Implementasi ESPCN untuk Meningkatkan Kualitas Foto dan Akurasi Model Klasifikasi Menggunakan CNN

Andre Daegal^{#1}, Rianto^{#2}

1.2 Program Studi Sains Data, Fakultas Sains dan Teknologi, Universitas Teknologi Yogyakarta Jl. Siliwangi (Ringroad Utara), Jombor, Sleman, D. I. Yogyakarta 55285

1 andre.5211811004@student.uty.ac.id

²rianto@staff.uty.ac.id

Abstract— In conducting research, there are often obstacles to supporting media to support the observations and experiments under study. Especially in the case of research involving photos, not a few quality problems that use cameras show results that are not ideal, such as dimness, disturbing-colored dots, or other disturbances. In line with the rapid development of technology today, these problems can be overcome by computer programming through the Opensource Computer Vision Library (OpenCV). OpenCV is a programming module that contains various features, one of which is improving image quality with super-resolution. In practice, photos that have low quality will be enhanced using the efficient subpixel convolutional neural network (ESPCN) model. The deep learning algorithm used is a convolutional neural network (CNN) to support the testing means. CNN works to obtain the percentage accuracy of the photos under study as a representation of the final test results. This test aims to improve the low quality of photos with the ESPCN model to compare the accuracy with the original photos. The test result is the application of ESPCN to low-quality photos. The test result is higher accuracy than the original photo with a difference of 1.2%. The original photo had an accuracy of 90.6%, while the enhanced photo had an accuracy of 91.8%. The final result shows that low-quality photos can be upscaled using ESPCN to produce better accuracy.

Keywords— accuracy, CNN, image quality, ESPCN, super-resolution

Abstrak— Dalam pelaksanaan penelitian sering kali dijumpai hambatan media pendukung untuk menunjang berlangsungnya observasi dan eksperimen yang diteliti. Terutama pada kasus penelitian yang melibatkan foto, tidak sedikit permasalahan kualitas yang menggunakan kamera menunjukkan hasil yang tidak ideal, seperti timbul remang-remang, titik-titik berwarna yang mengganggu, maupun gangguan lainnya. Sejalan dengan perkembangan teknologi yang saat ini melaju pesat, persoalan tersebut mampu diatasi dengan pemrograman komputer melalui Opensource Computer Vision Library (OpenCV). OpenCV ini merupakan modul pemrograman yang di dalamnya terkandung berbagai fitur. salah satunya meningkatkan kualitas gambar dengan super resolution. Dalam praktiknya, foto yang memiliki kualitas rendah akan ditingkatkan kualitas gambarnya menggunakan model efficient subpixel convolutional neural network (ESPCN). Untuk mendukung sarana pengujian, algoritme deep learning yang digunakan yaitu convolutional neural network (CNN). CNN bekerja untuk mendapatkan persentase akurasi foto yang diteliti sebagai representasi hasil akhir pengujian. Pengujian ini bertujuan untuk meningkatkan kualitas foto yang rendah dengan model ESPCN untuk dibandingkan akurasinya dengan foto orisinal. Hasil pengujiannya yaitu penerapan ESPCN terhadap foto kualitas rendah. Hasil pengujian akurasinya lebih tinggi daripada foto orisinal dengan selisih 1,2%. Foto orisinal memiliki akurasi 90,6%, sedangkan foto yang ditingkatkan kualitasnya memiliki akurasi 91,8%. Hasil akhir tersebut menunjukkan bahwa foto dengan kualitas rendah dapat ditingkatkan kualitasnya menggunakan ESPCN hingga dapat menghasilkan akurasi yang lebih baik.

e-ISSN: 2579-3772

Kata Kunci— akurasi, CNN, kualitas foto, ESPCN, super resolution

I. PENDAHULUAN

Variasi teknologi kamera semakin berkembang mengimbangi kebutuhan sehari-hari oleh berbagai keperluan. Sejalan dengan perkembangan tersebut, tidak sedikit pengguna menuntut hasil foto dengan kualitas tinggi meski spesifikasi kamera tidak mumpuni. Permasalahan biaya dan alokasi waktu untuk pengambilan foto menjadi hambatan dalam memperoleh hasil akhir foto yang kualitasnya baik. Terlebih hal tersebut dialami saat proses penelitian dengan segala keterbatasan yang ada.

