

PENGUNAAN METODE GLCM DENGAN *DEEP LEARNING* UNTUK PERBANDINGAN KLASIFIKASI BAHAN MAKANAN

Filbert

Program Studi Teknik Informatika, Fakultas Teknologi Informasi, Universitas Tarumanagara
Jl. Letjen S. Parman No.1, Jakarta Barat, DKI Jakarta, Indonesia 11410
e-mail: *Filbert.535180020@stu.untar.ac.id*

ABSTRAK

Penelitian ini merupakan laporan hasil penggunaan beberapa metode untuk menunjukkan tingkat keakuratan terhadap 6 bahan makanan dengan jumlah sampel data masing-masing bahan makanan adalah 50 gambar. Penelitian ini menerapkan metode GLCM dan *Deep Learning* melakukan klasifikasi. Hasil pengujian dan pembuatan program menunjukkan akurasi untuk *DecisionTree Classifier* memiliki akurasi 0.32%, *LogisticRegression* sebesar 0.28%, *Bagging Classifier* sebesar 0.23%, *GradientBoost Classifier* sebesar 0.37%, *InceptionV3* sebesar 0.93%, *ResNet50* sebesar 0.30%, dan *Xception* sebesar 0.85%. Dari hasil yang diperoleh dapat disimpulkan bahwa metode *Deep Learning* dengan model *InceptionV3* menjadi pilihan terbaik karena berhasil mengklasifikasikan setiap bahan makanan dengan akurasi paling tinggi di antara model lain yang digunakan.

Kata kunci: Pembelajaran Mendalam, Klasifikasi, GLCM, Bahan Makanan, *InceptionV3*

ABSTRACT

This study is a report on the results of using several methods to show the level of accuracy for six food items, with a sample size of 50 images for each food item. This study applied the GLCM and Deep Learning methods to perform classification. The results of testing and program development show that the DecisionTree Classifier has an accuracy of 0.32%, LogisticRegression 0.28%, Bagging Classifier 0.23%, GradientBoost Classifier 0.37%, InceptionV3 0.93%, ResNet50 0.30%, and Xception 0.85%. From the results obtained, it can be concluded that the Deep Learning method with the InceptionV3 model is the best choice because it successfully classified each food ingredient with the highest accuracy among the other models used.

Keywords: Deep Learning, Classification, GLCM, Food Ingredients, *InceptionV3*.

1. PENDAHULUAN

Di tengah pesatnya perkembangan teknologi kecerdasan buatan atau *Artificial Intelligence* (AI) saat ini. Belum banyak orang yang mengetahui bahwa kecerdasan buatan itu terdiri dari beberapa cabang, salah satunya adalah *machine learning* atau pembelajaran mesin. Teknologi ML ini merupakan salah satu cabang dari AI yang pada pengaplikasiannya memiliki cabang lainnya seperti *Natural Language Processing* (NLP), *Computer Vision*, *Speech Recognition*, dan *Robotics*.

Pembelajaran mesin dikembangkan berdasarkan disiplin ilmu lainnya seperti statistika, matematika, dan *data mining* sehingga mesin dapat belajar dengan menganalisis data tanpa perlu di program ulang atau diperintah [1]. *Deep learning* merupakan sub-bidang machine learning yang algoritmanya terinspirasi dari struktur otak manusia. Saat ini, teknik *deep learning* sangat populer di kalangan praktisi data dan menarik perhatian banyak pihak. Hal ini karena teknologi *deep learning* telah diterapkan dalam berbagai produk berteknologi tinggi seperti *self-driving car*.

Selain itu, ia juga ada di balik produk dan layanan yang kita gunakan sehari-hari [2]. Klasifikasi merupakan salah satu topik utama dalam ML, dimana data yang digunakan tersebut mempunyai kelas label atau target, sehingga algoritma diperlukan untuk menyelesaikan masalah klasifikasi yang dikategorisasikan ke dalam *supervised learning* atau pembelajaran yang diawasi. Maksud dari pembelajaran yang diawasi adalah data label atau target ikut berperan sebagai

supervisor yang mengawasi proses pembelajaran dalam mencapai tingkat akurasi atau presisi tertentu [3].

