

Model Transfer Learning untuk Klasifikasi Kesegaran Buah Jeruk Menggunakan Citra Digital

Liana Trihardianingsih¹, Hanifah Permatasari²

¹Sistem Informasi, Fakultas Ilmu Komputer, Universitas PGRI Jombang

²Sistem Informasi, Fakultas Ilmu Komputer, Universitas Duta Bangsa Surakarta

E-mail: [*¹liana@upjb.ac.id](mailto:liana@upjb.ac.id), [²hanifah_permatasari@udb.ac.id](mailto:hanifah_permatasari@udb.ac.id)

Abstrak – Kemajuan teknologi dalam bidang pembelajaran mesin dan pengolahan citra digital telah menawarkan solusi yang lebih efektif di dunia pertanian untuk mengklasifikasikan kualitas buah. Salah satu metode untuk menyelesaikan masalah mengklasifikasi kualitas buah adalah penggunaan deep learning untuk pengolahan citra digital. Dalam penelitian ini, proses klasifikasi akan dilakukan pada buah jeruk dengan mengadopsi arsitektur Convolutional Neural Network (CNN), yaitu ResNet50 dan Inception-V3. Dataset yang digunakan terdiri dari dua kelas, yaitu kelas fresh dan kelas stale. Proses pendistribusian dilakukan secara acak menjadi tiga bagian, dimana 80% untuk pelatihan, 10% untuk validasi, dan 10% untuk pengujian. Proses klasifikasi dilakukan dengan menggunakan batch size 32, epoch 100, optimizer Adam, dan learning rate 1e-4. Hasil penelitian menunjukkan bahwa kedua model menghasilkan nilai akurasi yang sama yaitu 99,67%. Namun, kedua model memiliki nilai loss dan waktu komputasi yang berbeda. Inception-V3 memiliki nilai loss sebesar 0,0148, sedangkan ResNet50 mencatat nilai loss yang lebih kecil, yaitu 0,0074. Nilai loss ini juga sebanding dengan waktu komputasi masing-masing model. Inception-V3 membutuhkan waktu 26,29 detik untuk satu iterasi, sementara ResNet50 hanya memerlukan 0,92 detik per iterasi. Jika dilihat dari total penggunaan memori, ResNet50 menggunakan 52,4% ruang memori, sedangkan Inception-V3 hanya menggunakan 5,2%.

Kata Kunci — Buah Jeruk, Inception-V3, Klasifikasi, ResNet50

1. PENDAHULUAN

Sektor pertanian adalah salah satu bagian terpenting yang membantu pertumbuhan ekonomi sebuah negara [1]. Seiring waktu, persaingan di sektor ini terus meningkat, yang ditunjukkan dengan peningkatan produktivitas, kualitas, dan efisiensi usaha [2]. Untuk menghadapi tantangan tersebut, diperlukan inovasi guna mendukung peningkatan kualitas dan kuantitas hasil produksi. Salah satu subsektor yang sangat membutuhkan inovasi adalah industri buah, khususnya dalam memastikan kualitas produk yang dihasilkan, seperti buah jeruk. Buah jeruk merupakan salah satu komoditas hortikultura yang sangat diminati oleh masyarakat di seluruh dunia karena kaya akan kandungan nutrisinya seperti banyaknya kandungan vitamin C [3].

Tingkat kepuasan pelanggan ketika membeli buah sangat bergantung pada kualitas dan kesegarannya. Kesegaran buah menjadi indikator utama yang menentukan kematangan, rasa, serta masa simpan produk. Dalam praktiknya, penilaian kesegaran buah jeruk sering kali dilakukan secara manual berdasarkan tampilan visual, seperti warna kulit, tekstur, dan adanya cacat fisik. Namun, proses manual ini memiliki keterbatasan, seperti subjektivitas, inkonsistensi, serta ketergantungan pada pengalaman individu. Hambatan-hambatan ini dapat mengurangi produktivitas dan efisiensi dalam rantai distribusi buah jeruk [4].

Kemajuan teknologi dalam bidang pembelajaran mesin dan pengolahan citra digital menawarkan solusi yang lebih efektif. Beberapa penelitian telah menunjukkan potensi besar teknologi ini dalam mengatasi berbagai masalah klasifikasi berbasis citra. Penelitian yang dilakukan oleh Ulandari telah memanfaatkan teknik computer vision untuk klasifikasi kualitas jeruk dengan menggunakan pendekatan berbasis ekstraksi fitur GLCM dan HSV untuk menganalisis tekstur dan warna kulit jeruk. Penelitian ini menggunakan dataset sebanyak 3.061 citra dan memperoleh akurasi hingga 86,88% [5].

