


초보자를 위한 빅 데이터/ 머신러닝



Index

1. Colab

1. Colab 사용법

2. MNIST 데이터 분류(기본)

0. Hyperparameter 설정
1. Python Package import
2. Load Dataset
3. Build Neural Net Model
4. Training
5. Model Evaluate
6. Model Save & Load

3. MNIST 데이터 분류(심화)

1. Custom DataLoader & Custom Model
2. Custom Dataset Preprocessing
3. Custom Model Build
4. Train / Test step build
5. Training
6. Model Evaluate
7. Model Save & Load

오늘의 할 일 요약

- Colab 동작 방식을 익힌다.
- 0 부터 9 까지의 손 글씨 데이터를 분류하는 머신러닝모델을 만들어 본다.
- 지도 학습(분류) 동작 방식을 이해한다.
- 대용량 데이터를 위한 Custom Data pipeline를 익힌다.
- 동적인 구조를 표현 할 수 있는 SubClassing Model 을 생성하는 법을 익힌다.



colab

Colab 사용법 : 1/4

[Colaboratory](#)(colab)은 브라우저에서 python을 작성하고 실행할 수 있는 서비스



- Python2/3 지원
- GPU/TPU 무료 액세스
- jupyter notebook 기반
- 간편한 공유
- 구글 클라우드 데이터 공유
- 구글 계정 필요
- 구독하는 클라우드 데이터 용량에 따라 데이터 용량에 제한이 있음

Colab 사용법 : 2/4



새노트 작성으로 새로운 파일을 생성하고 이 파일은 본인 계정의 구글 클라우드에 저장된다.

Colab 사용법 : 3/4



GPU 사용을 위해서 런타임 -> 런타임 유형 변경 -> 하드웨어 가속기를 GPU로 설정 하고 저장한다.

Colab 사용법 : 4/4

```
1 ! pip install tensorflow-gpu==2.2
```

... Collecting tensorflow-gpu==2.2
Downloading <https://files.pythonhosted.org/packages/31/bf/c28971266ca>

|■■■■■■■■■■■■■■■■■■■■■■■■■■■■■■| | 357.5MB 1.6MB/s eta 0

“! pip install tensorflow-gpu==2.2 “ 와 같이 ‘!’를 사용해 shell 명령어를 사용해 원하는 버전의 python package를 설치 할 수 있다.

단 런타임을 다시 할당하면 설치된 내용은 사라지며 2020.08.13 기준 기본으로 설치된 tensorflow 버전은 2.3이다.

MNIST 데이터 분류 (기본)

0. Hyperparameter 설정

```
learning_rate = 1e-3  
batch_size = 64  
epochs = 4
```

learning_rate : 최적화 함수의 학습률

batch_size: 한번에 몇개의 데이터를 학습하는지 결정

epochs : 전체 데이터를 몇 회 반복 학습 하는지 결정

1. Python Package import

```
import os
import tensorflow as tf
from tensorflow import keras
from tensorflow import keras
import numpy as np
import matplotlib.pyplot as plt
from tensorflow.keras import layers as l

print(tf.__version__)
```

```
import tensorflow as tf
# “tensorflow” 라는 이름의 모듈을 불러와 “tf” 라는 약칭으로 사용함.
```

```
from tensorflow import keras
# “tensorflow” 라는 모듈에서 “keras” 라는 모듈을 불러옴
```

2. Load Dataset

```
mnist = keras.datasets.mnist
(train_x, train_y), (test_x, test_y) = mnist.load_data()

print("Train image shape :", train_x.shape)
print("Test image shape :", test_x.shape)
print("Train target shape :", train_y.shape)
print("Test target shape :", test_y.shape)
```

Train image shape : (60000, 28, 28)


Test image shape : (10000, 28, 28)

Train target shape : (60000,)

Test target shape : (10000,)

```
keras.datasets.mnist.load_data()
# keras 모듈 내부의 mnist dataset을 불러옴.
# 불러온 데이터는 train_{x,y}, test_{x,y}로 4가지 Numpy 변수로 가지고 옴.
# Numpy 변수의 경우 *.shape를 통해 데이터 형태를 받을 수 있음
```

