

Arsitektur Model CNN untuk Pengenalan Topeng Pandawa

by International Journal Artificial Intelligence and Robotics

Submission date: 28-Jun-2020 11:51PM (UTC+0900)

Submission ID: 1350777026

File name: 2740-8441-2-SM.doc (8.5M)

Word count: 1346

Character count: 8318

Arsitektur Model CNN untuk Pengenalan Topeng Pandawa

Model Architecture of CNN for Recognition the Pandava Mask

Andi Sanjaya¹⁾, Endang Setyati²⁾, Herman Budianto³⁾

^{1,2,3)}Program Studi Teknologi Informasi, Fakultas Sains, Institut Sains dan Teknologi Terpadu Surabaya
Jl. Ngagel Jaya Tengah 73-77, Surabaya, Indonesia 6028

¹⁾4ndisanjaya@gmail.com (*)

²⁾endang@stts.edu

³⁾herman.budianto@gmail.com

Abstract - This research was conducted in an effort to observe looking for CNN model architecture that is suitable for use on the Pandava mask object. The data tested were as much as 200 class data. So there are 1000 trial data in this study. In experiments with LeNet using the input layer 32x32, 64x64, 128x128, 224x224, 256x256 showed that the 32x32 input layer succeeded in showing a faster time than the other input layers, accuracy and validation accuracy are not underfit or overfit. However, when the second dense process is switched from relu to sigmoid, the result of sigmoid is better than relu in terms of time and the possibility of overfit is smaller than using relu.

Keywords – LeNet, Relu Activation, Sigmoid Activation.

Abstrak – Penelitian ini dilakukan dalam upaya observasi mencari arsitektur model CNN yang cocok untuk digunakan pada obyek topeng pandawa. Data yang diujicobakan sebanyak 200 data perkelas. Sehingga ada 1000 data ujicoba pada penelitian ini. Pada percobaan dengan LeNet dengan menggunakan input layer 32x32, 64x64, 128x128, 224x224, 256x256 menunjukkan bahwa input layer 32x32 berhasil menunjukkan waktu yang lebih cepat daripada input layer yang lain, akurasi dan validasi akurasi tidak underfit atau overfit. Namun ketika proses dense kedua aktivasiya diganti dari relu menjadi sigmoid ternyata hasil dari sigmoid lebih baik daripada relu dari segi waktu dan kemungkinan overfit lebih kecil daripada menggunakan relu.

Kata kunci – LeNet, Aktivasi Relu, Aktivasi Sigmoid.

I. PENDAHULUAN

Pengenalan wajah menjadi salah satu fokus penelitian pada akhir-akhir ini. Seperti penelitian ekspresi wajah manusia [1] serta penelitian tentang proses yang terlibat dalam pengenalan wajah seperti perataan wajah dan ekstraksi fiturnya [2]. Penelitian pengenalan wajah heterogen bertujuan untuk mencocokkan gambar wajah yang diperoleh dari modalitas penginderaan yang berbeda dengan aplikasi mission-critical dalam sektor forensik, keamanan dan komersial [3]. Penelitian tentang kerangka kerja komprehensif untuk mengatasi tantangan dalam pengenalan wajah berbasis video [4] dan penelitian tentang pengenalan wajah berdasarkan informasi fitur wajah [5].

CNN pada saat telah berkembang pesat dalam bidang computer vision [6]. Pada bidang computer vision biasanya CNN digunakan sebagai metode pengenalan dan klasifikasi objek [7]. Dalam implementasi CNN perlu ditentukan sebuah arsitektur model. Arsitektur model pada CNN mempunyai banyak parameter [8]. Parameter ini yang akan diubah sesuai kebutuhan. Penentuan arsitektur model ini ditentukan dengan cara melakukan ujicoba untuk mengetahui mana arsitektur model yang baik untuk sebuah objek [9].

Pada penelitian ini, kami mencoba menggunakan arsitektur model LeNet [9][10]. Kami mencoba dengan beberapa inputan dengan format warna RGB, membandingkan hasil suatu inputan dengan format warna lain seperti *Grayscale* dan *Black and White* pada arsitektur yang sama ataupun dengan merubah beberapa parameter. Sehingga ditemukan sebuah arsitektur model CNN dengan parameter yang sesuai untuk topeng pandawa.

II. METODE PENELITIAN

Untuk memudahkan penelitian ini kami membagi proses menjadi dua yaitu pengumpulan data dan perancangan parameter. Pengumpulan data membahas bagaimana kami menyiapkan data pada penelitian ini sedangkan perancangan parameter membahas tentang parameter apa saja yang digunakan saat melakukan ujicoba pada penelitian ini.

A. Pengumpulan Data


Data merupakan dokumentasi pribadi yang kami dapat dari Museum Ganesya di Malang, Jawa Timur, Indonesia. Pada penelitian ini terdapat 5 kelas antara lain yudhistira, bima, arjuna, nakula dan sadewa. Masing-masing kelas ada 200 data. Jadi total data yang digunakan pada penelitian yaitu 1000 data. Adapun contoh data bisa dilihat pada gambar 1.