Selain itu, terdapat penelitian lain yang mengembangkan sistem untuk klasifikasi kesegaran buah jeruk menggunakan algoritma Naïve Bayes. Dengan memanfaatkan dataset gambar jeruk, sistem ini berhasil mencapai akurasi pelatihan sebesar 72,7% dan akurasi pengujian 62,6% [3]. Penelitian lain memanfaatkan fitur warna RGB dan HSV untuk mengklasifikasikan jeruk segar dan busuk dengan mengadopsi algoritma K-Nearest Neighbor (KNN). Dengan nilai k yang bervariasi, penelitian ini mencapai akurasi tertinggi sebesar 88,95% menggunakan dataset yang terdiri dari 146 data pelatihan dan 88 data pengujian [6]. Sistem ini memberikan alternatif metode yang lebih sederhana untuk meningkatkan efisiensi dalam klasifikasi buah.

Ekstraksi fitur tekstur dan warna merupakan salah satu pendekatan yang sering digunakan untuk proses klasifikasi buah. Local Binary Pattern (LBP) merupakan metode yang digunakan dalam ekstraksi fitur tekstur

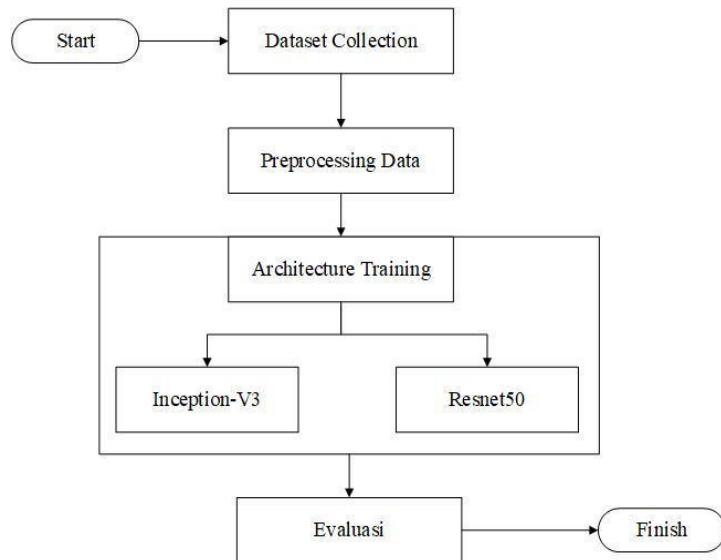
sederhana yang efisien dalam merepresentasikan pola tekstur, sedangkan HSV (Hue, Saturation, Value) digunakan untuk mengidentifikasi warna dasar yang dapat mentoleransi perubahan intensitas cahaya. Hasil dari kedua metode ini digunakan sebagai input untuk algoritma Random Forest dengan nilai n_estimator 500, 1000, 1500, dan 2000. Hasil penelitian ini memperoleh akurasi tertinggi sebesar 95,92% dengan n_estimator 2000 [7].

Selain ekstraksi fitur tekstur dan warna, penggunaan teknik *deep learning* juga telah menjadi pendekatan yang efektif untuk klasifikasi kualitas buah. Sebuah penelitian mengusulkan penggunaan Convolutional Neural Network (CNN) untuk mengenali jenis dan kualitas buah apel, jeruk, dan pisang dari gambar digital. Dengan menggunakan model VGG16 dan transfer learning, diperoleh akurasi untuk klasifikasi kualitas dan jenis buah secara berturut-turut sebesar 98,17%, dan 95,38% [8]. Penelitian lain bertujuan mengembangkan sistem klasifikasi otomatis menggunakan Convolutional Neural Network (CNN) dengan memanfaatkan dataset gambar buah yang mencakup berbagai kondisi kesegaran. Hasil penelitian menekankan bahwa model CNN yang diadopsi memperoleh akurasi sebesar 96,67% pada proses pengujian, yang mencerminkan model mampu mengidentifikasi buah segar dan busuk secara [9].

