

Nowoczesne narzędzia wykorzystywane w technologiach mobilnych

Adam Linke 121529, Mateusz Norel 126901

Uczenie maszynowe




- iOS
 - CoreML
 - CreateML
- Multiplatformowe
 - Tensorflow Lite
 - MLKit



ML Kit

CoreML


- Narzędzie służące do integracji modelu do aplikacji mobilnej na systemie iOS
- możliwe jest konwertowanie niektórych modeli na zgodne z CoreML takich jak modele:
 - tensorflow
 - MXNet



CreateML

- Umożliwia bardzo proste tworzenie i uczenie własnych modeli uczenia maszynowego.
- Pozwala na ćwiczenie modeli do zadań takich jak
 - rozpoznawanie obrazów - `MLImageClassifierBuilder`
 - ekstrahowanie znaczenia z tekstu - `MLTextClassifier`
 - znajdowania relacji pomiędzy wartościami liczbowymi - `MLDataTable`
- Oparte o technologie wykorzystywane w Siri i aplikacji Photos(najprawdopodobniej wykorzystuje także idee zawarte w Turi Create)

Android Neural Networks API



TensorFlow Lite



- Biblioteka istniejących modeli (Image Classification, Object Detection, Smart Reply, Pose Estimation, Segmentation)
- Narzędzia do konwersji
- Narzędzia do optymalizacji (Pruning, Model Quantization)

TensorFlow Lite Interpreter

- Android - Java i C++ API
- iOS - Swift i Objective-C API
- Linux - C++ i Python'owe API

W pełni działające operatory TFLite

- `tf.batch_to_space_nd`
- `tf.exp`
- `tf.fake_quant`
- `tf.matmul`
- `tf.nn.avg_pool`
- `tf.nn.conv2d`
- `tf.nn.depthwise_conv2d`
- `tf.nn.l2_normalize`
- `tf.nn.local_response_normalization`
- `tf.nn.log_softmax`
- `tf.split`
- `tf.nn.max_pool`
- `tf.nn.softmax`
- `tf.nn.top_k`
- `tf.one_hot`
- `tf.pad`
- `tf.reduce_mean`
- `tf.reshape`
- `tf.sigmoid`
- `tf.space_to_batch_nd`
- `tf.space_to_depth`

Niewspierane (tymczasowo) operatory

- `tf.depth_to_space`
- `tf.image.resize_bilinear`
- `tf.tanh`

Istnieje również część operatorów, która nie jest wspierana, ale jest łatwo zastępowalna, przez np. podstawienie kilku innych operacji. Lista takich operatorów również znajduje się na stronie TensorFlow.

Konwersja modelu TensorFlow do TensorFlow Lite

```
tflite_convert \  
  --output_file=/tmp/foo.tflite \  
  --saved_model_dir=/tmp/saved_model
```


```
tflite_convert \  
  --output_file=/tmp/foo.tflite \  
  --graph_def_file=/tmp/some_quantized_graph.pb \  
  --inference_type=QUANTIZED_UINT8 \  
  --input_arrays=input \  
  --output_arrays=MobilenetV1/Predictions/Reshape_1 \  
  --mean_values=128 \  
  --std_dev_values=127
```

```
import tensorflow as tf
```

```
converter = tf.lite.TFLiteConverter.from_saved_model(saved_model_dir)  
converter.optimizations = [tf.lite.Optimize.OPTIMIZE_FOR_SIZE]  
tflite_quant_model = converter.convert()  
open("converted_model.tflite", "wb").write(tflite_quantized_model)
```

```
python -m tensorflow.python.tools.optimize_for_inference \  
  --input=tf_files/retrained_graph.pb \  
  --output=tf_files/optimized_graph.pb \  
  --input_names="input" \  
  --output_names="final_result"
```

Schemat konwersji modelu



Optymalizacja

- Post-training quantization
- Quantization-aware training
- Przycinanie grafu
- zmniejszanie liczby
- optymalizacja dla specjalnych architektur sprzętowych