Oleh karena itu, beragam metode dapat digunakan dalam melakukan sebuah eksperimen atau penelitian. Pada penelitian ini digunakan 6 jenis bahan makanan yang berbeda sebagai sampel data penelitian dengan jumlah untuk masing-masing jenis sebanyak 50 gambar. Tujuan yang ingin dicapai dalam penelitian ini adalah untuk mengetahui hasil tingkat akurasi dengan penggunaan metode GLCM dan beberapa model *deep learning*. Manfaat yang diharapkan dapat dicapai dalam penelitian ini adalah melalui penggunaan metode ini dapat menjadi referensi atau literatur tambahan yang menjadi rujukan untuk penelitian-penelitian selanjutnya dengan topik yang serupa.

2. TINJAUAN LITERATUR

Jurnal dengan Judul “Thai Fast Food Image Classification Using Deep Learning” menunjukkan hasil keakuratannya sebesar 100% untuk beberapa gambar melalui penggunaan Deep Learning. Kemudian prosesnya adalah dengan melakukan input gambar, gambar yang diambil sebanyak 3960 sampel gambar dan terbagi atas beberapa kategori makanan cepat saji dengan masing-masing 300 objek gambar, kemudian dilakukan *pre-processing* yang diubah ukuran gambarnya menjadi 256x256 *pixels*. Untuk metode *deep learning* sendiri, dilakukan beberapa proses tahapan layer sehingga menjadi kecil dan terdapat garis serta ukuran untuk melakukan *processing* sehingga didapat hasil akhir klasifikasi.

Kemudian jurnal dengan judul “Polyth-Net: Classification of Polythene Bags for Garbage Segregation Using Deep Learning”, menunjukkan hasil akurat sebesar 96% untuk data training, 88 % untuk data *testing*, dan 95% untuk hasil validasinya. Metode yang digunakan adalah dengan metode *Xception*. Sampel data *training* sebanyak 1200 gambar untuk kelas plastik dan 500 gambar untuk non-plastik. Hasil akhir menunjukkan bahwa *Polyth-net* dapat memberikan hasil performa yang baik dalam melakukan sebuah klasifikasi

3. METODE PENELITIAN

3.1 Pengolahan Data

Data yang digunakan adalah gambar berbagai macam bahan makanan yaitu bawang merah, bawang putih, cabai merah, cabai jawa, cabai rawit, dan paprika.. Contoh data dapat di lihat pada Gambar 1, Gambar 2, Gambar 3, Gambar 4, Gambar 5, dan Gambar 6.



Gambar 1. Bawang Merah



Gambar 2. Bawang Putih



Gambar 3. Cabai Merah



Gambar 4. Cabai Jawa



Gambar 5. Cabai Rawit




Gambar 6. Paprika

Setelah semua gambar sudah disimpan sesuai dengan kelasnya masing-masing, proses dimulai dengan menentukan library yang akan digunakan dilanjutkan dengan menentukan properti gambar yang akan dioleh seperti *dissimilarity*, *correlation*, *homogeneity*, *contrast*, *ASM*, dan *energy*. Properti-properti tersebut diperlukan untuk memuat algoritma GLCM agar dapat memproses bentuk matrix pada gambar.

3.2 Penerapan Algoritma

Penelitian ini menggunakan dua jenis pendekatan yaitu *Gray Level Co-occurrence Matrix* (GLCM) dan *Convolutional Neural Network* (CNN).

GLCM merupakan teknis analisis tekstur pada citra dan merepresentasikan hubungan antara 2 pixel yang saling bertetangga (*neighboring pixels*) yang memiliki intensitas keabuan (*grayscale intensity*), jarak dan sudut. Terdapat 8 sudut yang dapat digunakan pada GLCM, diantaranya sudut 0°, 45°, 90°, 135°, 180°, 225°, 270°, atau 315° yang masing-masing sudut tersebut dapat di lihat pada Gambar 7 berikut.



Gambar 7. Sudut Algoritma GLCAM

Formula matematika yang digunakan dalam algoritma GLCM untuk masing-masing properti yang sudah ditentukan adalah sebagai berikut:

$$Energy = \sum_{i=1}^N \sum_{j=1}^M P(i,j)^2$$


$$Homogeneity = \sum_{i=1}^N \sum_{j=1}^M \frac{P(i-j)}{|i-j|}$$

$$Contrast = \sum_{i=1}^N \sum_{j=1}^M (i-j)^2 P(i,j)$$

$$Correlation = \frac{(i - \mu_1)(j - \mu_j)P(i,j)}{\sigma_i \sigma_j}$$


$$Entropy = \sum_{i=1}^N \sum_{j=1}^M P(i,j) \log P(i,j)$$

CNN terdiri dari banyak layer untuk memproses dan mengekstrak fitur dari data. CNN biasanya digunakan untuk mengolah citra atau mendeteksi objek. Saat ini, CNN banyak digunakan untuk mengidentifikasi citra satelit, citra medis, dan mendeteksi anomali. Teknik ini terinspirasi dari bagaimana cara mamalia dan manusia menghasilkan persepsi visual dengan cara kerjanya yang sama seperti neuron pada otak yang ditunjukkan oleh Gambar 8 berikut.



