

DEEP LEARNING FOR APPLE AND PEAR RECOGNITION

DZIĻĀ APMĀCĪBA ĀBOLU UN BUMBIERU ATPAZĪŠANAI

Authors: **Vitālijs ŽUKOVS**, vz16020@edu.rta.lv; **Ilmārs APEINĀNS**, ia16024@edu.rta.lv

Scientific supervisor: **Sergejs KODORS**, Dr.sc.ing. sergejs.kodors@rta.lv

Rezekne Academy of Technologies, Atbrīvošanas aleja 115, Rēzekne, Latvia

Abstract. The aim of this work is to develop a neural network, which can recognize apples and pears. To achieve the goal, the authors applied AlexNet architecture and the open dataset "Fruits360". The trained model showed a good result testing it on validation images - total accuracy 0.97 and latency 35ms/step. In the future research, authors consider training the neural network model using the MobileNet architecture and verify it using the Cohen's Kappa coefficient.

Keywords. AlexNet, apple, CNN, Fruits360, Food2030, neural network, pear

Ievads

Transfer learning ir mašīnmācīšanas metode, kad modelis, kurš ir izstrādāts priekš viena uzdevuma, tiek atkārtoti izmantots citā uzdevumā [2]. Šī ir populāra pieeja dziļajās apmācībā, kur iepriekš sagatavoti modeļi tiek izmantoti kā sagatave datora redzes un dabiskās valodas apstrādes uzdevumiem, nesmot vērā milzīgos aprēķina un laika resursus, kas nepieciešami neironu tīkla modeļu izstrādāšanai.

Neironu tīkla apmācīšana ietver sevi arhitektūru, datu kopu, apmācības parametrus un datu kopas pārveidojumus. Izmantojot *AlexNet* arhitektūru, *CIFAR-10*, *CIFAR-100* [6] un *Fruits 360* [3] datu kopas, tika apmācis neironu tīkls, pielietojot *transfer learning* metodi (tālāk *TL*).

Šī pētījuma **mērķis** ir apmācīt neironu tīklu, pielietojot *TL* metodi un salīdzināt rezultātus ar neironu tīklu bez *TL* metodes pielietošanas.

1. Materiāli un metodes

Eksperimenta laikā tika pielietotas trīs datu kopas: *CIFAR-10*, *CIFAR-100* un *Fruits360*. Datu kopu īpašības ir attēlotas 1. tabulā.

Lai izpildītu māšīnapmācības *uzdevumus*, tika pielietoti *TensorFlow* un *Keras* izstrādes rīki. *TensorFlow* [4] korektam darbam ar *GPU*, bija nepieciešams pieinstalēts klāt:

- *Python 3.7.6* – programmēšanas valoda;
- *CUDA Toolkit* – paralēlas skaitlošanas platforma neiron tīklā paātrināšanai izmantojot *GPU* jaudu;
- *cuDNN* – dziļās apmācības bibliotēka, kura nodrošina optimizēšanu standarta operācijām: apvienošana, normalizācija un slāņu aktivācija;
- *Anaconda* – *Python* datu zinātnes standarta platforma, kura ir paredzēta mašīnmācīšanas uzdevumiem [5];
- *TensorFlow 2.1.0* – atvērta bibliotēka māšīnapmācības uzdevumiem, kuru izstrādāja *Google*, lai ātri realizētu neiron tīklus un apmācītu tos.
- *TensorFlow GPU* – tiek izmantota veikt aprēķinus pielietojot *GPU*.

1. tabula

Datu kopas

Nosaukums	Klases	Attēli	Trenēšanai	Pārbaudei
<i>Fruits 360</i>	120	81120	60498	20622
<i>CIFAR-10</i>	10	60000	50000	10000
<i>CIFAR-100</i>	100	60000	50000	10000

Eksperimenta laikā tika sagatavots *Python* skripts, kuru var sadalīt uz 6. posmiem:

1. Datu kopu sagatavošana un datu augmetācija [7, 8];
2. Modeļa apmācība ar *CIFAR-10* un *CIFAR-100*;
3. Modeļa slāņu iesaldēšana un izejas mainīšana;
4. Modeļa apmācība ar *Fruits360-120*;
5. Modeļa slāņu iesaldēšana un izejas mainīšana;
6. Modeļa apmācība ar *Fruits360-3*.

Datu sagatavošanā ietilpst datu kopas atrašana, pieslēgšana un attēlu sakārtošana. Tālāk sakārtoti dati tiek apstrādāti (pagriezti, palielināti, utt.). Datu augmentācija ir metode, kā mākslīgi izveidot jaunus apmācības datus no esošajiem apmācības datiem. Tas tiek darīts, piemērojot specifiskās metodes piemēriem no apmācības datiem, kas rada jaunus un atšķirīgus apmācības piemērus.