Dalam konteks klasifikasi kesegaran buah jeruk, algoritma pembelajaran mendalam (deep learning) seperti ResNet50 dan InceptionV3 menawarkan kemampuan untuk mengenali pola visual secara mendalam, seperti perubahan warna, tekstur, dan cacat fisik. Penelitian ini bertujuan untuk mengeksplorasi performa arsitektur ResNet50 dan InceptionV3 dalam klasifikasi kesegaran buah jeruk menggunakan 3.061 citra untuk analisis dan pengolahan [5]. Fokus penelitian ini adalah membandingkan akurasi dan efisiensi kedua arsitektur tersebut dalam memproses dataset citra jeruk. Dengan demikian, penelitian ini tidak bertujuan untuk mengembangkan sistem klasifikasi lengkap, melainkan untuk memberikan wawasan yang lebih mendalam mengenai efektivitas kedua arsitektur dalam tugas klasifikasi berbasis citra.

2. METODE PENELITIAN

Tahapan dalam mengklasifikasikan jenis buah menggunakan model InceptionV3 adalah sebagai berikut: (1) Pengumpulan data, kumpulan data pada penelitian ini merupakan citra buah jeruk yang sehat dan buah jeruk yang busuk sudah dikumpulkan. (2) Pra-pemprosesan data, yang meliputi resize, split data, dan augmentasi data untuk meningkatkan variasi dataset (3) Membangun model ResNet 50 dan Inception-V3 untuk klasifikasi jenis buah jeruk dan menentukan parameter yang digunakan. (4) Mengevaluasi model menggunakan confusion matrix untuk mendapat nilai akurasi, presisi, recall, dan F1-Score. (5) Menganalisis hasil dan menarik kesimpulan dan dibandingkan dengan penelitian sebelumnya. Gambar 1 menunjukkan detail dari alur penelitian yang telah dilakukan

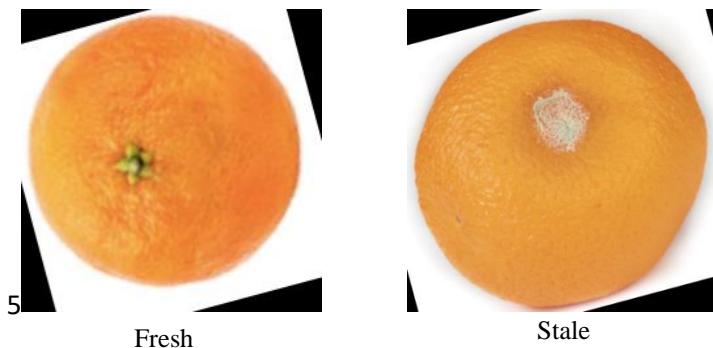


Gambar 1. Alur Penelitian

2.1 Pengumpulan Data

Dataset pada penelitian ini adalah dataset berupa citra digital buah jeruk yang dapat diakses secara publik melalui laman Kaggle. Dataset citra digital buah jeruk ini terbagi menjadi dua kelas yaitu kelas *fresh* dengan dan

stale yang terdiri 1466 citra untuk kelas *fresh* dan 1595 citra untuk kelas *stale*. Gambar 2 merupakan sampel dari dataset yang digunakan.



Gambar 2. Sampel Dataset

2.2 Preprocessing Data

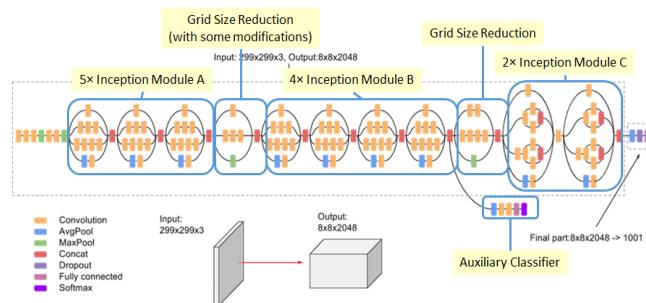
Pada tahap preprocessing dilakukan beberapa proses yaitu mengubah ukuran gambar, membagi data menjadi 3 bagian dengan rasio 80:10:10 dan data augmentation. Proses resize dilakukan pada seluruh dataset agar setiap citra memiliki ukuran yang sama agar tidak terjadi kesalahan akibat ketidakseimbangan ukuran data. Pada tahap ini citra yang sebelumnya berukuran 256x256 piksel akan diubah menjadi 150x150 piksel. Pada proses split data, dataset akan dibagi secara acak menjadi 3 bagian dengan perbandingan 80:10:10 untuk training, testing, dan validasi. Proses augmentasi dilakukan dengan mengadopsi teknik rotation range, rescale, zoom range, vertical flip, dan horizontal flip. Beberapa detail parameter yang digunakan dalam proses augmentasi pada penelitian ini ditunjukkan pada Tabel 1.