Gambar 1. Contoh data dari masing-masing kelas

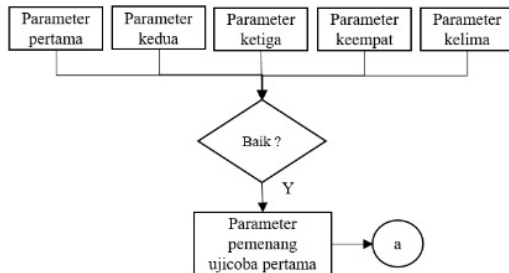
B. Perancangan Parameter

LeNet dikembangkan pertama kali oleh LeCun. Adapun susunan arsitektur model LeNet seperti gambar 2.



Gambar 2. Arsitektur model LeNet

Ujicoba pertama dilakukan dengan menggunakan 5 rancangan parameter yang telah disiapkan. Untuk melihat alur ujicoba pertama bisa dilihat pada gambar 3.



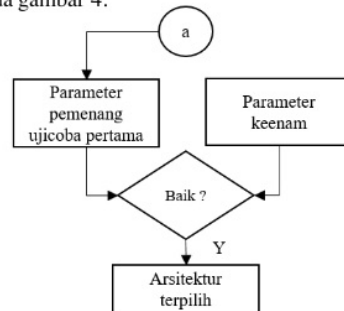
Gambar 3. Alur ujicoba pertama

Rancangan parameter pertama dilakukan ujicoba dengan menggunakan *input layer* antara lain 32x32. Rancangan parameter kedua menggunakan 64x64. Rancangan parameter ketiga menggunakan 128x128. Rancangan parameter keempat 224x224. Rancangan parameter kelima menggunakan 256x256. Semua rancangan parameter *input layer*-nya menggunakan format warna RBG.

Hasil ujicoba dengan parameter pertama akan disimpulkan *input layer* yang menghasilkan hasil yang baik. Indikator penentuan hasil yang baik antara lain.

- Waktu pemrosesan
- Akurasi dan validasi akurasi tidak overfit atau underfit.

Kemudian *input layer* terpilih akan dilakukan pengujian kedua dengan alur ujicoba yang bisa dilihat pada gambar 4.



Gambar 4. Alur ujicoba kedua

Ujicoba kedua menggunakan parameter keenam. Parameter keenam menggunakan arsitektur model seperti parameter pertama namun pada proses dense

Tabel 1. Hasil ujicoba pertama

Epoch	Rancangan parameter				
	1	2	3	4	5
1	0,4104	0,2958	0,4417	0,2125	0,4569
2	0,4188	0,6432	0,4145	0,3889	0,5108
3	0,5299	0,5385	0,4979	0,406	0,7478
4	0,5876	0,7137	0,7415	0,4658	0,7284
5	0,5406	0,6859	0,7714	0,7094	0,9267
6	0,6603	0,7564	0,8675	0,7799	0,9246
7	0,6752	0,8034	0,7714	0,8056	0,9263
8	0,7009	0,8056	0,9509	0,8376	0,9784
9	0,7051	0,8568	0,8953	0,8846	0,9914
10	0,7543	0,7799	0,9701	0,9487	0,9892
.
.
.
100	1	1	1	1	1

kedua menggunakan sigmoid sebagai aktivasi. Sehingga pada ujicoba kedua bisa diketahui bagaimana performa arsitektur model dengan mengubah aktivasi pada proses dense terakhir.

Tabel 2. Hasil perbandingan ujicoba pertama

Input Layer	RA	RVA	NA = 1	NVA = 1	Waktu proses (detik)
32x32	0,90	0,94	0	40	1022
64x64	0,89	0,95	0	47	4392
128x128	0,94	0,97	4	75	18410
224x224	0,93	0,96	1	51	57450
256x256	0,96	0,98	18	84	74228

III. HASIL DAN PEMBAHASAN

Pada ujicoba pertama berhasil mendapatkan data seperti tabel 1.

Pada tabel 1, diketahui bahwa validasi akurasi mengalami peningkatan pada masing-masing hasil *input layer* walaupun ada juga yang fluktuatif. Untuk mengetahui hasil perbandingan ujicoba pertama bisa dilihat pada tabel 2.

Pada tabel 2, RA menjelaskan tentang rata-rata akurasi. RVA menjelaskan tentang rata-rata validasi akurasi. NA = 1 menjelaskan tentang jumlah akurasi yang mencapai 100%. NVA menjelaskan tentang jumlah validasi akurasi yang mencapai 100%. Apabila dilihat pada tabel

Tabel 3. Hasil perbandingan ujicoba kedua

Aktivasi	RA	RVA	NA = 1	NVA = 1	Waktu proses (detik)
relu	0,90	0,94	0	40	1022
sigmoid	0,86	0,90	0	11	931

2, nilai akurasi sudah sangat baik karena lebih dari 0.8 atau 80%. Namun yang perlu diamati adalah NA dan NVA, memang bisa saja suatu prediksi bisa 100% namun apabila prediksi tersebut muncul dan sering. Bisa jadi hal tersebut dikatakan overfit [9]. Oleh karena pada parameter pertama dipilih *input layer* 32x32 sebagai parameter yang baik.