Gambar 8. Cara kerja algoritma CNN

CNN terdiri dari neuron yang memiliki weight, bias dan activation function. Convolutional layer juga terdiri dari neuron yang tersusun sedemikian rupa sehingga membentuk sebuah filter dengan panjang dan tinggi (pixels) [4]. Pada gambar 9 dibawah ini ditunjukkan alur kerja dari penelitian.



Gambar 9. Alur kerja penelitian

3.3 Metode Evaluasi

Beberapa metode evaluasi yang digunakan dalam penelitian ini adalah *recall*, *precision*, dan *F1-score*. *Recall* dapat didefinisikan sebagai rasio dari jumlah total contoh positif yang diklasifikasikan bernilai benar dibagi dengan jumlah total contoh positif. *High recall* menunjukkan kelas dikenali dengan baik yaitu pada nilai *False Negative* yang rendah. Persamaan *recall* ditunjukkan seperti dibawah ini [5]:

$$Recall = \frac{TP}{TP + FN}$$

Precision merupakan pembagian dari jumlah total contoh positif yang diklasifikasikan bernilai benar dengan jumlah total contoh positif yang diprediksi. *High Precision* menunjukkan contoh berlabel positif memang positif ditandai dengan nilai *False Positive* yang rendah. Persamaan *precision* dapat dilihat seperti dibawah ini [6]:

$$Precision = \frac{TP}{TP + FP}$$

Secara definisi, *F1-Score* adalah harmonic mean dari *precision* dan *recall*. *F1-Score* ditunjukkan pada rumus dibawah ini [7]:

$$\frac{1}{F1} = \frac{1}{2} \left(\frac{1}{precision} + \frac{1}{recall} \right)$$

Nilai terbaik *F1-score* adalah 1.0 dan nilai terburuknya adalah 0. Secara representasi, jika *F1-score* punya skor yang baik mengindikasikan bahwa model klasifikasi memiliki *precision* dan *recall* yang baik.

4. HASIL DAN PEMBAHASA

Setelah dilakukan beberapa percobaan pada GLCM, didapatkan hasil untuk *precision*, *recall* dan *F1-score* dibawah ini. Gambar 10 menampilkan hasil untuk GLCM melalui *Decision Tree Classifier*.

	precision	recall	f1-score	support
Bawang Merah	0.29	0.20	0.24	20
Bawang Putih	0.31	0.38	0.34	13
Cabe Jawa	0.58	0.50	0.54	14
Cabe Merah	0.27	0.43	0.33	14
Cabe Rawit	0.12	0.07	0.09	15
Paprika	0.33	0.43	0.38	14
accuracy			0.32	90
macro avg	0.32	0.33	0.32	90
weighted avg	0.31	0.32	0.31	90

Gambar 10. Hasil Evaluasi metode GLCM melalui Model *Decision Tree Classifier*

Melalui hasil evaluasi klasifikasi dengan *Decision Tree Classifier*, bawang merah mendapat nilai *precision* 0.29%, *recall* dengan 0.20%, dan *F1-score* yang rendah yaitu 0.24%. Kemudian bawang putih mendapat nilai *precision* 0.31%, *recall* dengan 0.38%, dan *F1-score* yaitu 0.34%. Cabai Jawa mendapat nilai *precision* yang cukup baik yaitu 0.58%, 0.43% untuk nilai *recall*, dan 0.54 untuk *F1-score*. Cabai merah mendapat nilai *precision* 0.27%, nilai *recall* 0.43%, dan *F1-score* 0.33%. Cabai rawit mendapat nilai terendah yaitu 0.12% untuk *precision*, 0.07% untuk *recall* dan 0.09% untuk *F1-score*. Paprika mendapatkan nilai *precision* 0.33%, 0.43% untuk *recall* dan 0.38% untuk *F1-score*. Dengan nilai rata-rata akurasi sebesar 0.32%.