Tabel 1. Parameter pada Data Augmentasi

No	Parameter	Value
1	Rotation Range	15
2.	Rescale	1./225
3.	Zoom Range	0.2
4.	Vertical Flip	True
5.	Horizontal Flip	True

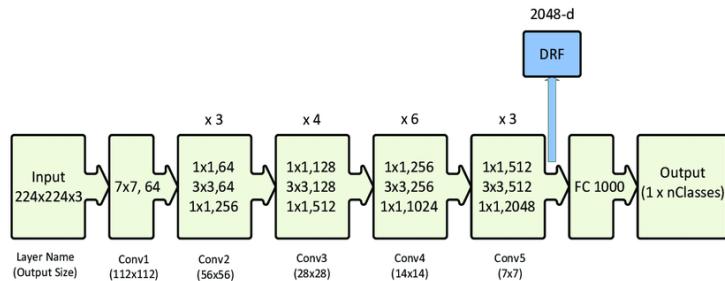
2.3 Model Transfer Learning

Untuk penelitian ini, arsitektur yang diadopsi adalah Inception-V3 dan ResNet50. Model Inception-V3 menggunakan banyak lapisan, termasuk lapisan konvolusi yang digunakan untuk membagi massa menjadi perselisihan kecil; pergeseran ini adalah operasi untuk mengolah berbagai fitur dari masukan yang diberi [10]. Lapisan pooling mempercepat komputasi dan mengurangi overfitting sehingga mengurangi dimensi fungsi folder [11]. Lapisan concat menggabungkan modul sebelumnya dengan yang berikutnya, dan lapisan yang berfungsi penuh menggabungkan semua neuron dari lapisan modul ke lapisan yang berfungsi penuh. Lapisan aktivasi softmax membantu menangani masalah klasifikasi kelas. Arsitektur model Inception-V3 ditunjukkan pada Gambar 3.



Gambar 3. Model Arsitektur Inception-V3

Pada Arsitektur Resnet50, digunakan 5 jenis konvolusi pada tahap pelatihan dengan menormalisasikan gambar menjadi ukuran 224×224 pixel [12]. Aktivasi yang digunakan pada fully-connected layer adalah fungsi flatten dengan mengubah keluaran multidimensional array dari proses training menjadi array satu dimensi untuk kemudian menghasilkan fungsi aktivasi softmax yang digunakan untuk menghitung peluang data hasil training terhadap objek yang terdiri dari beberapa kelas tersebut [13]. Gambar 4 merupakan arsitektur dari model ResNet50



Gambar 4. Model Arsitektur ResNet50

Dalam proses pelatihan, beberapa konfigurasi hyperparameter diatur terlebih dahulu. Hyperparameter yang digunakan pada kedua arsitektur dapat dilihat pada Tabel 2.

Tabel 2. Detail Konfigurasi Hyperparameter

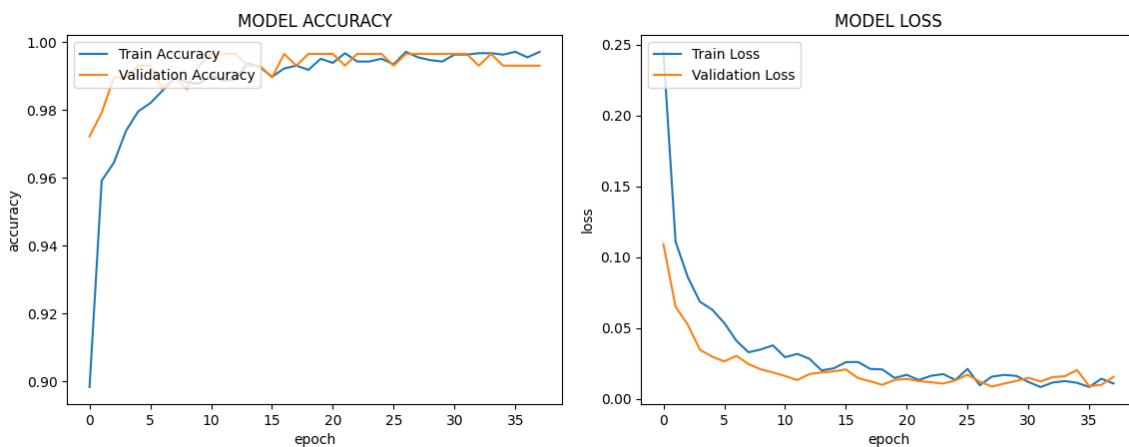
Parameters	Specifications
Learning rate	1e-4
Epochs	100
Batch size	32
Optimizer	Adam