Untuk ujicoba kedua bisa dilihat hasil perbandingan pada tabel 3.

Pada tabel 3 bisa dilihat bahwa sigmoid lebih cepat daripada relu. Secara performa RA dan RVA sigmoid lebih rendah dibanding relu. Namun untuk NVA relu lebih banyak daripada sigmoid.

IV. KESIMPULAN

Beda obyek beda juga arsitektur model yang digunakan. Pada penelitian ini telah dicoba berbagai macam *input layer* dengan berhadapan kepada arsitektur model yang sama. Namun hasilnya sangat berbeda. Setiap parameter pada arsitektur model yang digunakan CNN akan menghasilkan hasil yang berbeda. Arsitektur model dikatakan baik apabila tidak *underfit* atau *overfit*.

DAFTAR PUSTAKA

- [1] D. Qu, Z. Huang, Z. Gao, Y. Zhao, X. Zhao and G. Song, "An Automatic System for Smile Recognition Based on CNN and Face Detection," 2018 IEEE International Conference on Robotics and Biomimetics (ROBIO), Kuala Lumpur, Malaysia, 2018, pp. 243-247. doi: 10.1109/ROBIO.2018.8665310
- [2] S. Sharma, K. Shanmugasundaram and S. K. Ramasamy, "FAREC — CNN based efficient face recognition technique using Dlib," 2016 International Conference on Advanced Communication Control and Computing Technologies (ICACCCT), Ramanathapuram, 2016, pp. 192-195. doi: 10.1109/ICACCCT.2016.7831628
- [3] R. He, X. Wu, Z. Sun and T. Tan, "Wasserstein CNN: Learning Invariant Features for NIR-VIS Face Recognition," in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 41, no. 7, pp. 1761-1773, 1 July 2019. doi: 10.1109/TPAMI.2018.2842770
- [4] C. Ding and D. Tao, "Trunk-Branch Ensemble Convolutional Neural Networks for Video-Based Face Recognition," in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 40, no. 4, pp. 1002-1014, 1 April 2018. doi: 10.1109/TPAMI.2017.2700390
- [5] H. Zhang, Z. Qu, L. Yuan and G. Li, "A face recognition method based on LBP feature for CNN," 2017 IEEE 2nd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), Chongqing, 2017, pp. 544-547. doi: 10.1109/IAEAC.2017.8054074
- [6] M. Y. W. Teow, "Understanding Convolutional Neural Networks Using A Minimal Model for Handwritten Digit Recognition," no. October, pp. 167-172, 2017. doi: 10.1109/I2CACIS.2017.8239052
- [7] S. Albawi, T. A. Mohammed, and S. Al-Zawi, "Understanding of a Convolutional Neural Network," Int. Conf. Eng. Technol., pp. 1-6, 2017. doi: 10.1109/ICEngTechnol.2017.8308186
- [8] F. Ertam and G. Aydin, "Data classification with deep learning using Tensorflow," 2017 Int. Conf. Comput. Sci. Eng., pp. 755-758, 2017. doi: 10.1109/UBMK.2017.8093521

- [9] ¹ T. Septianto, E. Setyati, and J. Santoso, "Model CNN LeNet dalam Rekognisi Angka Tahun pada Prasasti Peninggalan Kerajaan Majapahit," *Jurnal Teknologi dan Sistem Komputer*, vol. 6, no. 3, pp. 106-109, Jul. 2018. <https://doi.org/10.14710/jtsiskom.6.3.2018.106-109>
- [10] ⁵ S. S. Ahranjany, F. Razzazi, and M. H. Ghassemian, "A very high accuracy handwritten character recognition system for Farsi/Arabic digits using convolutional neural networks," *Proc. 2010 IEEE 5th Int. Conf. Bio-Inspired Comput. Theor. Appl. BIC-TA 2010*, pp. 1585–1592, 2010. doi: 10.1109/BICTA.2010.5645265

Arsitektur Model CNN untuk Pengenalan Topeng Pandawa

ORIGINALITY REPORT

24%

SIMILARITY INDEX

20%

INTERNET SOURCES

16%

PUBLICATIONS

21%

STUDENT PAPERS

PRIMARY SOURCES

1

jtsiskom.undip.ac.id

Internet Source

4%

2

Submitted to Universitas 17 Agustus 1945
Surabaya

Student Paper

3%

3

defta.org

Internet Source

3%

4

Submitted to Study Group Australia

Student Paper

2%

5

Submitted to Universiti Teknikal Malaysia
Melaka

Student Paper

2%

6

Submitted to University of South Florida

Student Paper

2%

7

Submitted to Universidad Politecnica Salesiana
del Ecuador

Student Paper

2%

8

link.springer.com

Internet Source

2%

9	Submitted to University of Auckland Student Paper	1%
10	Submitted to University of Strathclyde Student Paper	1%
11	Submitted to Universitas Sebelas Maret Student Paper	1%
12	staff.uny.ac.id Internet Source	<1%
13	Submitted to Universiti Teknologi MARA Student Paper	<1%

Exclude quotes Off

Exclude matches Off

Exclude bibliography Off