Saat ini persoalan tersebut mampu ditangani dengan bantuan pemrograman komputer yang disebut *super resolution*. Super resolution bertujuan untuk mengonversi gambar beresolusi rendah dengan detail kasar menjadi gambar beresolusi tinggi dengan kualitas visual lebih baik dan detail yang halus. Gambar super-resolution juga disebut dengan nama lain seperti *image scaling*, *interpolation*, *upsampling*, zooming, dan enlargement. Proses menghasilkan gambar dengan resolusi yang lebih tinggi dapat dilakukan dengan menggunakan satu gambar atau beberapa gambar [1].

Dalam metode *super-resolution*, terdapat berbagai macam model untuk implementasi peningkatan kualitas foto. Satu diantaranya adalah *Efficient Subpixel Convolutional Neural Network* (ESPCN). Model ESPCN yang digunakan akan melakukan pemrosesan pada foto beresolusi rendah untuk kemudian resolusinya ditingkatkan sebanyak empat kali lipat [2].

Dalam penelitian berjudul "Edge–SR: Super–Resolution For The Masses" yang dilakukan Michelini dkk. [3] menyatakan bahwa proses meningkatkan kualitas gambar menggunakan model ESPCN ini dianggap paling cepat dan peningkatan kualitas gambarnya signifikan dibanding model lain, seperti FSRCNN (Fast Super-Resolution Convolutional Neural Network). FSRCNN sebagai model pendahulunya memiliki mekanisme kerja yang memakan waktu karena berfokus pada mempertahankan detail dan tekstur pada gambar. Berbeda dengan ESPCN yang memprioritaskan efisiensi komputasi hingga peningkatan kualitas foto dapat dicapai maksimal.

Zhang dkk. [4] mengungkapkan bahwa metode superresolution dianggap menjanjikan. Metode ini memulihkan foto dari resolusi rendah menjadi foto beresolusi tinggi melalui CNN. CNN (Convolutional Neural Network) merupakan salah satu algoritme dari deep learning yang digunakan dalam metode image processing. Menurut Ravikumar dkk. [5] dalam penelitian berjudul "Digital Image Processing-A Quick Review" mengungkapkan bahwa terdapat sejumlah aplikasi, alat, dan teknik pemrosesan gambar yang dapat membantu mengekstraksi fitur kompleks dari suatu gambar, salah satunya adalah image processing. Image processing merupakan pemrosesan gambar digital melalui berbagai algoritma. Image processing bekerja pada gambar satu dimensi menjadi multidimensi dengan melihat karakteristik yang sebenarnya ada di dalam gambar tersebut.

Deep learning adalah pengembangan dari teknologi machine learning yang penggunaan algoritmenya dibuat berdasarkan pada hukum matematika dan bekerja layaknya seperti otak manusia. Penggunaan deep learning dalam image processing, atau pengolahan citra digital, dimanfaatkan untuk membantu manusia dalam mengenali dan/atau mengklasifikasi objek dengan cepat dan tepat, serta dapat melakukan proses dengan banyak data secara bersamaan [6].

Machine learning adalah salah satu cabang dari artificial intelligence (AI) yang mengadopsi prinsip dari ilmu komputer dan statistik untuk membuat model yang merefleksikan polapola data [7]. Model tersebut dilatih dengan menggunakan berbagai algoritme dalam pendekatan machine learning sehingga bisa melakukan klasifikasi terhadap dataset foto yang digunakan dalam pengujian. Jadi, secara sederhana dapat dijelaskan bahwa machine learning adalah pemograman komputer untuk mencapai kriteria/performa tertentu dengan menggunakan sekumpulan data training atau pengalaman di masa lalu (past experience) [8].