Melalui hasil evaluasi klasifikasi dengan *Bagging Classifier* seperti yang ditunjukkan pada Gambar 11, bawang merah mendapat nilai *precision* 0.33%, *recall* dengan 0.10%, dan *F1-score* yaitu 0.15%. Kemudian bawang putih mendapat nilai *precision* 0.20%, *recall* dengan 0.15%, dan *F1-score* yaitu 0.17%. Cabai Jawa mendapat nilai *precision* yang cukup baik, yaitu 0.38%, 0.43% untuk nilai *recall*, dan 0.40 untuk *F1-Score*. Cabai merah mendapat nilai terendah yaitu *precision* dengan nilai 0.05%, nilai *recall* 0.07%, dan *F1-score* 0.06%. Cabai rawit dengan nilai 0.32% untuk *precision*, 0.53% untuk *recall* dan 0.40% untuk *F1-score*. Paprika mendapatkan nilai *precision* 0.14%, 0.14% untuk *recall* dan 0.14% untuk *F1-score*. Dengan nilai rata-rata akurasi hanya sebesar 0.23%.

	precision	recall	f1-score	support
Bawang Merah	0.33	0.10	0.15	20
Bawang Putih	0.20	0.15	0.17	13
Cabe Jawa	0.38	0.43	0.40	14
Cabe Merah	0.05	0.07	0.06	14
Cabe Rawit	0.32	0.53	0.40	15
Paprika	0.14	0.14	0.14	14
accuracy			0.23	90
macro avg	0.24	0.24	0.22	90
weighted avg	0.25	0.23	0.22	90

Gambar 11. Hasil Evaluasi metode GLCM melalui Model *Bagging Classifier*

Melalui hasil evaluasi klasifikasi dengan *Gradient Boosting* seperti yang ditunjukkan pada Gambar 12, bawang merah mendapat nilai *precision* 0.40%, *recall* dengan 0.40%, dan *F1-score* yaitu 0.40%. Kemudian bawang putih mendapat nilai *precision* 0.44%, *recall* dengan 0.62%, dan *F1-score* yaitu 0.52%. Cabai Jawa mendapat nilai *precision* yang cukup baik, yaitu 0.44%, 0.29% untuk nilai *recall*, dan 0.35 untuk *F1-Score*. Cabai merah mendapat nilai *precision* sebesar 0.35%, nilai *recall* 0.43%, dan *F1-score* 0.39%. Cabai rawit dengan nilai 0.14% untuk *precision*, 0.13% untuk *recall* dan 0.14% untuk *F1-score*. Paprika mendapatkan nilai *precision* 0.42%, 0.36% untuk *recall* dan 0.38% untuk *F1-score*. Dengan nilai rata-rata akurasi hanya sebesar 0.37%.


	precision	recall	f1-score	support
Bawang Merah	0.40	0.40	0.40	20
Bawang Putih	0.44	0.62	0.52	13
Cabe Jawa	0.44	0.29	0.35	14
Cabe Merah	0.35	0.43	0.39	14
Cabe Rawit	0.14	0.13	0.14	15
Paprika	0.42	0.36	0.38	14
accuracy			0.37	90
macro avg	0.37	0.37	0.36	90
weighted avg	0.37	0.37	0.36	90

Gambar 12. Hasil Evaluasi metode GLCM melalui Model *Gradient Boosting*

Hasil klasifikasi dengan metode *InceptionV3* menunjukkan akurasi untuk data training dan validation yang seimbang, dan nilai loss untuk *training* dan *validation* menunjukkan nilai rendah. Artinya tidak banyak fitur yang hilang ketika dilakukan proses *epoch* sebanyak 50 kali. Grafik *training* dan *loss* yang dihasilkan dari algoritma ini dapat di lihat pada Gambar 13.

Melalui hasil evaluasi klasifikasi dengan *InceptionV3* seperti yang ditunjukkan pada Gambar 14, bawang merah mendapat nilai *precision* 0.71%, *recall* dengan 0.91%, dan *F1-score* yaitu 0.80%. Kemudian bawang putih mendapat nilai *precision* 1.0%, *recall* dengan 0.67%, dan *F1-score* yaitu 0.80%. Cabai Jawa mendapat nilai *precision* yang cukup baik, yaitu 0.93%, 0.93% untuk nilai *recall*, dan 0.93% untuk *F1-Score*. Cabai merah mendapat nilai *precision* sebesar 1.0%, nilai *recall* 0.67%, dan *F1-score* 0.80%. Cabai rawit dengan nilai 0.67% untuk *precision*, 0.93% untuk *recall*, dan 0.78%

untuk *F1-score*. Paprika mendapatkan nilai *precision* 0.94%, 1.0% untuk *recall*, dan 0.97% untuk *F1-score*. Dengan nilai rata-rata akurasi hanya sebesar 0.85%.