2.4 Evaluasi

Proses terakhir dari sistem penelitian adalah pengujian. Ini menilai keakuratan klasifikasi dengan menilai indeks yang dibuat oleh model CNN yang telah dilatih. Evaluasi akan disajikan dalam confusion matrix. Confusion matrix menunjukkan jumlah gambar dari beberapa kelas dan kelas prediksi, dimana angka pada diagonal utama adalah jumlah prediksi benar berdasarkan model [14].

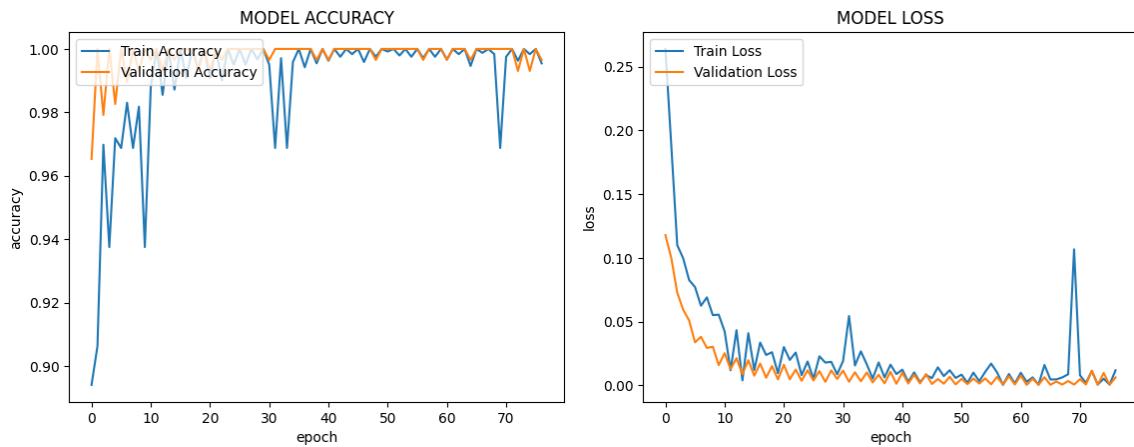
3. HASIL DAN PEMBAHASAN

Proses klasifikasi dilakukan dengan menggunakan 3061 citra buah jeruk yang akan dibagi dengan rasio 80% data training, 10% data testing, dan 10% data validation. Klasifikasi dilakukan dengan menggunakan model Inception-V3 dan Resnet 50 dimana setiap model sama-sama menggunakan proses batch size 32, 100 epochs, optimizer Adam, dan learning rate ie-4. Dapat dilihat pada Gambar 5, grafik hasil akurasi dan loss yang diperoleh melalui tahap iterasi training dengan menggunakan model Inception-V3. Nilai sumbu X menunjukkan jumlah iterasi pelatihan yang telah diproses selama proses pelatihan model, sedangkan sumbu Y menunjukkan tingkat akurasi atau loss dari setiap iterasi. Berdasarkan grafik tersebut, terlihat bahwa Inception V3 berhenti di iterasi 38 karena penggunaan early stop. Hasilnya ditunjukkan bahwa nilai akurasi data training sebesar 100% dan nilai validasi akurasi sebesar 99,35%. Nilai loss didapatkan 0,0024 untuk loss data train, dan 0,0149 untuk loss validasi.