2. Load Dataset



Original Set : 모든 원본 데이터
Training : 학습에만 사용하는 데이터
Validation : 학습 중 모델 정확도 검증을 위한 데이터
Testing : 학습 후 모델 검증을 위한 데이터 (**학습과정에 사용하면 안됨**)

주로 Training, Validation, Testing을 각각 6:2:2 비율로 나누어 사용함

2.1. Dataset Preprocessing

```
train_x = train_x.astype(np.float32) / 255.0  
train_x = np.reshape(train_x, (train_x.shape[0], -1))  
  
test_x = test_x.astype(np.float32) / 255.0  
test_x = np.reshape(test_x, (test_x.shape[0], -1))
```

학습을 위해 데이터를 사전에 처리하는 과정

```
train_x.astype(np.float32) / 255.0 # data type을 fp32로 변경하여 255로 나눔  
# 데이터 범위를 0 ~ 255 에서 0 ~ 1.0 으로 정규화시킴  
np.reshape(train_x, (train_x.shape[0], -1))  
# [?, 28, 28, 1]의 형태를 가지는 데이터를 [?, 784]로 펼침
```

2.2. Training & Validation Dataset Split

```
data_size = int(len(train_x) * 0.2)
val_x = train_x[:data_size]
val_y = train_y[:data_size]
train_x = train_x[data_size:]
train_y = train_y[data_size:]
```

학습 데이터 셋을 8:2 비율로 학습, 검증 데이터셋을 분리하는 과정

```
data_size = int(len(train_x) * 0.2)
# 학습 데이터 셋의 개수(len)의 20%를 계산
val_x = train_x[:data_size]
# 개수를 기준으로 학습 데이터 셋을 나누어 검증 데이터 셋으로 보관
train_x = train_x[data_size:]
# 반대 기준으로 학습 데이터 셋을 나누어 학습 데이터 셋으로 보관
```

3. Build Neural Net Model

```
from tensorflow.keras import layers as l
layers = [l.Dense(128), l.ReLU(),
          l.Dense(256), l.ReLU(),
          l.Dense(512), l.ReLU(),
          l.Dense(10), l.Softmax()]
model = keras.Sequential(layers, name='MyModel')
```

딥러닝 모델을 생성하는 과정

```
from tensorflow.keras import layers as l
# Tensorflow 패키지에서 keras 모듈 내부에 layers 모듈을 가져와 약칭을 "l" 로 함
l.Dense(128), l.ReLU(),
# layers 내부의 Dense 레이어를 가져와 출력 개수를 128개로 설정함.
# layers 내부의 ReLU 레이어를 가져와 리스트에 추가함
model = keras.Sequential(layers, name='MyModel')
# keras 모듈 내부의 Sequential 모듈을 가져와 레이어 리스트를 모델로 변환함
```


3. Build Neural Net Model

input_1: InputLayer	input:	$[(?, 784)]$
	output:	$[(?, 784)]$

dense: Dense	input:	$(?, 784)$
	output:	$(?, 64)$

dense_1: Dense	input:	$(?, 64)$
	output:	$(?, 64)$

dense_2: Dense	input:	$(?, 64)$
	output:	$(?, 10)$



Sequential의 경우 레고를 쌓는것과 비슷하게 각층의 레이어를 조립할 수 있음

3. Build Neural Net Model

```
loss_function = keras.losses.SparseCategoricalCrossentropy()  
optimizer = keras.optimizers.Adam(learning_rate=learning_rate)  
  
model.compile(optimizer=optimizer,  
              loss=loss_function,  
              metrics=[keras.metrics.SparseCategoricalAccuracy(name="acc")])
```

학습에 필요한 손실 함수 및 모델 내부 가중치를 조절하는 정책(Adam)을 생성

```
model.compile(optimizer=, loss=, metrics= )  
# 모델 학습에 필요한 설정 값을 추가함  
# optimizer: 모델 내부 가중치를 조정하는 정책  
# loss : 손실 함수  
# metrics : 정확도 측정을 위한 방법
```

4. Training

```
history = model.fit(x=train_x,  
                    y=train_y,  
                    batch_size=batch_size,  
                    epochs=epochs,  
                    validation_data=(val_x, val_y))
```