Gambar 13. Grafik *training* dan *loss* InceptionV3

	precision	recall	f1-score	support
0	0.71	0.91	0.80	11
1	1.00	0.67	0.80	15
2	0.93	0.93	0.93	15
3	1.00	0.67	0.80	15
4	0.67	0.93	0.78	15
5	0.94	1.00	0.97	15
accuracy			0.85	86
macro avg	0.88	0.85	0.85	86
weighted avg	0.88	0.85	0.85	86

Gambar 14. Hasil Evaluasi metode CNN melalui Arsitektur *InceptionV3*

Hasil dengan metode *ResNet50* menunjukkan akurasi untuk data *training* dan *validation* yang sangat rendah dan tidak stabil, dan nilai *loss* untuk *training* dan *validation* menunjukkan nilai rendah. Artinya metode ini tidak cocok untuk digunakan dalam pengklasifikasian terhadap gambar karena banyak fitur yang bias ketika dilakukan *epoch* sebanyak 50 kali. Grafik pergerakan nilai *training* dan *loss* untuk algoritma ini ditunjukkan oleh Gambar 15.

Melalui hasil evaluasi klasifikasi dengan *Resnet50* seperti yang ditunjukkan pada Gambar 16, bawang merah mendapat nilai *precision* 1.0%, *recall* dengan 0.09%, dan *F1-score* yaitu 0.17%. Kemudian bawang putih mendapat nilai *precision* 0.17%, *recall* dengan 0.27%, dan *F1-score* yaitu 0.21%. Cabai Jawa mendapat nilai *precision* hanya 0.28%, 0.73% untuk nilai *recall*, dan 0.21% untuk *F1-Score*. Cabai merah mendapat nilai *precision* sebesar 0.47%, nilai *recall* 0.53%, dan *F1-score* 0.50%. Cabai rawit dengan nilai 0.40% untuk *precision*, 0.13% untuk *recall*, dan 0.20% untuk *F1-score*. Paprika mendapatkan nilai *precision* 0.0%, 0.0% untuk *recall*, dan 0.0% untuk *F1-score*. Dengan nilai rata-rata akurasi hanya sebesar 0.30%.



Gambar 15. Grafik training dan loss Resnet50


	precision	recall	f1-score	support
0	1.00	0.09	0.17	11
1	0.17	0.27	0.21	15
2	0.28	0.73	0.41	15
3	0.47	0.53	0.50	15
4	0.40	0.13	0.20	15
5	0.00	0.00	0.00	15
accuracy			0.30	86
macro avg	0.39	0.29	0.25	86
weighted avg	0.36	0.30	0.25	86

Gambar 16. Hasil Evaluasi metode CNN melalui Arsitektur Resnet50

Hasil dengan metode *Xception* menunjukkan akurasi untuk data *training* dan *validation* yang seimbang, dan nilai *loss* untuk *training* dan *validation* menunjukkan nilai rendah. Artinya tidak banyak data yang hilang ketika dilakukan *epoch* sebanyak 50 kali. Grafik pergerakan nilai *training* dan *loss* untuk algoritma ini ditunjukkan oleh Gambar 17.

Melalui hasil evaluasi klasifikasi dengan Resnet50 seperti yang ditunjukkan pada Gambar 18 bawang merah mendapat nilai *precision* 0.71%, *recall* dengan 0.91%, dan *F1-score* yaitu 0.80%. Kemudian bawang putih mendapat nilai *precision* 1.00%, *recall* dengan 0.67%, dan *F1-score* yaitu 0.80%. Cabai Jawa dengan nilai *precision* yaitu 0.93%, 0.93% untuk nilai *recall*, dan 0.93 untuk *F1-score*. Cabai merah dengan nilai *precision* 1.00%, nilai *recall* 0.67%, dan *F1-score* 0.80%. Cabai rawit dengan nilai 0.67% untuk *precision*, 0.93% untuk *recall* dan 0.78% untuk *F1-score*. Paprika mendapatkan nilai *precision* 0.94%, 1.00% untuk *recall* dan 0.97% untuk *F1-score*. Dengan nilai rata-rata akurasi mencapai 0.85%.

