eğitim sırasında doğrulama verileri kullanılır.

Eğitim tamamlandıktan sonra, test verileri ağı test etmek için kullanılır. Doğrulama ve eğitim için aynı yöntem kullanılabilir. Ancak aynı bir gözlem kullanırsak ağı daha doğru bir değerlendirme elde edilir.

TRAIN için

(80) $\begin{aligned} \text{traindata} &= \text{sigdata}(\text{trainidx}) \\ \text{trainlabels} &= \text{labels}(\text{trainidx}) \end{aligned}$

readall sonucu çıktı

readmeats sonucu çıktı

VALIDATION için:

81) $\begin{cases} \text{valdata} = \text{sigdata}(\text{validx}) \\ \text{vallabels} = \text{labels}(\text{validx}) \end{cases}$

TEST için:

82) $\begin{cases} \text{testdata} = \text{sigdata}(\text{testidx}) \\ \text{testlabels} = \text{labels}(\text{testidx}) \end{cases}$

Deep Learning Acuri

Sequence Networks'ten → Sequence to Label seçilir.

→ Bir LSTM'in ilk katmanı bir dizi giriş katmanından katmanın girdi boyutu, veri setindeki kanal sayısı ile veya bir gözlemlenilen satır sayısı ile eşleşmelidir.


→ $X_{gizli} \rightarrow \text{InputSize} = 3$ olur. (Transpoz alınmalı)

→ fully Connected Layer (Tam Bağlı Katman) girdi olarak sınıf sayısı gerektirir. Kac farklı derinlik varsa sonucu değiştirilir. örneğin

→ $0, 0.12, 0.45, 0.73 \rightarrow \text{OutputSize} = 4$ olur.

LSTM Network Eğitimi

Workflow (iş akışı)



- Derin bir ağı eğitmek için 4 bileşen oluşturmanız gerekir
- 1) Eğitim verisi olarak kullanılmak üzere bilinen etiketlere sahip veri kümesi. Singel sınıflandırma problemleri için bu, bir veri deposu veya bir hücre dizisi olarak sağlanabilir.
 - 2) Deep Network Designer'da oluşturduğunuz ağı mimarisini temsil eden katmanlar.
 - 3) Eğitimin algoritmasının davranışını kontrol eden seçenekler merkezi bir değişken.

Ağı eğitildikten sonra test edilmelidir. Sonuçlardan memnun değilse, genellikle eğitim girdilerinde batırımı değiştirir ve ağı yeniden eğitir.

Fonksiyon:

"trainNetwork" işlevi gözetli girdileri kabul eder. Ancak bu eğitimde aşağıdaki gibi kullanılır.

(83) net = trainNetwork (C, Y, layers, options)

INPUTS:

C: Gözetimlerin hücre dizisi. Her hücre, sütunların zaman adımları ve satırların kanallar olduğu bir gözetim içerir.

Y: C'nin her bir elemanı için karşılık gelen etiket.

layers: Ağı katmanları. Bu katmanlardan birisi 'lstmLayer', diğeri 'biLstmLayer' olmalıdır.

options: trainingOptions fonksiyonu ile oluşturulan eğitim seçenekleri.

Ağı eğitimi için aşağıdaki kodu kullup algoritmasını belirleyebiliriz.

(84) opts = trainingOptions ("adam")

Validasyon seçenekleri eklemek için

(85) opts = trainingOptions ("adam", "ValidationData", {validationData, "plots", "training-progress"})

"classify" fonksiyonu, veri sinyallerinin sınıflandırma tahmininin gerçekleştirilmesi için eğitilmiş bir LSTM ile kullanılabilir.

(86) `predictedlabel = classify(net, data)`

Bir hücre dizisinin her hücresi üzerinde işlem yapmanın hızlı bir yolu bir "cellfun" kullanmaktır.

Veri setindeki gözetimlerin uzunluğunu hesaplamak için, fonksiyon handlelerini kullanarak belirli fonksiyonun "cellfun" a aktarabiliriz.

Bir fonksiyon hakkında tanımlayıcı oluşturmak için fonksiyon handle "@fun" koyulur.

(87) `out = cellfun(@funet, data)`

↳ Bunu "bar" ile vizüleyebiliriz

(88) `bar(out)`

"padsequences" fonksiyonu ile bir sinyal gerektiği gibi doldurulacak veya kesilecektir.


(89) `sig = padsequences(cells, dim, "length", L)`

Epochs ve Mini-Batches

Her yinelenmede, ağırlıkları güncellemek için "mini-batches" olarak bilinen eğitim gözetimlerinin bir alt kümesi kullanılır.

Her yinelenmede "mini-batches" kullanılır. Eğitim setinin tamamı kullanıldığında buna "epochs" denir. Derin bir ağ, ağırlıkları birden fazla "epochs" boyunca güncellendiğinde en iyi şekilde eğitilir. Varsayılan "epochs" sayısı 30'dur.

Maksimum "epoch" sayısı (MaxEpochs) ve "mini-batches" (MiniBatchSize), eğitim algoritması seçeneklerinde ayarlanabilecek parametrelerdir.



177 eğitim gözleminin olduğu ve mini-batch sayısının 128 olduğu bir sistem düzenli mini-batch boyutu eğitim gözlemlerinin sayısını eşit şekilde bölünçünce trainNetwork kalan gözlemleri atar. Bunu önlemek için mini-batch boyutunu eğitim gözlemlerinin sayısına göre eşit olarak şekilde ayarlayabiliriz.

SIGNAL LABELER

Sinyal veri kıneleri daha önceden ~~etiketlenmemişse~~ etiketlenmemişse sinyalleri etkilerini olarak etiketlemek için Signal Labeler kullanabiliriz. Sinyal özellikleri, bölgeleri ve ilgi çekici noktaları etiketleyebiliriz.

Veriler Signal Labeler'de etiketlendikten sonra dışa aktarılır, export edilir. Workspace'de her gözleme ilişkin etiketlerin ilgi alanı tabloda saklanır.

Bu etiketleri derin bir ~~öğ~~ ^{öğ} ile eğtmek amacıyla kullanır ilk adım sinyaller ve etiketler için veri deposu oluşturulmalıdır.

(90) [sig, lbl] = createDatastores(lss, "labelnone")

Hücre dizisinde (cell array) bir öğeyi çıkarmak için süslü parantez {} kullanabilirsiniz.