Лабораторна робота №4

Класифікація зображень засобами згорткових нейронних мереж

Мета роботи: набути практичних навичок роботи в *Python*; зрозуміти принцип роботи згорткових нейронних мереж.

Література

Документація: https://keras.io/models/sequential/

Розпізнавання об'єктів в базі даних зображень CIFAR - 10https://samyzaf.com/ML/cifar10/cifar10.html

Зміст роботи

Завдання 1. Розробити модель зготкової нейронної мережі (CNN, Convolutional Neural Networks) і застосувати її до класифікації зображень на основі набору даних CIFAR-10.

Набір даних CIFAR-10 зазвичай використовується для дослідження машинного навчання містить 60 000 кольорових зображень 32x32 у 10 різних класах (літак, автомобіль, птах, кішка, олень, собака, жаба, кінь, корабель і вантажівка), 6 000 зображень кожного класу.

Згорткова нейронна мережа - це одна з різних типів нейронних мереж глибокого навчання. CNN дуже потужний і широко використовується в класифікації зображень, розпізнаванні зображень, комп'ютерному зору тощо.

CNN складається з вхідного, вихідного та безлічі прихованих шарів між ними.

Ці шари виконують операції, які змінюють дані з метою вивчення властивостей, притаманних цім даним. Три найбільш поширені рівні - це згортка, активація і об'єднання.

Convolution - це процес, що включає поєднання двох функцій, в результаті чого виходить інша функція. У CNN вхідне зображення піддається згортці з використанням фільтрів, які створюють карту ознак .

ReLU (функція активації) дозволяє проводити більш швидке та ефективне навчання, зіставляючи негативні значення з нулем та зберігаючи позитивні значення.

Pooling спрощує вивід, виконуючи нелінійну субдискретизацію, зменшуючи кількість параметрів.

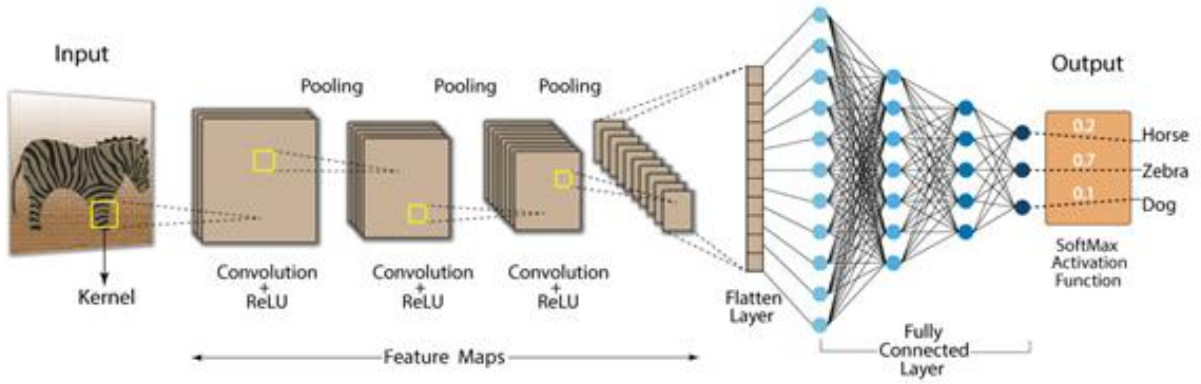

Бібліотеки

```
import numpy as np
```

Набір даних CIFAR-10

```
from keras.datasets import cifar10
```

Базовий клас для навчання нейронної мережі

```
import tensorflow.compat.v1 as tf
tf.disable_v2_behavior()
from tensorflow.keras.models import Model
from tensorflow.keras.layers import Input, Convolution2D, MaxPooling2D, De
nse, Dropout, Flatten
from keras.preprocessing import image
import matplotlib.pyplot as plt
```

Утиліти для одноразового кодування значень

```
from tensorflow.python.keras.utils import np_utils
```

Зазвичай CNN використовує більше параметрів, ніж багатошаровий персептрон (MLP). Задаємо наступні параметри:

– *batch_size* - кількість навчальних зразків, оброблюваних одночасно за одну ітерацію алгоритму градієнтного спуску;

– *num_epochs* - кількість ітерацій навчального алгоритму;

– *kernel_size* - розмір ядра в згорткових шарах;

– *pool_size* - розмір підвибірки в шарах підвибірки;

– *conv_depth* - кількість ядер в згорткових шарах;

– *drop_prob* (dropout probability) - будемо застосовувати dropout після кожного шару підвибірки, а також після повнозв'язного шару;

– *hidden_size* - кількість нейронів у повнозв'язному шарі MLP

- batch_size=32
- num_epochs=5
- kernel_size=3
- pool_size=1
- conv_depth_1=32
- conv_depth_2=64
- drop_prob_1=0.25
- drop_prob_2=0.5
- hidden_size=512

200 епох може зайняти занадто багато часу, якщо у вашому розпорядженні немає графічного процесора. Якщо ви збираєтеся навчати мережу на CPU, варто скоротити кількість епох і / або ядер.

