

## BAB 5

### KESIMPULAN DAN SARAN

Quark-quark dan gluon-gluon yang terbentuk dari proses tumbukan antarproton dapat dibedakan dengan menggunakan berbagai metode dari *machine learning*. Dalam tugas akhir ini, terdapat dua metode yang digunakan, yaitu *shallow network* dan CNN. Dari kedua metode tersebut, CNN lah yang memiliki hasil paling baik. CNN berhasil memprediksi data validasi dengan benar hingga 70.5% sedangkan *shallow network* hanya mampu memprediksi 58.5% saja. CNN dibangun dengan arsitektur yang lebih kompleks. Sehingga CNN dinilai memiliki performa lebih baik karena proses pembelajarannya lebih mendalam. Selain itu, karena adanya *maxpooling* metode CNN menghabiskan memori lebih sedikit dibandingkan dengan *shallow network*.

Pada kedua metode ini data yang digunakan tidak sepenuhnya memberikan informasi yang bermakna. Hanya sebagian informasi penting yang terdapat dari data yang berukuran  $448 \times 360$ . Misalnya, dari  $448 \times 360$ , hanya  $200 \times 100$  yang memuat informasi yang berguna. Oleh karena itu, penulis mengusulkan agar proses pengolahan menggunakan data yang sudah dipotong sehingga data-data tersebut hanya memuat informasi-informasi yang berguna saja. Sehingga, memori yang digunakan dapat berkurang dan sisa memori yang ada dapat digunakan untuk memperbanyak data. Selain itu, memori yang tersisa dapat digunakan juga untuk memperdalam arsitektur jaringan yang digunakan.

## DAFTAR REFERENSI

- [1] Griffiths, D. J. (2008) *Introduction to Elementary Particles*, 2nd edition. WILEY-VCH, German.
- [2] Feranie, S. (2010) Bab 2 partikel penyusun materi dan gaya. Diktat Kuliah di Universitas Pendidikan Indonesia, Bandung.
- [3] chalmers, M. (2019) Lhc experiments reborn. *CERN Courier*, **59** No.1, 25–30.
- [4] Sjöstranda, T., Ask, S., Christiansen, J. R., Corke, R., Desai, N., Ilten, P., Mrenna, S., Prestel, S., Rasmussen, C. O., dan Skands, P. Z. (2014) An introduction to pythia 8.2. *CERN-PH-TH-2014-190*, **01**, 4.
- [5] CERN The large hadron collider (lhc). <https://home.cern/science/accelerators/large-hadron-collider>. diakses pada 28 November 2018.
- [6] Rasal1, R. D. (2015) Laws of high energy particle dynamics. *IOSR-JAP*, **1**, 1.
- [7] Sirunyan, A. dan et al (2019) Search for long-lived particles decaying into displaced jets in proton-proton collisions at  $\sqrt{s} = 13$  tev. *Phys. Rev.*, **D99**, 032011.
- [8] CERN (2016) The accelerator complex. <https://home.cern/science/accelerators/accelerator-complex>. diakses pada 10 Juli 2019.
- [9] Siegel, E. (2016) Could the large hadron collider make an earth-killing black hole? <https://medium.com/startswithabang/could-the-large-hadron-collider-make-an-earth-killing-black-hole-1da6ee2bd7d9>. diakses pada 28 November 2018.
- [10] CERN Detector. <https://cms.cern/detector>. diakses pada 28 November 2018.
- [11] Bai, Y. dan Schwaller, P. (2018) Cms looks into the dark. *CERN Courier*, **58** No. 7, 15–17.
- [12] Kallonen, K. (2019) Quantitative comparison of deep neural networks for quark/gluon jet discrimination. Thesis. University Of Helsinki, Helsinki, Finland.
- [13] Gagnon, P. (2014) The standard model: A beautiful but flawed theory. <https://www.quantumdiaries.org/2014/03/14/the-standard-model-a-beautiful-but-flawed-theory/>. 15 November 2018. [5] Graham, D. M. (2017) If we are able to split. diakses pada 15 November 2018.
- [14] Graham, D. M. (2017) If we are able to split an atom, then theoretically, wouldn't we be able to keep splitting it? or if it disintegrated, then couldn't we split the neutron, electron or proton? <https://www.quora.com>If-we-are-able-to-split-an-atom-then-theoretically-wouldnt-we-be-able-to-keep-splitting>. diakses pada 19 April 2019.
- [15] Hubsch, T. (2018) What is quark confinement? <http://energywavetheory.com/explanations/whats-in-a-proton/>. diakses pada 19 April 2019.

- [16] Boscolo, M., Huber, P., dan Long, K. (2018) Muons cooled for action. *CERN Courier*, **58 No.6**, 19–23.
- [17] Shane, J. (2018) Neural networks, explained. *Physics World*, **page**, 5–7.
- [18] Komiske, P. T., Metodiev, E. M., dan Schwartz, M. D. (2018) Deep learning in color: Towards automated quark/gluon jet discrimination. *JHEP*, **01**, 1–5.
- [19] Imran, A. A. (2017) Intuition of gradient descent for machine learning. <https://medium.com/abdullah-al-imran/intuition-of-gradient-descent-for-machine-learning-49e1b6b89c8b>. diakses pada 29 Mei 2019.
- [20] Andrew, N. Supervised learning. Technical Report CS229. Stanford University, California.
- [21] Sharma, S. (2017) Activation functions in neural network. <https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6>. diakses pada 22 Mei 2019.
- [22] Agrawal, R. (2017) Shallow neural networks. <https://towardsdatascience.com/shallow-neural-networks-23594aa97a5>. diakses pada 20 Juni 2019.
- [23] Dave, A., Riaz, M. A., dan Kinkade, N. (2015) Convolutional neural networks. Technical Report CSE-291-PA4. University of California, San Diego.
- [24] Yalcin, O. G. (2018) Image classification in 10 minutes with mnist dataset. <https://towardsdatascience.com/image-classification-in-10-minutes-with-mnist-dataset-54c35b77a38d>. diakses pada 29 April 2019.
- [25] Team, S. (2018) Convolutional neural networks (cnn): Step 3 - flattening. <https://www.superdatascience.com/blogs/convolutional-neural-networks-cnn-step-3-flattening>. diakses pada 22 Mei 2019.
- [26] Padhi, S., Millstein, T., Nori, A., dan Sharma, R. (2019) Overfitting in synthesis: Theory and practice. *arXiv:1905.07457*, **3**, 2.