Otrajā punkta modelis tiek apmācīts ar *CIFAR* datu kopas palīdzību. Pirmais slānis tiek iesaldēts, tāpēc ka tas atbild par līniju, krāsu, leņķu atpazīšanu (skat. 1.1. att.) un izmainīta izeja, no 10 un 100 klasēm uz 120.



1.1. attēls. **Modeļa iesaldēto slānu vizualizācijas piemērs** [1]

Tālāk modelis tiek apmācīts atpazīt augļus ar *Fruits360* datu kopas palīdzību un beigās tiek nomainīts klašu *daudzums* no *Fruits360-120* uz *Fruits360-3*, kas ir nepieciešams tieši priekš ābolu, bumbieru attēlu atpazīšanas. Modeļa apmācība ar *Fruits360-3* tika atkārtota 10 reizes.

Sākumā, modelis tiek apmācīts atpazīt līnijas un krāsas. Ar *Fruits360-120* datu kopu, modelis tiek apmācīts atpazīt augļus un pēc tam to pārapmāca atpazīt tieši tos augļus, kuri ir nepieciešami (ābolus un bumbierus).

Eksperimentam par pamatu tika paņemta *AlexNet* arhitektūra. Eksperimenta *AlexNet* arhitektūras modeli, kas tika izmēģināti eksperimentā ir attēloti 2. tabulā. Izmantotajiem arhitektūras modeļiem ir dažādi filtru izmēri. Filtra izmērs iestata konvolūcijas darbībā izmantoto filtru skaitu.

Kā var pamanīt, agrākie 2D konvolūcijas slāņi, kas ir tuvāk ievadei, mācās mazāk filtru, bet vēlākie - vairāk.

2. tabula

Eksperimenta AlexNet modeli

<i>Layer (type)</i>	<i>AlexNet16</i>	<i>AlexNet32</i>	<i>AlexNet64</i>
<i>conv2d-1</i>	(48, 48, 16)	(48, 48, 32)	(48, 48, 64)
<i>batch_normalization</i>	(48, 48, 16)	(48, 48, 32)	(48, 48, 64)
<i>max_pooling2d</i>	(24, 24, 16)	(24, 24, 32)	(24, 24, 64)
<i>conv2d-2</i>	(20, 20, 16)	(20, 20, 32)	(20, 20, 64)
<i>batch_normalization-1</i>	(20, 20, 16)	(20, 20, 32)	(20, 20, 64)
<i>average_pooling2d</i>	(10, 10, 16)	(10, 10, 32)	(10, 10, 64)
<i>dropout-1</i>	(10, 10, 16)	(10, 10, 32)	(10, 10, 64)
<i>conv2d-3</i>	(7, 7, 32)	(7, 7, 64)	(7, 7, 128)
<i>batch_normalization-2</i>	(7, 7, 32)	(7, 7, 64)	(7, 7, 128)
<i>dropout</i>	(7, 7, 32)	(7, 7, 64)	(7, 7, 128)
<i>dense</i>	(512)	(512)	(512)
<i>dropout-2</i>	(512)	(512)	(512)
<i>out_layer</i>	(10)	(10)	(10)

2. Rezultāti

Neirontīku apmācības rezultāti ir apkopoti 3.-8. tabulās. 3. un 4. tabulā ir attēloti *AlexNet16* apmācības un modeļa parametri, kā arī eksperimenta rezultāti, izmantojot *CIFAR* datu kopas priekšapmācības laikā. Atbilstošu informāciju var atrast par *AlexNet32* (skat. 5.-6. tabulas) un *AlexNet64* (skat. 7.-8. tabulas).

3. tabula

AlexNet16

CIFAR-10							
<i>Epoch</i>	<i>Sleep</i>	<i>Step time (ms/step)</i>	<i>Time (min)</i>	<i>Trainable params</i>	<i>Non-trainable params</i>	<i>Accuracy</i>	<i>Validation accuracy</i>
524	200	605	1056	956 426	96	0.82686	0.7872
FRUITS360-120							
<i>Epoch</i>	<i>Sleep</i>	<i>Step time (ms/step)</i>	<i>Time (min)</i>	<i>Trainable params</i>	<i>Non-trainable params</i>	<i>Accuracy</i>	<i>Validation accuracy</i>
100	20	795	320	988 504	24 448	0.95552	0.97963
FRUITS360-3 (average of 10 repeat)							
<i>Time (min)</i>			<i>Accuracy</i>		<i>Validation accuracy</i>		
3.28			0.96269		0.97239		