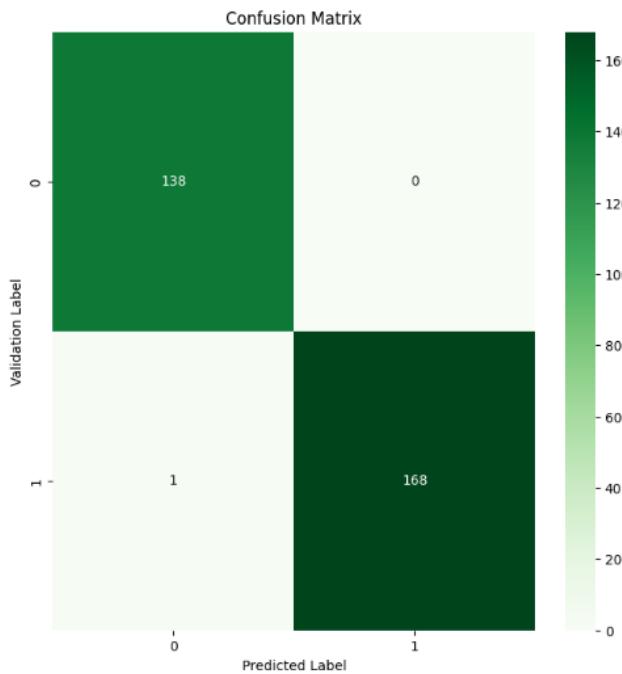
Gambar 5. Grafik Model dengan Inception-V3

Pada Gambar 6, merupakan grafik akurasi dan loss dengan menggunakan model Resnet50. Berdasarkan Gambar 8 terlihat bahwa ResNet50 berhenti di epoch 77. Sama halnya dengan InceptionV3, ResNet50 juga tidak mencapai epoch 100 karena adanya penggunaan early stop. Pada Resnet 50 didapatkan nilai akurasi data train sebesar sebesar 100% dan nilai validasi akurasi sebesar 99,79%. Nilai loss didapatkan 0,0015 untuk loss data train, dan 0,0071 untuk loss validasi.

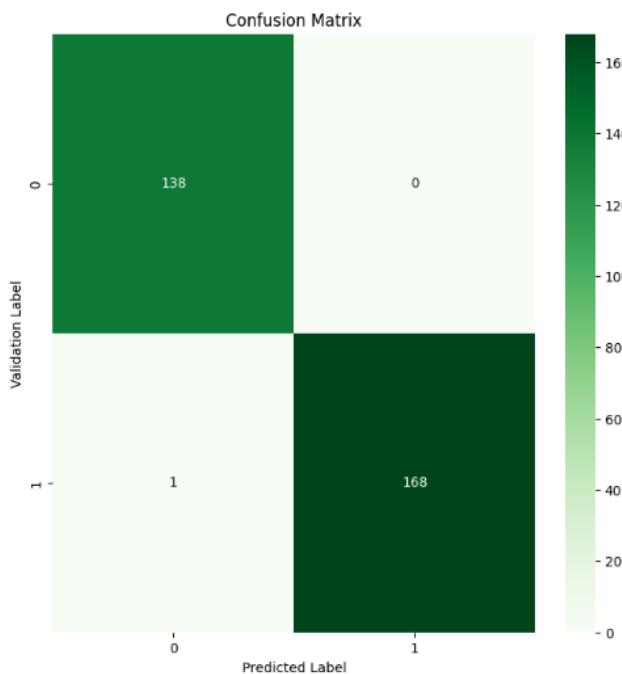


Gambar 6. Grafik Model dengan ResNet50

Dari nilai akurasi pada data training terlihat kedua model memiliki nilai yang sama, tetapi dengan nilai akurasi pada data validasi berbeda. Pada penelitian ini, terlihat ResNet50 memiliki nilai akurasi validasi yang lebih tinggi dan nilai loss yang lebih rendah jika dibandingkan dengan InceptionV3. Setelah mengetahui nilai dari akurasi dan loss dari data training dan data validasi. Dilakukan klasifikasi dengan menggunakan data testing untuk melihat sejauh mana algoritma yang digunakan mampu memberikan akurasi yang tepat. Gambar 7 merupakan hasil dari confusion matrix untuk data testing dengan menggunakan model Inception-V3 sedangkan Gambar 8 merupakan hasil dari confusion matrix untuk data testing dengan menggunakan model Resnet50



Gambar 7. Confusion Matrix Model Inception-V3



Gambar 8. Confusion Matrix Model ResNet50

Berdasarkan hasil confusion matrix pada Gambar 7 dan Gambar 8, terlihat bahwa kedua model menghasilkan confusion matrix yang sama. Dari 138 citra pada kelas *fresh* dan 169 citra pada kelas *stale*, hanya terdapat satu citra yang salah diklasifikasikan yaitu citra pada kelas *stale* yang salah diklasifikasikan sebagai kelas *fresh*. Sehingga, hasil dari classification report untuk kedua model ini juga akan sama. Gambar 9 merupakan clasification report untuk kedua model.