Sebagai komparasi dengan metode lain, yaitu SVM, dalam penelitian oleh Kurniadi dkk. [9] tentang perbandingan algoritme SVM dan CNN untuk klasifikasi buah, CNN menghasilkan akurasi yang baik dengan nilai 96,87% dibandingkan SVM dengan akurasi 93,09%.

Penelitian ini menggunakan ESPCN sebagai model untuk meningkatkan kualitas foto dan menggunakan CNN sebagai algoritme untuk menguji akurasi foto. ESPCN diterapkan ke dalam foto beresolusi rendah untuk kemudian diuji akurasinya. Hasil foto yang memiliki resolusi rendah dibandingkan

dengan foto yang telah ditingkatkan kualitasnya menggunakan ESPCN.

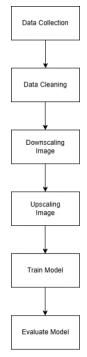
II. METODOLOGI

Pemrosesan dalam penelitian ini dilakukan terhadap *dataset* yang berisi macam-macam foto yang telah diberi perlakuan tertentu dan diuji oleh algoritme *convolutional neural network* (CNN) untuk mendapatkan persentase akurasi yang merepresentasikan hasil akhir pengujian. Data yang digunakan untuk pengujian berasal dari data primer. Data primer adalah data yang diperoleh peneliti secara langsung dari hasil observasi [10].

Secara singkat langkah pengujian esensial yang dilakukan yaitu setelah *dataset* foto diperoleh, foto akan diturunkan kualitasnya lalu ditingkatkan kembali menggunakan ESPCN dan dilakukan pengujian dengan CNN untuk diperoleh akurasinya sebagai pembanding di konklusi akhir. Langkahlangkah lebih lanjut dalam penelitian ini ditunjukkan dalam Gambar 1.

A. Data Collection

Pengumpulan *dataset* foto atau *data collection* untuk pengujian didapat dari tangkapan gambar oleh kamera Sony Xperia XZ2 Premium. Tangkapan gambar ini menghasilkan foto dengan resolusi 3472 x 3472-pixel dan format *file* JPEG. Jenis objek foto yaitu rempah-rempah yang meliputi jahe, kencur, kunyit, lengkuas dengan objek yang berbeda-beda dan masing-masing terdiri atas 500 foto. Total 2000 foto tersebut diklasifikasikan menjadi empat kelas sesuai dengan jenis rempah-rempahnya. Contoh hasil tangkapan foto tersebut ditunjukkan pada Gambar 2.



Gambar 1 Alur penelitian









Gambar 2 Hasil foto (dari kiri: jahe, kencur, kunyit, lengkuas)

Resolusi gambar adalah banyaknya detail gambar yang tersimpan. Makin tinggi resolusi dari suatu gambar berarti lebih banyak detail gambar yang dimiliki [11]. JPEG merupakan format gambar digital yang sangat dominan di internet karena kemampuan kompresi yang tinggi tanpa mengorbankan kualitas gambar secara signifikan [12]. Resolusi foto yang dihasilkan tergolong tinggi dan pemilihan format *file* JPEG dianggap mumpuni.

B. Data Cleaning

Pembersihan data atau *data cleaning* bertujuan untuk menyaring foto yang nantinya digunakan dalam pengujian. Proses pengambilan foto melalui kamera dilakukan dengan cara pendekatan, yaitu tiap objek diletakkan pada tempat yang sama dan kamera berada di posisi yang tetap sebagai standarisasi untuk menjaga seluruh foto konsisten.

Setiap foto melalui tahap pemilihan terlebih dahulu, khususnya foto yang memiliki efek remang-remang (*blur*), fokus foto tidak sesuai, maupun gangguan lainnya. Foto-foto tersebut dihapus dan diganti dengan pengambilan foto ulang (*retake*). Langkah ini merupakan normalisasi data yang dilakukan dalam penelitian ini agar *dataset* saat pengujian benar-benar merupakan foto yang terseleksi dengan baik sehingga akurasi yang diperoleh bisa maksimal.