4. tabula

AlexNet16

CIFAR-100							
<i>Epoch</i>	<i>Sleep</i>	<i>Step time (ms/step)</i>	<i>Time (min)</i>	<i>Trainable params</i>	<i>Non-trainable params</i>	<i>Accuracy</i>	<i>Validation accuracy</i>
763	200	571	1449	1 002 596	96	0.47080	0.48100
FRUITS360-120							
<i>Epoch</i>	<i>Sleep</i>	<i>Step time (ms/step)</i>	<i>Time (min)</i>	<i>Trainable params</i>	<i>Non-trainable params</i>	<i>Accuracy</i>	<i>Validation accuracy</i>
100	20	800	310	988 504	24, 448	0.98681	0.96856
FRUITS360-3 (average of 10 repeat)							
<i>Time (min)</i>			<i>Accuracy</i>		<i>Validation accuracy</i>		
8.53			0.96474		0.97514		

5. tabula

AlexNet32

CIFAR-10							
<i>Epoch</i>	<i>Sleep</i>	<i>Step time (ms/step)</i>	<i>Time (min)</i>	<i>Trainable params</i>	<i>Non-trainable params</i>	<i>Accuracy</i>	<i>Validation accuracy</i>
573	200	623	1212	1 672 426	256	0.82126	0.7879
FRUITS360-120							
<i>Epoch</i>	<i>Sleep</i>	<i>Step time (ms/step)</i>	<i>Time (min)</i>	<i>Trainable params</i>	<i>Non-trainable params</i>	<i>Accuracy</i>	<i>Validation accuracy</i>
74	20	806	240	1 726 424	2 688	0.99126	0.99695
FRUITS360-3 (average of 10 repeat)							
<i>Time (min)</i>		<i>Accuracy</i>			<i>Validation accuracy</i>		
8.91		0.96643			0.95765		

6. tabula

AlexNet32

CIFAR-100							
<i>Epoch</i>	<i>Sleep</i>	<i>Step time (ms/step)</i>	<i>Time (min)</i>	<i>Trainable params</i>	<i>Non-trainable params</i>	<i>Accuracy</i>	<i>Validation accuracy</i>
366	200	560	683	1 718 596	256	0.56978	0.49260
FRUITS360-120							
<i>Epoch</i>	<i>Sleep</i>	<i>Step time (ms/step)</i>	<i>Time (min)</i>	<i>Trainable params</i>	<i>Non-trainable params</i>	<i>Accuracy</i>	<i>Validation accuracy</i>
73	20	780	227	1 726 424	2 688	0.99246	0.99622
FRUITS360-3 (average of 10 repeat)							
<i>Time (min)</i>		<i>Accuracy</i>			<i>Validation accuracy</i>		
5.25		0.97208			0.95673		

7. tabula

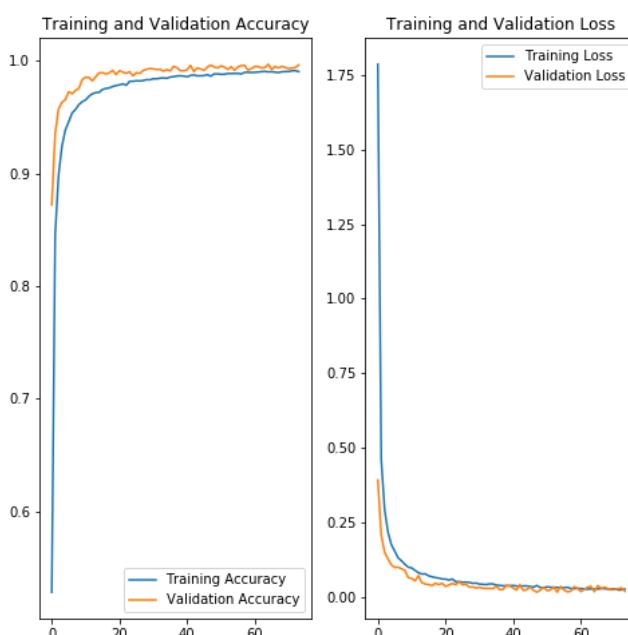
AlexNet64

CIFAR-10							
<i>Epoch</i>	<i>Sleep</i>	<i>Step time (ms/step)</i>	<i>Time (min)</i>	<i>Trainable params</i>	<i>Non-trainable params</i>	<i>Accuracy</i>	<i>Validation accuracy</i>
390	200	645	845	4 012 618	256	0.88224	0.7793
FRUITS360-120							
<i>Epoch</i>	<i>Sleep</i>	<i>Step time (ms/step)</i>	<i>Time (min)</i>	<i>Trainable params</i>	<i>Non-trainable params</i>	<i>Accuracy</i>	<i>Validation accuracy</i>
63	20	847	211	4 064 184	5 120	0.99567	0.99598
FRUITS360-3 (average of 10 repeat)							
<i>Time (min)</i>		<i>Accuracy</i>			<i>Validation accuracy</i>		
10.27		0.97319			0.94981		

