

## BAB 4

### KESIMPULAN DAN SARAN

#### 4.1 Kesimpulan

Dalam tugas akhir ini, penulis mengambil kesimpulan dari hasil uji model arsitektur-arsitektur tersebut bahwa semua model tersebut mampu mengklasifikasikan bentuk galaksi. Uji data tersebut dengan citra sebanyak 9000 data yang diperoleh dari paper Willet (Referensi [17]) dengan ukuran  $96 \times 96$  pixel. Selain itu, hasil survei yang didapat ini menjadi pengaruh penting terhadap pengklasifikasian bentuk-bentuk galaksi itu.

Sebab, hasil yang diperoleh untuk klasifikasi bentuk galaksi dari gambarnya diperoleh dengan melihat Gambar 3.6 bahwa akurasi dari ketiga model arsitektur yang dijabarkan pada Gambar 3.6 diperoleh hasil yang cukup signifikan dimana sebuah akurasi mencapai di atas 60% yang artinya sudah cukup bagus dibandingkan hanya 50% artinya masih ada bisa ada setengah yang salah atau masih acak. Hasil yang terbaik akurasi untuk data training dan validasi diperoleh dari model arsitektur pertama yang mencapai di atas 64,5% (*training set*) dan 62,5% (*test set*) artinya model arsitektur pertama-lah yang memiliki performa paling bagus. Hal ini terlihat ketika dibandingkan dengan model arsitektur kedua yang memiliki akurasi yang tertinggi mencapai 65% untuk data validasi dan training-nya namun ia memiliki ketidakkonsistenan atau pergerakan naik turunnya yang cukup tajam yang terlihat dari garis oranye pada Gambar 3.6b dan 3.7b ini disebabkan ada data validasi ada yang tidak cocok dengan data trainingnya atau tidak cukup. Terlebih lagi, model arsitektur ketiga ini terlalu lambat dibandingkan model lainnya dengan melihat akurasi yang baru mencapai 60% setelah 240 epoch. Ini artinya kedua arsitektur ini agak jelek dalam memprediksi data bentuk sebuah galaksi. Selain itu, untuk klasifikasi survei dari sebuah pertanyaan yang mengacu referensi [17] didapatkan bahwa model arsitektur ketiga memiliki hasil performa yang sangat bagus dimana memiliki error yang sangat kecil terlihat grafik validasi lossnya yang sama-sama menurun (atau sejalan) dengan training loss-nya dibanding arsitektur lainnya yang tetap stabil (arsitektur pertama) dan bisa naik (arsitektur kedua) terlihat dari Gambar 3.6b. Model arsitektur lainnya seperti model pertama dan kedua masih memiliki loss yang menurun sangat bagus mencapai di bawah 0,005 atau bisa dikatakan sudah mencapai 0. Akan tetapi, penulis mendapatkan kesimpulan untuk ketiga model klasifikasi survei kelas ini didapatkan bahwa model arsitektur pertama memiliki performa signifikan dalam loss training-nya yang mencapai paling kecil dari yang lainnya dan loss validasi-nya tidak mengalami overfitting baik menaik atau menurun.

Hasil akurasi dan loss dari setiap model ini dipengaruhi oleh komposisi jumlah data masing-masing jenis bentuk galaksi yang dimuat dalam 9000 data itu sendiri. Seperti dalam laporan kali ini, penulis menggunakan data berjumlah 9000 data yang didominasi dengan data bentuk galaksi dari elips dengan jumlah 40,3% dari datanya, sedangkan 0,08%-nya dari 9000 data atau yang setara dengan 7 buah itu hanya diisi oleh bintang/artifak. Terlebih lagi, dengan adanya penggunaan data training dan validasi yang dipecah de-

ngan rasio 70 : 30 akan membuat sebuah data menjadi terbagi-bagi sehingga terjadi masalah dari salah satu pihak antara pada saat training ataupun validasi terutama pada saat training karena satu atau beberapa yang digunakan sebagai data untuk validasi mungkin ada yang penting bagi proses training model.

Tabel 4.1: Tabel komposisi jumlah data dalam 9000 buah data.

Jenis Galaksi	Jumlah Data	Persentase Jumlah Data
Elips	3626	40,3%
Spiral	2732	30,36%
Tak Beraturan	2635	1,28%
Bintang/Artifak	7	0,08%

## 4.2 Saran

Setelah melalui penelitian dari beberapa model arsitektur yang digunakan, penulis menyarankan agar RAM yang digunakan lebih besar dari 2 GB yang penulis uji. Sebab dengan RAM ukuran yang lebih besar, kapasitas data yang dapat diperoleh akan semakin banyak sehingga performa uji akurasi dari klasifikasi galaksi ini mungkin dapat lebih akurat. Ditambah lagi, akurasi akan semakin bagus jika citra yang diproses masih sama dengan ukuran citra atau tanpa mengecilkannya.