C. Downscaling Image

Penurunan kualitas foto atau disebut *image downscaling* merupakan proses transformasi foto dari resolusi tinggi ke resolusi rendah [13]. Langkah ini bertujuan untuk menurunkan kualitas hasil tangkapan foto orisinal untuk nantinya dilihat perbedaan akurasi dengan dataset foto yang ditingkatkan kualitasnya. Perbandingan pada Gambar 3 memvisualisasikan hasil dari penurunan kualitas dalam proses pengolahan foto.

Langkah ini menggunakan PIL (Python Imaging Library). Menurut Kuhikar dkk. [14] dalam penelitian berjudul "Well Detection Using Image Processing" mengungkapkan bahwa proses dari PIL library dimulai dengan mengambil foto lalu dimanipulasi melalui pemrograman khusus dan disimpan dalam format yang dikehendaki. Dalam library tersebut mencakup fitur-fitur manipulasi gambar per *pixel*, peningkatan kualitas gambar, seperti mempertajam gambar dan warna, mengatur transparansi gambar, memperhalus pixel gambar dengan menghilangkan efek kabur (blur), dan sebagainya. Gambar yang diproses dengan PIL disimpan dalam array dan diproses dengan komputasi tertentu lewat metode rewriting of pixel values.





Gambar 3 Perbandingan hasil downscaling (dari kiri: foto jahe orisinal, foto jahe downscaled)

Implementasi *library* pada penelitian ini dilakukan dengan menurunkan resolusi pada foto orisinal sebesar 1/16 sehingga menghasilkan foto baru dengan *pixel* rendah berukuran 217 x 217. Dalam penelitian yang dilakukan Hou dkk. [13] besaran penurunan kualitas foto adalah 1/4, namun dalam praktik di sini, karena foto beresolusi tinggi, maka diturunkan dengan skala 1/4 ternyata tidak menimbulkan perbedaan *pixel* secara signifikan. Skala tersebut akhirnya ditingkatkan sebanyak empat kali lipat hingga diperoleh komposisi penurunan kualitas foto yang pas sebesar 1/16. Proses ini diterapkan pada keempat kelas foto dengan skala perbandingan penurunan kualitas gambar yang sama.

D. Upscaling Image

Setelah proses menurunkan kualitas foto dengan PIL (Python Imaging Library), foto yang telah diturunkan kualitasnya dilakukan pemrosesan untuk ditingkatkan kembali kualitasnya menggunakan model efficient subpixel convolutional neural network (ESPCN) melalui tahap importing library dari cv2 dan dnn superres pada superresolution yang ada di OpenCV. OpenCV (Opensource Computer Vision Library) merupakan salah satu modul pemrograman perangkat lunak yang sifatnya dapat digunakan dan dimodifikasi oleh pengguna. Di dalamnya terkandung berbagai macam function dan algoritme untuk penangkapan gerak (motion tracking), pengenalan wajah (face recognition), pendeteksian benda (object detection), serta pengaplikasian lainnya. Foto dan video pun dapat secara langsung (real time) dimanipulasi untuk berbagai kebutuhan menggunakan *library* ini [15]. Salah satu di antara penerapan tersebut yaitu superresolution yang bekerja dengan meningkatkan jumlah pixel gambar. Gambar dengan resolusi yang rendah diubah menjadi gambar dengan resolusi tinggi [16]. Hasil proses peningkatan kualitas foto tersebut ditunjukkan pada perbandingan foto yang ada pada Gambar 4.