Output:

```
Epoch 1/4 750/750 [=====] - 2s 2ms/step - loss: 0.5899 - acc: 0.8441 - val_loss: 0.2680 - val_acc: 0.9238  
Epoch 2/4 750/750 [=====] - 2s 2ms/step - loss: 0.2272 - acc: 0.9342 - val_loss: 0.1936 - val_acc: 0.9423  
Epoch 3/4 750/750 [=====] - 2s 2ms/step - loss: 0.1726 - acc: 0.9490 - val_loss: 0.1657 - val_acc: 0.9520
```

...

모델 학습하는 과정

```
history = model.fit(x=, y=, batch_size=, epochs=, validation_data=)
```

```
# fit을 사용해 학습가능  
# x: 입력데이터  
# y: 입력라벨(지도학습)
```

```
# batch_size : 배치 사이즈  
# epochs : 반복학습 횟수  
# validation_data : 검증 데이터 셋
```

5. Model Evaluate

```
result = model.evaluate(x=test_x, y=test_y)
evaluate = dict(zip(model.metrics_names, result))
print(evaluate)
```

Output:

```
313/313 [=====] - 1s 2ms/step - loss: 0.1345 - acc: 0.9579
{'loss': 0.1344558149576187, 'acc': 0.9578999876976013}
```

모델 테스트 과정

```
result = model.evaluate(x=test_x, y=test_y)
```

```
# evaluate를 사용해 테스트 가능
# x: 입력 데이터
# y: 입력 라벨(지도 학습)
```

6. Model Save & Load (Keras Model, h5 format)

```
save_path = './mnist_cnn.h5'  
save_point = model.save(save_path) # save  
model = tf.keras.models.load_model(save_path) # load
```

```
# 불러온 모델을 테스트  
result = model.evaluate(x=test_x, y=test_y)  
evaluate = dict(zip(model.metrics_names, result))  
print(evaluate)
```

모델 저장 및 불러오기


```
model.save("저장경로")  
model = tf.keras.models.load_model("불러올 경로")  
# save를 사용해 모델을 '*.h5'로 저장 가능  
# tf.keras.models.load_model를 사용해 저장된 '*.h5'를 모델로 불러올 수 있음
```

MNIST 데이터 분류 (심화)

1. Custom DataLoader & Custom Model

Batch : data load, data preprocessing 을 포함 CPU에서 진행됨

Train : 모델 학습, GPU에서 진행됨




가능한 GPU(가속기) 사용이 **100%**가 될 수 있도록 낭비가 없도록 해야함!

1. Custom DataLoader & Custom Model



VGG16 Model

Sequential 로 표현 가능



Inception block

residual block

Sequential 로 불가능

Keras.Sequential 형태로는 표현 할 수 있는 모델 구조가 한정되어 있음

Inception, residual 같은 복잡한 구조를 표현 하기 위해서는 SubClassing 방식이 필요함.

2. Custom Dataset Preprocessing

```
# validation / training Split Done
```

```
train_dataset = tf.data.Dataset.from_tensor_slices((train_x, train_y))  
valid_dataset = tf.data.Dataset.from_tensor_slices((val_x, val_y))  
test_dataset = tf.data.Dataset.from_tensor_slices((test_x, test_y))
```

커스텀 데이터 로더를 생성 `tf.data.Dataset`이

```
*_dataset = tf.data.Dataset.from_tensor_slices(*_x, *_y))  
# tf.data.Dataset.from_tensor_slices 함수를 사용해 데이터,라벨을 입력하여 커스텀  
데이터 셋을 생성
```

2. Custom Dataset Preprocessing

```
def pre_processing(image, target):  
    image = tf.reshape(image, [28*28]) # Flatten  
    image = tf.cast(image, dtype=tf.float32) # cast to fp32  
    image /= 255.0 # normalization  
    return image, target
```

`pre_processing` 함수를 사용해 데이터 전처리

```
image = tf.reshape(image, [28*28]) # Flatten
```