Model	Top-1 Accuracy (Original)	Top-1 Accuracy (Post Training Quantized)	Top-1 Accuracy (Quantization Aware Training)	Latency (Original) (ms)	Latency (Post Training Quantized) (ms)	Latency (Quantization Aware Training) (ms)	Size (Original) (MB)	Size (Optimized) (MB)
Mobilenet-v1-1-224	0.709	0.657	0.70	124	112	64	16.9	4.3
Mobilenet-v2-1-224	0.719	0.637	0.709	89	98	54	14	3.6
Inception_v3	0.78	0.772	0.775	1130	845	543	95.7	23.9
Resnet_v2_101	0.770	0.768	N/A	3973	2868	N/A	178.3	44.9

Użycie modelu

Java

```
try (Interpreter interpreter = new Interpreter(file_of_a_tensorflowlite_model)) {  
    interpreter.run(input, output);  
}
```

```
interpreter.runForMultipleInputsOutputs(inputs, map_of_indices_to_outputs);
```

C++

```
tflite::FlatBufferModel model(path_to_model);  
  
tflite::ops::builtin::BuiltinOpResolver resolver;  
std::unique_ptr<tflite::Interpreter> interpreter;  
tflite::InterpreterBuilder(*model, resolver>(&interpreter);  
  
// Resize input tensors, if desired.  
interpreter->AllocateTensors();  
  
float* input = interpreter->typed_input_tensor<float>(0);  
// Fill `input`.  
  
interpreter->Invoke();  
  
float* output = interpreter->typed_output_tensor<float>(0);
```

Przyszłość TFLite

- Więcej operatorów
- Wersjonowanie i sygnatury operatorów
- Nowy konwerter
- Usprawnienie TF Select Ops
- Wsparcie dla LSTM i RNN
- Wizualizacja grafów
- Wsparcie dla technik pre-i-post processingu
- Uczenie na urządzeniu
- Dodatkowe API
- Więcej modeli

MLKit



- Text Recognition
- Image Labeling
- Face Detection
- Barcode Scanning
- Landmark Recognition



Firebase

Obliczenia na urządzeniu vs obliczenia w chmurze


	Zalety	Wady
Na urządzeniu	Szybkość Prywatność Nie wymaga połączenia	Ograniczona złożoność operacji Model zajmuje dodatkowe miejsce
W chmurze	Złożone operacje Nie potrzeba modelu na urządzeniu Umożliwia zbieranie danych	Większy czas odpowiedzi Wymaga stałego połączenia Potencjalne zagrożenie dla prywatności

Czym jest AR


Rozszerzona rzeczywistość (Augmented Reality) - System łączący świat rzeczywisty z generowanym komputerowo. Zazwyczaj wykorzystuje się obraz z kamery, na który nałożona jest, generowana w czasie rzeczywistym, grafika 3D. Istnieją także zastosowania wspomagające jedynie dźwięk.

Narzędzia do AR

- iOS
 - ARKit
- Android
 - ARCore (ARCore jest też dla iOS)
- Multiplatformowe
 - Vuforia
 - Unity for Mobile AR(wysoko poziomowe(pod spodem ARKit i ARCore))
 - Unreal Engine(wysoko poziomowe(pod spodem ARKit i ARCore))



unity



ARCore



UNREAL
ENGINE





vuforia™

Narzędzie	Producent	Zastosowanie	Platformy
ARPA SDKs	ARPA Solutions	Komercyjne	Android, iOS (ARPA SDKs), Google Glass (ARPA GLASS SDK), Android, iOS, Windows PC (ARPA Unity Plugin)
ARLab SDKs	ARLab	Komercyjne	Android, iOS
Metaio SDK	Metaio	Darmowe i komercyjne	Android, iOS, Windows PC, Google Glass, Epson Moverio BT-200, Vuzix M-100, Unity
Vuforia SDK	Qualcomm	Darmowe i komercyjne	Android, iOS, Unity
Wikitude SDK	Wikitude GmbH	Komercyjne	Android, iOS, Google Glass, Epson Moverio, Vuzix M-100, Optinvent ORA1, PhoneGap, Titanium, Xamarin