Komparasi pada Gambar 4 nampak bahwa foto dengan kualitas rendah setelah ditingkatkan menggunakan ESPCN, diperbesar tampilannya akan terlihat lebih mulus, tidak kasar, tidak remang-remang, dan tidak kaku pada *pixel* di setiap sisinya. Garber dkk. [17] mengungkapkan bahwa ESPCN le-





Gambar 4 Perbandingan hasil *upscaling* (dari kiri: foto jahe *downscaled*, foto jahe *upscaled*)

bih efisien karena bekerja dalam dimensi *layer* paling terkecil sehingga model ini memiliki kualitas yang unggul terutama mampu meningkatkan akurasi pengujian.

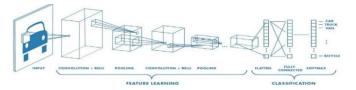
E. Train Model

Algoritma yang digunakan dalam pengujian ini adalah convolutional neural network (CNN). Pertimbangannya karena metode deep learning yang saat ini memiliki hasil paling signifikan dalam pengenalan citra adalah convolutional neural network (CNN). Hal tersebut dikarenakan CNN berusaha meniru sistem pengenalan citra pada visual cortex manusia sehingga memiliki kemampuan mengolah informasi citra [18].

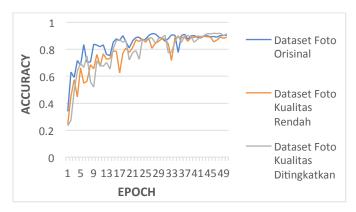
Secara teknis CNN (convolutional neural network) melatih dan menguji setiap gambar masukan melalui serangkaian proses, yaitu convolutional layer. Proses ini lalu diikuti oleh pooling untuk mengekstraksi fitur dari gambar masukan berturut-turut. Setelah operasi pooling, citra di-flatten dan kemudian dimasukkan ke dalam proses fully connected-layer untuk melaksanakan tugas pengklasifikasian. Arsitektur yang menggambarkan proses-proses yang terjadi pada metode CNN ditampilkan pada Gambar 5.

Tahap selanjutnya ketiga *dataset*, yaitu foto orisinal, foto yang telah diturunkan kualitasnya, dan foto yang ditingkatkan kualitasnya, akan menjalankan proses *training model*. *Training model* bertujuan untuk melatih komputer agar mencapai sebuah keputusan atau prediksi dengan cara mengolah citra sehingga terbentuk pola atau karakteristik [19].

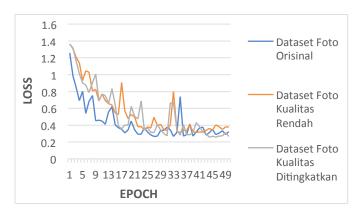
Pengujian ini menggunakan Google Colaboratory untuk pemrosesan Python *code* sebagai *machine learning tool* dan Google Drive sebagai media penyimpanan *dataset*. Untuk menguji tingkat akurasi digunakan *hyperparameter* di antaranya *batch_size 32, validation_split 0.25, optimizer SGD,* dan *epoch* 50. Ketika pemrosesan yang berlangsung menyentuh urutan 50, maka pengujian akan berhenti. Pemilihan ukuran *epoch* di sini berdasarkan eksperimen yang dilakukan. Jika lebih dari 50, tidak menunjukkan perubahan akurasi pada grafik. Hal ini juga tampak pada Gambar 6 dan Gambar 7. Ketika proses pengujian hendak selesai, grafik menunjukkan kecenderungan linier. Parameter lain, yaitu kombinasi *data split* 75:25, didapat 1500 *data training* dan 500 *data testing*, serta menggunakan SGD *optimizer*.



Gambar 5 Arsitektur CNN [19]



Gambar 6 Grafik rekapitulasi accuracy hasil pengujian dataset



Gambar 7 Grafik rekapitulasi loss hasil pengujian dataset

SGD optimizer digunakan karena keunggulannya terhadap akurasi pengujian pada dataset yang jumlahnya besar dan variatif. Dalam penelitian Efendi dkk. [20] yang berjudul "Penerapan Algoritma Convolutional Neural Network Arsitektur ResNet-50 untuk Klasifikasi Citra Daging Sapi dan Babi", SGD optimizer mendapat akurasi tertinggi sebesar 97,83% dibandingkan dengan ADAM dan RMSprop. Selain itu, dalam penelitian yang dilakukan Zhou dkk. [21] yang berjudul "Towards Theoretically Understanding Why SGD Generalizes Better Than ADAM in Deep Learning" menyatakan bahwa SGD memiliki performa yang baik dalam melakukan generalisasi data dibanding ADAM. Inilah alasan SGD optimizer dipilih berdasarkan pertimbangan studi literatur tersebut.