데이터 셋의 형태를 [28,28,1]인 이미지 형태에서 [784]로 펼쳐줌

```
image = tf.cast(image, dtype=tf.float32) # cast to fp32
```

데이터 타입을 uint8 에서 fp32로 변경

```
image /= 255.0 # normalization
```

데이터 범위를 0~255에서 0~1.0으로 변경

2. Custom Dataset Preprocessing

```
def pre_processing(image, target):  
    image = tf.reshape(image, [28*28]) # Flatten  
    image = tf.cast(image, dtype=tf.float32) # cast to fp32  
    image /= 255.0 # normalization  
    return image, target  
  
train_dataset = train_dataset.map(pre_processing)  
valid_dataset = valid_dataset.map(pre_processing)  
test_dataset = test_dataset.map(pre_processing)
```

custom dataset 과 전처리 함수를 연결 하는 과정

Dataset.map 을 사용해 전처리 함수(pre_processing)와 데이터 셋을 연결 할 수 있음

2. Custom Dataset Preprocessing

```
train_dataset = train_dataset.shuffle(train_data_size).batch(batch_size)
test_dataset = test_dataset.batch(batch_size)
valid_dataset = valid_dataset.batch(batch_size)
```

Dataset 설정을 진행

```
train_dataset = train_dataset.shuffle(train_data_size).batch(batch_size)
# Dataset.shuffle(버퍼사이즈)를 사용해 데이터를 순서를 임의로 만듦
# Dataset.batch(배치사이즈)를 사용해 데이터를 한번에 몇 개씩 가지고 올지 설정
```

Shuffle, Batch 둘 다 dataset을 반환함

2. Custom Dataset Preprocessing

```
print(train_dataset.element_spec)  
print(test_dataset.element_spec)  
print(valid_dataset.element_spec)
```

Dataset 설정을 진행

shuffle, batch둘다 dataset을 반환함, dataset.element_spec 으로 출력되는 데이터 형태를 확인 할 수 있음

3. Custom Model Build

```
class SubBlock(keras.Model):  
    def __init__(self, units):  
        super(SubBlock, self).__init__() # 꼭 해줘야 함  
        self.block_1 = l.Dense(units)  
        self.act = l.ReLU()  
  
    def call(self, inputs):  
        tensor = self.block_1(inputs)  
        return self.act(tensor)
```

SubClassing 방식을 사용해 커스텀 모델을 생성

`def __init__(self, units):` 생성자

`def call(self, inputs):` 모델이 호출 (feedforward) 될 때 실행

`super(SubBlock, self).__init__()`

부모의 생성자를 실행 SubClassing 방식을 사용할 때 꼭 호출 해야함

3. Custom Model Build

```
class MyModel(keras.Model):  
    def __init__(self, name):  
        super(MyModel, self).__init__(name=name)  
        self.layer_0 = SubBlock(128)  
        self.layer_1 = SubBlock(256)  
        self.layer_2 = SubBlock(512)  
        self.drop = l.Dropout(0.5)  
        self.layer_3 = l.Dense(10)  
  
    def call(self, inputs):  
        tensor = self.layer_0(inputs)  
        tensor = self.layer_1(tensor)  
        tensor = self.layer_2(tensor)  
        tensor = self.drop(tensor)  
        tensor = self.layer_3(tensor)  
        return tensor
```

앞서 생성한 Dense + Relu Layer인 SubBlock을 사용해 모델을 구성

`__init__`에서 모델에 필요한 layer를 생성

`call`에서 생성한 레이어를 호출하여 입력 받은 데이터(`inputs`)로 Feedforward를 진행

3. Custom Model Build

```
def build_model(input_shape, summary, name):  
    model = MyModel(name = "MyModel")  
    model.build(input_shape)  
    if summary: model.summary()  
    return model
```

Custom 모델을 생성하고, build 시키는 과정

```
model.build(input_shape)  
# SubClassing 모델의 경우 build(입력 데이터 형태)를 호출해야 모델 구조를 볼 수 있음  
model.summary()  
# 모델 구조를 출력함
```