Завантаження та первинну обробку CIFAR-10 *Keras* виконує все автоматично.

```
(X_train, y_train), (X_test, y_test) = cifar10.load_data()
num_train, depth, height, width = X_train.shape
num_test = X_test.shape[0]
num_classes = np.unique(y_train).shape[0]
X_train = X_train.astype('float32')
X_test = X_test.astype('float32')
```

Нормалізувати дані до [0, 1] діапазону

```
X_train/=np.max(X_train)
X_test/=np.max(X_train)
Y_train=np_utils.to_categorical(y_train,num_classes)
Y_test=np_utils.to_categorical(y_test,num_classes)
```

Мережа буде складатися з чотирьох шарів *Convolution_2D* і шарів *MaxPooling2D* після другої і четвертої згорток. Подвоюємо кількість ядер після першого шару підвибірки, після чого вихідне зображення шару підвибірки трансформується у одновимірний вектор (шаром *Flatten*) і проходить два повнозв'язних шари (*Dense*). На всіх шарах, крім вихідного, використовується функція активації *ReLU*, останній же шар використовує *softmax*.

Для регуляризації отриманої моделі після кожного шару підвибірки і першого повнозв'язного шару застосовується шар *Dropout*. Тут Keras також виділяється на тлі інших фреймворків: в ньому є внутрішній прапор, який

автоматично включає і вимикає dropout, в залежності від того, знаходиться модель в фазі навчання або тестування.

Налаштування:

– використовуємо перехресну ентропію як функції втрат;
– використовуємо оптимізатор Адама для градієнтного спуску;
– вимірюємо точність моделі (так як вихідні дані розподілені по класам рівномірно);
– залишаємо 10% даних для подальшої валідації.

```
inp=Input(shape=(depth,height,width))
conv_1=Convolution2D(conv_depth_1,kernel_size,kernel_size,padding='same',a
ctivation='relu')(inp)
conv_2=Convolution2D(conv_depth_1,kernel_size,kernel_size,padding='same',a
ctivation='relu')(conv_1)
pool_1=MaxPooling2D(pool_size=(pool_size,pool_size))(conv_2)
drop_1=Dropout(drop_prob_1)(pool_1)
conv_3=Convolution2D(conv_depth_2,kernel_size,kernel_size,padding='same',a
ctivation='relu')(drop_1)
conv_4=Convolution2D(conv_depth_2,kernel_size,kernel_size,padding='same',a
ctivation='relu')(conv_3)
pool_2=MaxPooling2D(pool_size=(pool_size,pool_size))(conv_4)
drop_2=Dropout(drop_prob_1)(pool_2)
flat=Flatten()(drop_2)
hidden=Dense(hidden_size,activation='relu')(flat)
drop_3=Dropout(drop_prob_2)(hidden)
out=Dense(num_classes,activation='softmax')(drop_3)

model=Model(inp,out)
model.compile(loss='categorical_crossentropy',optimizer='adam',metrics=['a
ccuracy'])
model.fit(X_train,Y_train,batch_size=batch_size,nb_epoch=num_epochs,verbos
e=1,validation_split=0.1)
model.evaluate(X_test,Y_test,verbose=1)
```

Результат:

```
WARNING:tensorflow:The `nb_epoch` argument in `fit` has been renamed
`epochs`.
Train on 45000 samples, validate on 5000 samples
Epoch 1/10
45000/45000 [==============================] - 16s 349us/sample - loss:
1.8304 - acc: 0.3226 - val_loss: 1.5397 - val_acc: 0.4452
Epoch 2/10
45000/45000 [==============================] - 16s 351us/sample - loss:
1.5712 - acc: 0.4235 - val_loss: 1.4027 - val_acc: 0.4900
Epoch 3/10
45000/45000 [==============================] - 15s 344us/sample - loss:
1.4817 - acc: 0.4580 - val_loss: 1.3176 - val_acc: 0.5222
Epoch 4/10
45000/45000 [==============================] - 17s 371us/sample - loss:
1.4226 - acc: 0.4833 - val_loss: 1.3143 - val_acc: 0.5298
Epoch 5/10
```

Завдання 2. Проведіть експерименти з моделлю, що отримали у завданні 1: Спробуйте досягти більшої точності.