F. Evaluate Model

Setelah pengujian selesai, pada bagian akhir akan didapat konklusi melalui rekapitulasi akurasi yang telah diuji menggu-

nakan CNN. Evaluasi model adalah langkah untuk mengetahui hasil pengujian terhadap *dataset* yang merepresentasikan data. Dalam pelaksanaannya, akurasi yang telah diperoleh dari hasil pengujian *dataset*, yaitu foto orisinal, foto kualitas yang diturunkan, dan foto kualitas ditingkatkan, akan dibandingkan perolehan akurasinya disertai penjelasan sesuai skenario uji selama proses berlangsung pada masing-masing *dataset*.

III. HASIL DAN PEMBAHASAN

Setelah menghimpun *dataset* dan setiap kelas melewati serangkaian proses *downscaling* dan *upscaling*, selanjutnya menguji ketiga *dataset*, yaitu foto orisinal, foto kualitas yang diturunkan atau kualitas rendah, dan foto kualitas yang ditingkatkan. Pengujian dilakukan dengan pendekatan *deep learning* berbasis *convolutional neural network (CNN)* untuk memperoleh akurasi foto. Hasil komputasi tersebut dirangkum dalam Tabel I.

Pada Tabel I terlihat bahwa ketiga *dataset* memiliki hasil akurasi pengujian yang berbeda dengan selisih yang tidak terlalu jauh. Namun, jika dibandingkan, terdapat perbedaan kontras yang signifikan antara foto kualitas yang ditingkatkan dengan foto orisinal, yaitu sebesar 0,9180 atau 91,8% dan 0,9060 atau 90,6%. Hal ini menunjukkan bahwa dalam praktiknya, model ESPCN mampu melakukan peningkatan kualitas foto hingga menghasilkan akurasi selisih 0,012 lebih tinggi dibanding foto orisinal.

Hasil pengujian masing-masing *dataset* yang terdiri dari *accuracy* dan *loss* digambarkan berupa grafik. Grafik ini merupakan kesimpulan dari serangkaian proses pengujian. Setiap tahapan pengujian akan mendapat nilai *accuracy* beserta *loss*. Ketika proses berakhir, nilai tersebut dimanifestasikan dalam bentuk grafik.

Grafik pada Gambar 6 memperlihatkan bahwa secara garis besar ketiga dataset mengalami kenaikan akurasi meski sifatnya fluktuatif. Khususnya pada epoch 11 nampak mengalami penurunan akurasi pada seluruh *dataset*, kemudian mengalami eskalasi kembali, puncaknya pada epoch 21. Fluktuasi ini berlanjut hingga epoch 41 lalu berada dalam ambang stabil (tidak menunjukkan kenaikan maupun penurunan drastis) pada epoch selanjutnya hingga proses pengujian selesai. Pengujian ini membuktikan bahwa SGD optimizer mampu menjalankan tugasnya dengan menggeneralisasi dataset dengan baik, terutama pada dataset dengan jumlah yang banyak dan variative.

Grafik *loss* pada Gambar 7 menunjukkan bahwa hasil pengujian untuk nilai *loss* terhadap ketiga *dataset* pada proses *training* relatif mengalami penurunan. Pada *epoch* 16 sampai 36 terlihat nilai *loss* mengindikasikan ketidakstabilan, namun pada *epoch* selanjutnya nilai *loss* kembali turun hingga proses pengujian selesai. Menariknya, *dataset* foto kualitas yang ditingkatkan menghasilkan nilai *loss* lebih rendah dibandingkan *dataset* foto orisinal. Perbandingan tersebut mengartikan bahwa penerapan ESPCN menghasilkan efektivitas terhadap nilai *loss* yang kecil.