3. Custom Model Build



```
class MyModel(keras.Model):  
    def __init__(self, name):  
        super(MyModel, self).__init__(name=name)  
        self.layer_0 = SubBlock(128)  
        self.layer_1 = SubBlock(256)  
        self.layer_2 = SubBlock(512)  
        self.drop = l.Dropout(0.5)  
        self.layer_3 = l.Dense(10)  
  
    def call(self, inputs):  
        tensor = self.layer_0(inputs)  
        tensor = self.layer_1(tensor)  
        tensor = self.layer_2(tensor)  
        tensor = self.drop(tensor)  
        tensor = self.layer_3(tensor)  
        return tensor
```

`model.build(input_shape)`는 입력 데이터 형태를 사용해 더미 데이터를 만들어 모델에 강제로 호출을 진행함. 호출이 진행되면서 연결구조를 알 수 있게 되어 `model.summary()`를 통해 내부 구조를 확인 할 수 있음.

3. Custom Model Build

```
input_shape = (None, 28*28)

model = build_model(input_shape, True, 'MyModel')
loss_function =
    keras.losses.SparseCategoricalCrossentropy(from_logits=True)
optimizer = keras.optimizers.Adam()
```

학습을 위한 손실 함수 및 최적화 함수를 정하는 과정

```
model = build_model(input_shape, True, 'MyModel')
# build_model을 통해 모델을 생성하고 가지고 옴
```

```
keras.losses.SparseCategoricalCrossentropy(from_logits=True)
# 손실 함수 설정
```

```
optimizer = keras.optimizers.Adam()
# 최적화 함수 설정
```

3. Custom Model Build

```
train_loss = keras.metrics.Mean(name='train_loss')
train_accuracy =
    keras.metrics.SparseCategoricalAccuracy(name='train_accuracy')

test_loss = keras.metrics.Mean(name='test_loss')
test_accuracy =
    keras.metrics.SparseCategoricalAccuracy(name='test_accuracy')
```

`keras.metrics.Mean`

입력 값을 받을 때 계산하는 방식이 평균인 측정방법

`*_accuracy = keras.metrics.SparseCategoricalAccuracy(name='train_accuracy')`

정확도 측정을 위한 방법

4. Train step build

```
def train_step(images, targets):  
    with tf.GradientTape() as tape:  
        pred = model(images, training=True)  
        loss = loss_func(targets, pred)  
        # 기울기 계산  
        gradients = tape.gradient(loss, model.trainable_variables)  
        optimizer.apply_gradients(zip(gradients, model.trainable_variables))  
        # Logging  
        train_loss(loss)  
        train_accuracy(targets, pred)
```

학습을 위한 함수

```
with tf.GradientTape() as tape  
# 연산을 기록하여 기울기를 계산하는 객체  
gradients = tape.gradient(loss, model.trainable_variables)  
# 기록된 연산 내용을 사용, 오차와 모델 내부 가중치를 입력 받아 기울기를 계산  
optimizer.apply_gradients(zip(gradients, model.trainable_variables))  
# 계산된 기울기로 모델 가중치 값을 수정
```

4. Train step build

```
def train_step(images, targets):  
    with tf.GradientTape() as tape:  
        pred = model(images, training=True)  
        loss = loss_function(targets, pred)  
        # 기울기 계산  
        gradients = tape.gradient(loss, model.trainable_variables)  
        optimizer.apply_gradients(zip(gradients, model.trainable_variables))  
        # Logging  
        train_loss(loss)  
        train_accuracy(targets, pred)
```

학습을 위한 함수

train_loss(loss)

train_accuracy(targets, pred)

계산된 오차(손실) 및 예측 정확도를 계산

4. Test step build

```
def test_step(images, targets):  
    pred = model(images, training=False)  
    loss = loss_func(targets, pred)  
  
    test_loss(loss)  
    test_accuracy(targets, pred)
```

검증 및 테스트를 위한 함수

```
pred = model(images, training=False)  
# 학습에 사용하는 것이 아니기 때문에 training 값을 False로 입력, 학습 여부에 따라  
동작 방법이 달라지는 레이어가 있음(Dropout, BatchNorm)
```