## DAFTAR REFERENSI

- [1] Rosenberg, A. (2019) Hubble photo shows what a side view of the milky way might look like. <https://mashable.com/article/nasa-hubble-spiral-galaxy-photo-milky-way>. Diakses tanggal 22 Oktober 2021.
- [2] Bennett, J. O. (2013) *Cosmic perspective: Pearson New International Edition*. Pearson, England, Harlow.
- [3] Dunbar, B. (2015) Our milky way gets a makeover. [https://www.nasa.gov/mission\\_pages/spitzer/multimedia/20080603a.html](https://www.nasa.gov/mission_pages/spitzer/multimedia/20080603a.html). Diakses tanggal 3 Januari 2022.
- [4] Glozman, I. (2021). <https://people.highline.edu/iglozman/classes/astronotes/cycles.htm>. Diakses tanggal 12 November 2021.
- [5] Ciccolella, A. (2011) Gruppo locale. [https://it.wikipedia.org/wiki/Gruppo\\_Locale](https://it.wikipedia.org/wiki/Gruppo_Locale). Diakses tanggal 12 November 2021.
- [6] News, S. (2016) Hubble space telescope spies dwarf irregular galaxy ngc 5264. <https://www.sci.news/astronomy/hubble-dwarf-irregular-galaxy-ngc-5264-04120.html>. Diakses tanggal 12 November 2021.
- [7] (2020) What are neural networks? <https://www.ibm.com/uk-en/cloud/learn/neural-networks>. Diakses tanggal 13 Januari 2022.
- [8] Ganesh, S. (2020) What's the role of weights and bias in a neural network? <https://towardsdatascience.com/what-s-the-role-of-weights-and-bias-in-a-neural-network-4cf7e9888a0f>. Diakses tanggal 13 Januari 2022.
- [9] Varma, S. dan Das, S. (2018) Deep learning. <https://srdas.github.io/DLBook/GradientDescentTechniques.html>. Diakses tanggal 5 November 2022.
- [10] Chollet, F. (2021) *Deep learning with Python*. Simon and Schuster, New York.
- [11] Moroney, L. (2019) Build convolutions and perform pooling. <https://developers.google.com/codelabs/tensorflow-3-convolutions>. Diakses tanggal 10 Januari 2022.
- [12] Team, G. (2020) Edge deep learning. <https://galliot.us/2020/05/11/edge-deep-learning-p1/>. Diakses tanggal 10 Januari 2022.
- [13] Doshi, K. (2021) Batch norm explained visually - how it works, and why neural networks need it. <https://towardsdatascience.com/batch-norm-explained-visually-how-it-works-and-why-neural-networks-need-it-k>. Diakses tanggal 9 Juli 2022.

- [14] Team, D. (2021).
- [15] Team, S. (2018). <https://www.superdatascience.com/blogs/convolutional-neural-networks-cnn-step-3-flattening>. Diakses tanggal 10 Januari 2022.
- [16] Adepoju, O. (2019) A step-by-step tutorial on coding neural network logistic regression model from scratch. <https://theopetunde.medium.com/a-step-by-step-tutorial-on-coding-neural-network-logistic-regression-model-from-scratch>. Diakses tanggal 18 Januari 2022.
- [17] Willett, K. W., Lintott, C. J., Bamford, S. P., Masters, K. L., Simmons, B. D., Casteels, K. R., Edmondson, E. M., Fortson, L. F., Kaviraj, S., Keel, W. C., dan et al. (2013) Galaxy zoo 2: Detailed morphological classifications for 304 &nbsp;122 galaxies from the sloan digital sky survey. *Monthly Notices of the Royal Astronomical Society*, **435**, 2835–2860.
- [18] Space Place, N. (2020) What is a galaxy? <https://spaceplace.nasa.gov/galaxy/en/>. Diakses tanggal 22 Oktober 2021.
- [19] Schiller, J. (2010) *Big Bang & Black Holes*. CreateSpace, United States of America.
- [20] Putri, G. S. (2018) 9 fakta galaksi bima sakti, dari kisah wayang sampai serangan bintang. <https://sains.kompas.com/read/2018/10/19/100100623/9-fakta-galaksi-bima-sakti-dari-kisah-wayang-sampai-serangan-bintang?page=all>. Diakses tanggal 25 Oktober 2021.
- [21] The Editors of Encyclopaedia, B. (2011). <https://www.britannica.com/science/interstellar-medium>. Diakses tanggal 11 November 2021.
- [22] Sharma, S. (2017) Activation functions in neural networks. <https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6>. Diakses tanggal 11 Oktober 2022.
- [23] Kumar, P. (2021). <https://medium.com/artificialis/softmax-function-and-webonception-4248917e5a1c>. Diakses tanggal 19 Oktober 2022.
- [24] Team, K. (2022) Keras documentation: Normalization layer. [https://keras.io/api/layers/preprocessing\\_layers/numerical/normalization/](https://keras.io/api/layers/preprocessing_layers/numerical/normalization/). Diakses tanggal 8 Desember 2022.
- [25] Asthana, M. (2018) Introduction to convolutional neural networks. <https://medium.com/analytics-vidhya/introduction-to-convolutional-neural-networks-c50f41e3bc66>. Diakses tanggal 10 Juli 2022.
- [26] Developers, G. (2022) Normalization. <https://developers.google.com/machine-learning/data-prep/transform/normalization>. Diakses tanggal 10 Juli 2022.
- [27] Team, K. (2022) Why choose keras? [https://keras.io/why\\_keras/](https://keras.io/why_keras/). Diakses tanggal 13 Januari 2022.

- [28] Davis, T. (2019) What is an api and how does it work? <https://towardsdatascience.com/what-is-an-api-and-how-does-it-work-1dccd7a8219e>. Diakses tanggal 13 Januari 2022.
- [29] Team, K. (2022) Keras : the python deep learning api. <https://keras.io/>. Diakses tanggal 13 Januari 2022.