TABEL I RANGKUMAN HASIL PENGUJIAN

No.	Dataset	Rata-Rata Hasil Pengujian	
		Accuracy	Loss
1	Foto Orisinal	0,9060	0,3238
2	Foto Kualitas Yang Diturunkan	0,8900	0,3752
3	Foto Kualitas Yang Ditingkatkan	0,9180	0,2662

IV. SIMPULAN

Penerapan EPSCN terhadap foto kualitas rendah menghasilkan akurasi pengujian lebih tinggi dibandingkan foto orisinal, dengan selisih 0,012 atau 1,2%. Persentase akurasi foto orisinal adalah sebesar 90,6%, sedangkan akurasi foto yang ditingkatkan dengan ESPCN adalah sebesar 91,8%. Pengujian ini menunjukkan bahwa foto kualitas rendah dapat ditingkatkan kualitasnya menggunakan ESPCN hingga menghasilkan akurasi yang baik. Konteks kualitas disini memiliki arti resolusi foto beserta *pixel* yang ada di dalamnya. Dengan akurasi yang diperoleh melalui pengujian CNN, semakin tinggi akurasi maka merepresentasikan kualitas foto yang baik.

DAFTAR REFERENSI

- [1] S. Anwar, S. Khan, dan N. Barnes, "A deep journey into super-resolution: a survey," ACM Comput. Surv., vol. 53, no. 3, hlm. 1–21, 2020, doi: 10.1145/3390462.
- [2] Z. Chu, dkk., "A generalizable smple resolution augmentation method for mechanical fault diagnosis based on ESPCN," J. Sensors, vol. 2021, 2021, doi: 10.1155/2021/7496007.
- [3] P. N. Michelini, Y. Lu, dan X. Jiang, "Edge-SR: super-resolution for the masses," Pros. - 2022 IEEE/CVF Winter Conf. Appl. Comput. Vision, WACV 2022, hlm. 4019–4028, 2022, doi: 10.1109/WACV51458.2022.00407.
- [4] S. Zhang, G. Liang, S. Pan, dan L. Zheng, "A fast medical image super resolution method based on deep learning network," IEEE Access, vol. 7, hlm. 12319–12327, 2019, doi: 10.1109/ACCESS.2018.2871626.
- [5] R. Ravikumar dan V. Arulmozhi, "Digital image processing-a quick review," Int. J. Intell. Comput. Technol., vol. 2, no. 2, hlm. 16–24, 2019.
- [6] F. F. Maulana dan N. Rochmawati, "Klasifikasi citra buah menggunakan convolutional neural network," *J. Informatics Comput. Sci.*, vol. 1, no. 02, hlm. 104–108, 2020, doi: 10.26740/jinacs.v1n02.p104-108.
- [7] C. Chazar dan B. Erawan, "Machine learning diagnosis kanker payudara menggunakan algoritme support vector machine," Inf. (Jurnal Inform. dan Sist. Informasi), vol. 12, no. 1, hlm. 67–80, 2020, doi: 10.37424/informasi.v12i1.48.
- [8] N. Giarsyani, A. F. Hidayatullah, dan R. Rahmadi, "Komparasi algoritme machine learning dan deep learning untuk named entity recognition (studi kasus: data kebencanaan)," J. Inform. Rekayasa Elektron., vol. 3, no. 1, hlm. 48–57, 2020, doi: 10.20961/ijai.v4i2.41317.
- [9] B. W. Kurniadi, H. Prasetyo, G. L. Ahmad, B. Aditya Wibisono, dan D. Sandya Prasvita, "Analisis perbandingan algoritme SVM dan CNN untuk klasifikasi buah," dalam Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya (Senamika), 2021, vol. 2, no. 2, hlm. 1–11.
- [10] S. Sinaga, "Pengaruh motivasi dan pengalaman kerja terhadap produktivitas kerja karyawan pada PT Trikarya Cemerlang Medan," *J. Ilm. Metadata*, vol. 2, no. 2, hlm. 159–169, 2020, doi: 10.47652/metadata.v2i2.28.