	precision	recall	f1-score	support
0	0.9928	1.0000	0.9964	138
1	1.0000	0.9941	0.9970	169
			accuracy	0.9967
		macro avg	0.9964	0.9970
		weighted avg	0.9968	0.9967
				307

Gambar 9. Clasification Report Inception-V3 dan ResNet50

Berdasarkan Gambar 9, terlihat bahwa kedua model memperoleh akurasi sebesar 99,67%, presisi 99,64%, recall 99,70%, dan F1-Score sebesar 99,67%. Namun, walaupun memiliki nilai akurasi, presisi, recall, dan F1-Score yang sama, kedua model ini memiliki nilai loss pada data testing dan waktu komputasi yang berbeda. Inception-V3 memiliki nilai loss sebesar 0,0148, sedangkan ResNet50 memiliki nilai loss yang lebih rendah yaitu 0,0074. Nilai loss ini juga berbanding lurus dengan waktu komputasi tiap model. InceptionV3 memerlukan 26.29 detik untuk satu kali iterasi, sedangkan ResNet hanya memerlukan 0.92 detik untuk tiap iterasi. Namun, jika dilihat dari penggunaan total memori, ResNet50 memerlukan 52,4% ruang pada memori, sedangkan Inception-V3 hanya memerlukan 5,2% ruang pada memori. Detail perbedaan untuk akurasi, loss, waktu komputasi dan persentase memori dari Inception-V3 dan ResNet50 dapat dilihat pada Tabel 3.

Tabel 3. Detail Perbedaan Akurasi, Loss, Komputasi, dan Memori

Model	Akurasi	Loss	Waktu Komputasi	Persentase Memori
Inception-V3	99,67%	0,0148	26.29 s	52,4%
ResNet50	99,67%	0,0074	0.92 s	5,2%

4. SIMPULAN

Dalam penelitian ini, kinerja Inception-V3 dan ResNet50 telah diuji untuk klasifikasi kesegaran buah jeruk menggunakan citra digital. Dataset pada penelitian ini terdiri dari 3061 citra buah jeruk yang dibagi menjadi dua kelas dengan rincian 1466 citra untuk kelas *fresh* dan 1595 citra untuk kelas *stale*. Setelah melakukan pengujian terhadap kedua model arsitektur yang diusulkan, hasil yang diperoleh menunjukkan bahwa kedua model menghasilkan akurasi yang sama yaitu 99,67%. Namun, nilai loss kedua model memiliki hasil yang berbeda walaupun akurasi yang dihasilkan sama. Nilai loss dan time consumption pada InceptionV3 adalah 1,49% sedangkan pada ResNet50 diperoleh 0,7%. Hasil yang diperoleh menunjukkan bahwa kedua model ini memiliki kemampuan dalam mengidentifikasi kesegaran buah jeruk dengan benar dan efektif karena menghasilkan akurasi yang tinggi dan nilai loss yang cukup rendah. Nilai loss yang dihasilkan berbanding lurus dengan waktu komputasi tiap model. InceptionV3 memerlukan 26.29 detik untuk satu kali iterasi, sedangkan ResNet hanya memerlukan 0.92 detik untuk tiap iterasi. Namun, jika dilihat dari penggunaan total memori, ResNet50 memerlukan 52,4% ruang pada memori, sedangkan Inception-V3 hanya memerlukan 5,2% ruang pada memori. Sehingga, jika ingin diimplementasikan menjadi sebuah sistem, keduanya model layak untuk dijadikan pertimbangan. Jika memori yang digunakan terbatas, bisa memilih Inception-V3, namun jika ingin menggunakan model dengan waktu komputasi yang lebih cepat dan nilai loss yang lebih kecil, maka bisa memilih ResNet50.

5. SARAN

Untuk penelitian selanjutnya, dapat disarankan untuk menggunakan model arsitektur yang berbeda atau menggabungkan dua arsitektur atau lebih untuk mengurangi nilai loss, waktu komputasi, dan persentase memori yang digunakan. Selain itu juga dapat menambahkan jenis buah yang lain yang memiliki ciri fisik yang mirip dengan buah jeruk pada dataset untuk mengukur lebih jauh model arsitektur yang digunakan pada penelitian ini..