8. tabula

AlexNet64

CIFAR-100							
Epoch	Sleep	Step time (ms/step)	Time (min)	Trainable params	Non-trainable params	Accuracy	Validation accuracy
306	200	566	576	4 058 788	256	0.67250	0.48950
FRUITS360-120							
Epoch	Sleep	Step time (ms/step)	Time (min)	Trainable params	Non-trainable params	Accuracy	Validation accuracy
50	20	761	153	4 027 256	42 048	0.99076	0.99525
FRUITS360-3 (average of 10 repeat)							
Time (min)		Accuracy			Validation accuracy		
5.46		0.94406			0.93027		



1.2. attēls. Modeļa trenēšanas un validācijas diagrammas piemērs

Secinājumi

Neironu tīklu apmācībā ir diezgan liels un apjomīgs laika ziņā process. Priekš apmācības ir nepieciešams sagatavot datu kopu, ka arī izvēlēties arhitektūru. Pielietojot *transfer learning* metodi, ir iespējams atkārtoti izmantot iepriekš apmācītu modeli citām vajadzībām. Izmantojot *AlexNet* arhitektūru un *CIFAR* un *FRUITS360* datu kopas tika veikts *transfer learning* eksperiments, kurā, ar *CIFAR* datu kopas apmācīs modelis, tika pārmācīts atpazīt ābolus un bumbierus ar *FRUITS360* datu kopas palīdzību.

Eksperiments tika sadalīts uz trim etapiem:

1. Modeļa apmācība ar *CIFAR10* aizņēma ~17,5 stundas un rezultātā tika iegūta apmācības precizitāte ~0.78% (priekš *AlexNet16* arhitektūras);
2. Modeļa apmācība ar *FRUITS360-120* aizņēma ~5.3 stundas un rezultātā tika iegūta precizitāte ~0.98% (priekš *AlexNet16* arhitektūras);
3. Modeļa apmācība ar *FRUITS360-3* aizņēma ~3.5 minūtes un tika iegūta precizitāte ~0.96% (priekš *AlexNet16* arhitektūras).

Līdz ar to var secināt, ka apmācības laiks ir samazinājies 3 reizēs.

Acknowledgement

Funding institution: Latvian Council of Science

Funding number: lzp-2019/1-0094

Acronym: FLPP-2019-1

Funding text: This research is funded by the Latvian Council of Science, project “Application of deep learning and datamining for the study of plant-pathogen interaction: the case of apple and pear scab”, project No. lzp-2019/1-0094

Summary

Neural network training is a rather large and time-consuming process. For training it is necessary to prepare a data set, as well as to choose the architecture. Using the transfer learning method, it is possible to reuse a previously trained model for other purposes. Using the AlexNet architecture and the CIFAR-FRUITS360 data set, a transfer learning experiment was performed in which, with the CIFAR data set, the model was trained to recognize apples and pears using the FRUITS360 data set.

The experiment was divided into three stages:

1. *Model training with CIFAR10 took ~17.5 hours and as a result training accuracy ~0.78% was obtained (for AlexNet16 architecture);*
2. *Model training with FRUITS360-120 took ~5.3 hours and resulted in accuracy of ~0.98% (for AlexNet16 architecture);*
3. *Model training with FRUITS360-3 took ~3.5 minutes and the accuracy was ~0.96% (for AlexNet16 architecture).*

Thus, it can be concluded that the training time has decreased 3 times.

Literatūra

[1] Konvolūcijas neironu tīkli attēlu atpazīšanai [tiešsaiste], [atsauce uz 01.03.2021]. Pieejams:

<https://habr.com/ru/post/456186/>

[2] Transfer learning [tiešsaiste], [atsauce uz 01.03.2021]. Pieejams:

<https://machinelearningmastery.com/transfer-learning-for-deep-learning/>

[3] Fruits360 datu kopa [tiešsaiste], [atsauce uz 01.03.2021]. Pieejams:

<https://www.kaggle.com/moltean/fruits>

[4] TensorFlow [tiešsaiste], [atsauce uz 01.03.2021]. Pieejams:

<https://www.tensorflow.org/about>

[5] Anaconda rīks [tiešsaiste], [atsauce uz 01.03.2021]. Pieejams:

<https://www.anaconda.com/why-anaconda/>

[6] CIFAR datu kopa [tiešsaiste], [atsauce uz 01.03.2021]. Pieejams:

<https://www.cs.toronto.edu/~kriz/cifar.html>

[7] Datu augmentācija [tiešsaiste], [atsauce uz 03.03.2021]. Pieejams:

<https://algorithmia.com/blog/introduction-to-dataset-augmentation-and-expansion>

[8] Datu augmentācija [tiešsaiste], [atsauce uz 07.03.2021]. Pieejams:

<https://medium.com/analytics-vidhya/data-augmentation-is-it-really-necessary-b3cb12ab3c3f>