Seluruh hasil eksperimen kemudian ditampung ke dalam Tabel 1 untuk melihat perbandingan dari seluruh model dan arsitektur yang digunakan dalam penelitian ini



Gambar 17. Grafik training dan loss Xception

	precision	recall	f1-score	support
0	0.71	0.91	0.80	11
1	1.00	0.67	0.80	15
2	0.93	0.93	0.93	15
3	1.00	0.67	0.80	15
4	0.67	0.93	0.78	15
5	0.94	1.00	0.97	15
accuracy			0.85	86
macro avg	0.88	0.85	0.85	86
weighted avg	0.88	0.85	0.85	86

Gambar 18. Hasil Evaluasi metode CNN melalui Arsitektur Xception

Tabel 1. Perbandingan Hasil Evaluasi Setiap Model

	Precision (%)	Recall (%)	F1-score (%)	Accuracy (%)
<i>Decision Tree</i>	0.32	0.33	0.32	0.32
<i>Bagging Classifier</i>	0.24	0.24	0.22	0.23
<i>Gradient Boosting</i>	0.37	0.37	0.36	0.37
<i>InceptionV3</i>	0.93	0.93	0.93	0.93
<i>ResNet50</i>	0.39	0.29	0.25	0.30
<i>Xception</i>	0.88	0.85	0.85	0.85

Dari tabel di atas dapat disimpulkan bahwa beberapa model memberikan performa terbaik dalam mengenali citra bahan makanan yang dapat dibuktikan dengan hasil evaluasi yang dapat dikatakan cukup baik. Contoh model yang memberikan hasil terbaik adalah model CNN dengan arsitektur *InceptionV3* dan *Xception* yang masing-masing memiliki total akurasi sebesar 93% dan 85%.

5. KESIMPULAN

Dari penelitian yang telah dilakukan, maka dapat disimpulkan bahwa penggunaan algoritma *Deep Learning* dengan metode *InceptionV3* dan *Xception* dapat menampilkan hasil akurasi yang maksimal dibandingkan dengan algoritma *ResNet50* dan algoritma GLCM yang hasilnya tidak mencapai lebih dari 50%. Namun, dibalik kesuksesan hasil yang diperoleh masih perlu di amati lagi karena kemungkinan adanya bias pada data, sehingga kedua model dengan performa terbaik kemungkinan mengalami kekeliruan dalam mengolah setiap fitur pada citra.

Melalui perbandingan yang ditampilkan melalui tabel perbandingan juga dapat dijadikan sebagai referensi pada saat ingin melakukan penelitian selanjutnya dengan menggunakan metode *transfer learning* atau dengan menambahkan metode *fine-tuning*. Oleh karena pengaturan parameter dan penyesuaian sebelum melalui tahapan menyusun algoritma GLCM sangat diperlukan agar setiap *pixel* pada citra dapat dioleh dengan lebih baik lagi, sehingga saran untuk penelitian selanjutnya adalah menggunakan metode-metode yang sudah disebutkan sebelumnya.

DAFTAR PUSAKA

- [1] N. Hnoohom and S. Yuenyong, "Thai Fast Food Image Classification Using Deep Learning," 15th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-NCON2018), 2018.
- [2] D. Singh, "Polyth-Net : Classification of Polythene Bags for Garbage Segregation Using Deep Learning," 202 International Conference on Sustainable Energy and Future Electric Transportation (SeFeT), 21-23 January 2021, GRIET, Hyderabad, India, 2021.
- [3] R. Setiawan, "Mengenal Deep Learning Lebih Jelas," 9 October 2021. [Online]. Available: <https://www.dicoding.com/blog/mengenal-deep-learning/>.
- [4] D. Intern, "Apa itu Machine Learning? Beserta Pengertian dan Cara Kerjanya," 19 August 2020. [Online]. Available: <https://www.dicoding.com/blog/machine-learning-adalah/>.
- [5] S. Setiawan, "Membicarakan Precision, Recall dan F1-Score," Medium.com, 12 July 2020. [Online]. Available: <https://stevkarta.medium.com/membicarakan-precision-recall-dan-f1-score-e96d81910354>. [Accessed 24 May 2022].
- [6] M. Yunus, "#3 Machine Learning Evaluation," Medium.com, 12 January 2020. [Online]. Available: <https://yunusmuhammad007.medium.com/3-machine-learning-evaluation-239426e3319e>. [Accessed 24 May 2022].
- [7] D. J. Hand, P. Christen, and N. Kirielle, "F*: an interpretable transformation of the F-measure," Machine Learning, vol. 110, no. 3, pp. 451–456, Mar. 2021.