DAFTAR PUSTAKA

- [1] F. R. Moeis, T. Dartanto, J. P. Moeis, and M. Ikhsan, “A longitudinal study of agriculture households in Indonesia: The effect of land and labor mobility on welfare and poverty dynamics,” *World Dev. Perspect.*, vol. 20, p. 100261, Dec. 2020, doi: 10.1016/j.wdp.2020.100261.
- [2] F. N. Cahya, R. Pebrianto, and T. A. M, “Klasifikasi Buah Segar dan Busuk Menggunakan Ekstraksi Fitur Hu-Moment, Haralick dan Histogram,” *IJCIT (Indonesian J. Comput. Inf. Technol.*, vol. 6, no. 1, May 2021, doi: 10.31294/ijcit.v6i1.10052.

- [3] G. Firmansyah and A. Hermawan, "Implementasi Algortima Naive Bayes Untuk Klasifikasi Kesegaran Buah Jeruk," *J. Inform.*, vol. 10, no. 2, pp. 180–184, Oct. 2023, doi: 10.31294/inf.v10i2.16115.
- [4] G. Firmansyah and A. Hermawan, "Implementasi Algortima Naive Bayes Untuk Klasifikasi Kesegaran Buah Jeruk," *J. Inform.*, vol. 10, no. 2, pp. 180–184, 2023, doi: 10.31294/inf.v10i2.16115.
- [5] A. K. Ulandari, G. K. Ramdhani, W. Wahyuningsih, M. N. Arwansyuri, and F. Bimantoro, "Klasifikasi Jeruk Segar dan Busuk Melalui GLCM dan HSV dengan Menggunakan Metode ANN," *Semin. Nas. Teknol. Sains*, vol. 3, no. 1, pp. 97–102, 2024, doi: 10.29407/stains.v3i1.4358.
- [6] S. Napitu, R. Paramita Panjaitan, P. A. Nulhakim, and M. Khalik Lubis, "Klasifikasi Buah Jeruk Segar dan Busuk Berdasarkan RGB dan HSV Menggunakan Metode KNN," *J. SAINTEKOM*, vol. 13, no. 2, pp. 214–221, 2023, doi: 10.33020/saintekom.v13i2.420.
- [7] F. Santoso and E. Hartati, "Penggunaan Algoritma Random Forest Dalam Klasifikasi Buah Segar Dan Busuk," *J. Algoritm.*, vol. 3, no. 1, pp. 133–140, 2022, doi: 10.35957/algoritme.v3i1.3404.
- [8] S. Darmawan Putra Bahari and U. Latifa, "Klasifikasi Buah Segar Menggunakan Teknik Computer Vision Untuk Pendekripsi Kualitas Dan Kesegaran Buah," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 3, pp. 1567–1573, 2023, doi: 10.36040/jati.v7i3.6871.
- [9] Prinzky and C. Lubis, "Klasifikasi Buah Segar Dan Busuk Menggunakan Convolutional Neural Network Berbasis Android," *J. Ilmu Komput. dan Sist. Inf.*, vol. 10, no. 2, pp. 10823–10827, 2022, doi: 10.24912/jiksi.v10i2.22551.
- [10] N. Dong, L. Zhao, C. H. Wu, and J. F. Chang, "Inception-V3 based cervical cell classification combined with artificially extracted features," *Appl. Soft Comput.*, vol. 93, p. 106311, Aug. 2020, doi: 10.1016/j.asoc.2020.106311.
- [11] M. Nour, Z. Cömert, and K. Polat, "A Novel Medical Diagnosis model for COVID-19 infection detection based on Deep Features and Bayesian Optimization," *Appl. Soft Comput.*, vol. 97, no. xxxx, p. 106580, 2020, doi: 10.1016/j.asoc.2020.106580.
- [12] N. D. Miranda, L. Novamizanti, and S. Rizal, "CONVOLUTIONAL NEURAL NETWORK PADA KLASIFIKASI SIDIK JARI MENGGUNAKAN RESNET50," *J. Tek. Inform.*, vol. 1, no. 2, pp. 61–68, Dec. 2020, doi: 10.20884/1.jutif.2020.1.2.18.
- [13] X. Ou *et al.*, "Moving Object Detection Method via ResNet-18 With Encoder–Decoder Structure in Complex Scenes," *IEEE Access*, vol. 7, pp. 108152–108160, 2019, doi: 10.1109/ACCESS.2019.2931922.
- [14] S. Y. Chaganti, I. Nanda, K. R. Pandi, T. Gnrssn Prudhvith, and N. Kumar, "Image Classification using SVM and CNN," in *2020 International Conference on Computer Science, Engineering and Applications*, 2020, pp. 1–5. doi: 10.1109/ICCSEA49143.2020.9132851.