학습이 아니기 때문에 `tf.GradientTape()`를 사용하지 않음
기울기를 계산할 필요가 없기 때문

5. Training

```
for epoch in range(epochs):  
    train_loss.reset_states()  
    train_accuracy.reset_states()  
    test_loss.reset_states()  
    test_accuracy.reset_states()
```

TRAIN

VALIDATION

Message_Print

학습 파이프 라인

```
for epoch in range(epochs)  
# epochs 만큼의 반복을 가지고 내부에서 학습을 반복하는 2중 for 구조를 가짐  
  
metrics.reset_states()  
# epoch 정확한 값을 출력하기 위해 내부 값을 비움
```

5. Training

TRAIN

```
pbar = tqdm(train_dataset, total=(train_data_size//batch_size)+1)
for images, targets in pbar:
    train_step(images, targets)
    pbar.set_description('[%d/%d] Loss: %0.4f, Acc: %0.4f' % (epoch+1,
        epochs, train_loss.result(), train_accuracy.result()))
```

학습 파이프 라인 ***TRAIN*** 과정

```
pbar = tqdm(train_dataset, total=(train_data_size//batch_size)+1)
# 학습 진행과정을 나타내기 위해 tqdm 패키지로 train_dataset을 래핑
```

```
for images, targets in pbar:
# pbar를 반복해 데이터와 라벨을 받음
```

5. Training

VALIDATION

```
for images, targets in valid_dataset:  
    test_step(images, targets)
```

학습 파이프 라인 ***VALIDATION*** 과정

매 epoch 마다 Valid_dataset을 반복해
데이터, 라벨을 받아 test_step(데이터, 라벨)로 검증 작업을 진행

5. Training

Message_Print

```
itr = optimizer.iterations.numpy()  
msg = ""  
Epoch\t: [%d/%d]  
Itr\t: %d  
-----Train-----  
Loss\t: %0.4f  
Acc\t: %0.4f  
-----Vaild-----  
Loss\t: %0.4f  
Acc\t: %0.4f  
""  
  
print(msg % (epoch+1, epochs, itr,  
train_loss.result(), train_accuracy.result(),  
test_loss.result(), test_accuracy.result()))
```

학습 파이프 라인

Message_Print 과정

optimizer.iterations.numpy()
옵티마이저의 스텝 횟수를
가지고 옴
*.numpy()의 경우
Tensorflow의 데이터를
numpy 데이터로 변환해
가지고 옴

metrics.result()
계산된 메트릭 값을 반환함

6. Model Evaluate

```
test_loss.reset_states()
test_accuracy.reset_states()

for images, targets in tqdm(test_dataset):
    test_step(images, targets)

msg = """
-----Test-----
Loss\t: %0.4f
Acc\t: %0.4f
----- """
print(msg % (test_loss.result(), test_accuracy.result()))
```

학습(for문)을 나와 테스트 데이터로 모델의 정확도를 측정

7. Model Save & Load (Tensorflow SavedModel format)

```
tf.saved_model.save(model, 'MyModel')  
load_model = tf.saved_model.load('MyModel')
```

tf.saved_model을 사용해 모델의 저장 및 불러오기가 가능
save(모델, 저장경로)를 입력하면 저장경로로 모델을 저장함.

저장된 모델은 폴더로 관리되며 모델구조, 모델 가중치, 모델 실행 그래프로 관리된다.

```
load_model = tf.saved_model.load('MyModel')  
# 저장된 모델 경로를 입력하여 모델을 불러온다.
```

SavedModel 폴더 구조

```
graph LR  
  A["./MyModel"] --> B["assets : 구조"]  
  A --> C["variable : 가중치"]  
  A --> D["saved_model.pb : 실행 그래프"]
```

7. Model Save & Load (Tensorflow SavedModel format)

```
for images, targets in tqdm(test_dataset):
    pred = load_model(images, False)
    loss = loss_funcion(targets, pred)
    test_loss(loss)
    test_accuracy(targets, pred)

msg = """-----Test-----
      Loss\t: %0.4f
      Acc\t: %0.4f
      -----"""
print(msg % (test_loss.result(), test_accuracy.result()))
```

테스트를 진행하여 이전 테스트와 비교하여 모델과 가중치가 정확하게 불러와졌는지 확인한다.