Збереження навченої нейронної мережі. Після навчання мережі в Colaboratory потрібно її зберегти і завантажити з хмарної платформи на свій комп'ютер. Для збереження скористайтеся стандартними засобами *Keras*:

```
model_json=model.to_json()
json_file=open("cifar10_model.json","w")
json_file.write(model_json)
json_file.close()
model.save_weights("cifar10_model.h5")
```

Архітектуру нейронної мережі і ваги зберігаємо у файли cifar10_model.json і cifar10_model.h5. Але ці файли знаходяться на віртуальній машині. Перевірити це можна командою ls.

```
!ls
```

Результат:

```
B_1.jpg  B_3.jpg  cifar10_model.h5  cifar10_model.json  sample_data
```

Для завантаження файлів з віртуальної машини на власний комп'ютер можна скористатися вбудованими в Colaboratory засобами роботи з файлами. Підключаємо відповідний модуль:

```
from google.colab import files
```

Завантажуємо файли командами:

```
files.download("cifar10_model.json")
files.download("cifar10_model.h5")
```

Завдання 3. Протестуйте роботу нейронної мережі на зображеннях.

Для цього потрібно завантажити власні зображення з локального комп'ютера на віртуальну машину *Colaboratory*. Скористаємося модулем *files*, у якого є метод *upload()*. При виклику цього методу відкриється вікно вибору файлів браузера. Файли, які ви виберете в цьому вікні, будуть відправлені на віртуальну машину.

```
files.download("cifar10_model.json")
files.download("cifar10_model.h5")
```

Результат:

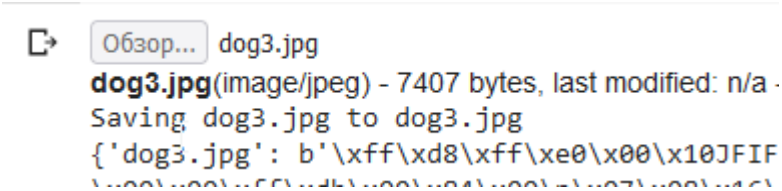

Зображення для перевірки роботи моделі:

Перевіряємо загрузку файлу.

Перетворюємо картинку у масив для розпізнавання.

```
img_path='dog3.jpg'
#img=image.load_img(img_path)
img=tf.keras.utils.load_img(img_path)
plt.imshow(img)
plt.show()
#img=image.load_img(img_path,target_size=(32,32))
img=tf.keras.utils.load_img(img_path,target_size=(32,32))
plt.imshow(img)
plt.show()
```

Результат:

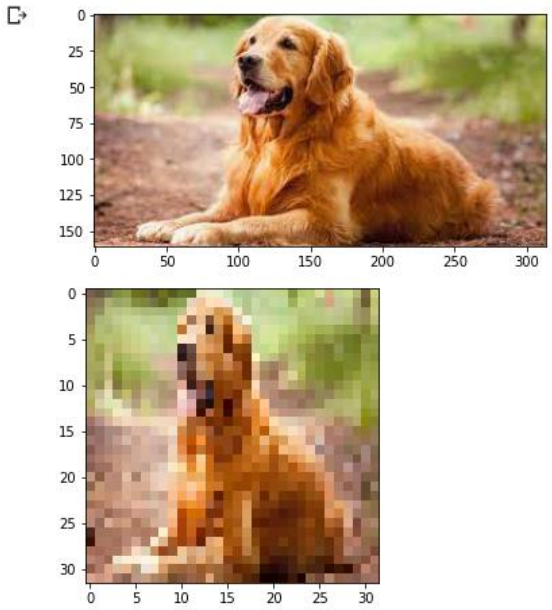

Запускаємо розпізнавання:

```
x=tf.keras.utils.img_to_array(img)

x/=255
x=np.expand_dims(x,axis=0)
prediction=model.predict(x)
classes=['літак','автомобіль','птах','кіт','олень','собака','жаба','кінь',
'корабель','вантажівка']
print(classes[np.argmax(prediction)])
```

Результат:

Завдання 2.3. Протестуйте роботу нейронної мережі на різних зображеннях.

Контрольні запитання

1. Назвіть сфери застосування нейронних мереж.
2. Які шари використовуються в CNN?
3. Назвіть та охарактеризуйте етапи побудови нейромережевої моделі.
4. Яким чином перевіряється правильність роботи навченої мережі?
5. Назвіть недоліки алгоритму зворотного розповсюдження.
6. Охарактеризуйте набор даних CIFAR-10.