- [11] Y. Fitrianto, Dasar-Dasar Digital Imaging. Semarang: Yayasan Prima Agus Teknik, 2021.
- [12] A. Stanley, "Penerapan kode Huffman dalam proses kompresi dan dekompresi format gambar JPEG", Makalah IF2120 Matematika Diskrit-Sem. 1 Tahun 2018, 2018.
- [13] X. Hou, dkk., "Learning based image transformation using convolutional neural networks," IEEE Access, vol. 6, hlm. 49779– 49792, 2018, doi: 10.1109/ACCESS.2018.2868733.
- [14] T. R. Ravi, K. Kuhikar, Y. Kalambe, A. Wagh, dan U. Deshkar, "Well detection using image processing," J. Res. Eng. Appl. Sci., vol. 5, no. 4, hlm. 142–145, 2020, doi: 10.46565/jreas.2020.v05i04.004.
- [15] H. Adusumalli, D. Kalyani, dan R. K. Sri, "Face mask detection using OpenCV," dalam 2021 Third International Conference on Intelligent Communication Technologies and Virtual Mobile Networks (ICICV), 2021, hlm. 1304–1309. doi: 10.1109/ICICV50876.2021.9388375.
- [16] B. Hardiansyah, A. P. Armin, dan A. B. Yunanda, "Rekonstruksi citra pada super resolusi menggunakan interpolasi bicubic," Integer J. Inf. Technol., vol. 4, no. 2, hlm. 1–12, 2019, doi: 10.31284/j.integer.2019.v4i2.684.
- [17] B. Garber, A. Grossman, dan S. Johnson-Yu, "Image Super-Resolution via a Convolutional Neural Network," 2020.
- [18] P. A. Nugroho, I. Fenriana, dan R. Arijanto, "Implementasi deep learning menggunakan convolutional neural network (CNN) pada ekspresi manusia," J. Algor Data Syst., vol. 2, no. 1, hlm. 12–21, 2020, doi: 10.31253/algor.v2i1.
- [19] A. A. Sulaeman dan A. Susilo, "Implementasi convolutional neural network untuk klasifikasi Covid-19," Sigma- J. Teknol. Pelita Bangsa,

- vol. 13, no. 2, hlm. 113-118, 2022.
- [20] D. Efendi, J. Jasril, S. Sanjaya, F. Syafria, dan E. Budianita, "Penerapan algoritme convolutional neural network arsitektur ResNet-50 untuk klasifikasi citra daging sapi dan babi," Jurikom (Jurnal Ris. Komputer), vol. 9, no. 3, hlm. 607–614, 2022, doi: 10.30865/jurikom.v9i3.4176.
- [21] P. Zhou, J. Feng, C. Ma, C. Xiong, S. Hoi, dan E. Weinan, "Towards theoretically understanding why SGD generalizes better than ADAM in deep learning," dalam 34th Conference on Neural Information Processing Systems (NeurIPS 2020), 2020, vol. 2020-Decem, no. 1, hlm. 19–21.

Andre Daegal, kelahiran Ciamis, Jawa Barat sebagai mahasiswa aktif yang sedang menempuh pendidikan sarjana pada Program Studi Sains Data di Universitas Teknologi Yogyakarta.

Rianto, kelahiran Bantul, Daerah Istimewa Yogyakarta. Memperoleh gelar Master of Engineering (M.Eng.) di Universitas Gadjah Mada dan menyelesaikan pendidikan S3 dengan gelar Doktor di Universitas Gunadarma. Sekarang menjadi dosen tetap di Universitas Teknologi Yogyakarta dengan minat penelitian pada human computer interaction, artificial intelligence, dan natural language processing.