Dzisiejsze zastosowania AR

- gry (pokemon go, minecraft)
- Architektura i wystrój wnętrz (Ikea Place, Augment)
- Rozpoznawanie twarzy (snapchat)
- Pomiary odległości (Air Measure, MeasureKit, TapMeasure)
- Nawigacja (Google maps, American Airlines)
- Tworzenie wizualizacji sprzętu przemysłowego(GE)





Ewolucja AR 1

- 1968 - Ivan Sutherland pierwsze urządzenie AR
- 1974 - Pierwsze interaktywne środowisko AR
- 1990 - Tom Caudell po raz pierwszy używa terminu "Augmented Reality"
- 1998 - Pojawienie się markerów podczas meczy NFL



Ewolucja AR 2

- 1999 - NASA X-38
wykorzystuje system AR aby
nakładać dane mapy podczas
lotów testowych
- 2000 - ARToolKit pierwsza
biblioteka open-source
służąca do nakładania grafik
komputerowych na obraz z
kamery
- 2009 - ARToolKit zaczyna być
wykorzystywany w
przeglądarkach



AR

Ewolucja AR 3

- 2013 - Producenci samochodów zaczynają wykorzystywać AR do serwisowania samochodów(VW MARTA)
- 2014 - Google Glass
- 2015 - Inwestycje AR wynoszą 700 milionów dolarów
- 2016 - Inwestycje wynoszą 1.1 miliarda dolarów, pojawia się Microsoft HoloLens Developer Kit
- 2017 - premiera ARKit
- 2018 - premiera ARCore i ARKit 2





<https://www.youtube.com/watch?v=7ZrmPTPgY3I>

Urządzenia z systemami iOS oraz Android wspierające AR

- iOS
 - iPhone 6s oraz nowsze(w tym także iPhone SE)
 - iPad 5 i 6 generacji oraz iPad Pro(dowolna generacja)
 - nowe modele iPodów
- Android
 - ARCore wymaga systemu Android wersji 7.0 lub późniejszej
 - Wikitude oraz Vuforia wspierają również wcześniejsze wersje Android OS (4.4)

Znajdowanie powierzchni

Dedykowane urządzenia do AR

- HoloLens
- Atheer AiR Glasses
- DAQRI Smart Glasses
- EPSON Smart Glasses
- Google Glass



Optymalne warunki do rozszerzonej rzeczywistości

- Powierzchnia posiadająca punkty charakterystyczne (złe: gładkie biurko/podłoga, dobre: podłoga posiadająca różne wzorki/meble)
- dobre oświetlenie, unikanie powierzchni błyszczących
- unikanie szybkich nagłych ruchów aparatem

Parę przemyśleń po implementacji paru projektów AR na potrzeby prezentacji

- większość testów była wykonywana na starych urządzeniach AR są one bardzo nieprecyzyjne potrafią przesuwac obiekty
- Często aby dane miejsce zostało uznane za powierzchnie musi być ono puste i duże. (W mniejszych pomieszczeniach czasem nie da się znaleźć takiej powierzchni nie powiodły się także testy w których próbowano wykorzystywać drzwi jako taką przestrzeń).

Przyszłość

- Okulary AR(google glass)
- rosnące inwestycje w technologie AR
- możliwa częściowa dezaktualizacja prezentacji(wwdc w dniu prezentacji o 19:00 najprawdopodobniej rozszerzone zostaną technologie CreateML, CoreML, ARKit)



Bibliografia

- <https://unity3d.com/how-to/create-AR-games-in-Unity-efficiently>
- <https://developers.google.com/ar/>
- https://pl.wikipedia.org/wiki/Rzeczywistość_rozszerzona
- <https://www.apple.com/lae/ios/augmented-reality/>
- <https://developer.apple.com/documentation/>
- "App development with Swift" Apple
- <https://github.com/tensorflow/examples/tree/master/lite/examples>
- <https://www.tensorflow.org/lite/>