

Penerapan Model Arsitektur VGG-19 untuk Klasifikasi Kanker Serviks Menggunakan Citra Pap Smear

Leta Anindya Riyadi*¹, Yufis Azhar¹

Universitas Muhammadiyah Malang
anindya020801@gmail.com*¹, yufis@umm.ac.id¹

Abstrak

Kanker serviks merupakan jenis kanker yang menjadi ancaman serius bagi kesehatan wanita secara global, termasuk di Indonesia. Infeksi Human Papillomavirus (HPV) adalah penyebab utama kanker ini, dan sering kali sulit terdeteksi pada tahap awal. Penelitian ini memanfaatkan model arsitektur VGG-19 untuk membantu proses klasifikasi kanker serviks, karena interpretasi manual citra pap smear memiliki keterbatasan, seperti waktu yang lama. Model VGG-19 dioptimalkan dengan menggunakan teknik transfer learning. Dataset penelitian diambil dari situs Kaggle berjudul "Cervical Cancer largest dataset (SipakMed)" dengan 4049 gambar, kemudian dibagi menjadi data validasi, pelatihan, dan pengujian dengan rasio 80:10:10. Augmentasi data dilakukan untuk meningkatkan keragaman dan kualitas dataset. Hasil evaluasi menunjukkan bahwa akurasi klasifikasi mencapai 92%, dengan precision, recall, dan F1-Score yang tinggi di beberapa kelas. Dari hasil tersebut, arsitektur VGG-19 terbukti efektif dalam membantu klasifikasi gambar pap smear dan berpotensi menjadi solusi untuk deteksi kanker serviks yang lebih cepat dan akurat.

Kata Kunci: Kanker Serviks, Pap Smear, VGG-19, Klasifikasi

Abstract

Cervical cancer is a type of cancer that poses a serious threat to women's health globally, including in Indonesia. Human Papillomavirus (HPV) infection is main cause of this cancer, it is often difficult to detect in the early stages. This research utilizes the VGG-19 architecture model to assist in the classification process of cervical cancer, as the manual interpretation of pap smear images has limitations, such as being time-consuming. The VGG-19 model is optimized using transfer learning techniques. The research dataset was taken from the Kaggle site titled "Cervical Cancer largest dataset (SipakMed)" with 4049 images, which were then divided into validation, training, and testing data with ratio of 80:10:10. Data augmentation is performed to enhance the diversity and quality of the dataset. Evaluation results show that classification accuracy reached 92%, with high precision, recall, and F1-Score in several classes. From the results, the VGG-19 architecture has proven to be effective in assisting the classification of pap smear images and has the potential to become a solution for faster and more accurate cervical cancer detection.

Keywords: Cervical Cancer, Pap Smear, VGG-19, Classification

1. Pendahuluan

Kanker servik adalah kanker yang mempengaruhi organ reproduksi wanita, terutama bagian leher rahim, berada di antara rahim dan vagina [1]. Setiap tahun, sekitar 500.000 perempuan di seluruh dunia terdiagnosis terkena kanker serviks, dengan lebih dari 300.000 di antaranya berakhir dengan kematian. [2]. Menurut data Observasi Kanker Dunia (Globocan) untuk Indonesia, kanker serviks pada tahun 2020 menduduki peringkat kedua sebagai jenis kanker paling umum di Indonesia, dengan lebih dari 36.000 kasus baru, yang mencakup sekitar 9,2% dari total kasus kanker. [3].

Kanker servik terjadi ketika sel ganas tumbuh di leher rahim. Kondisi ini disebabkan oleh infeksi virus Human Papillomavirus, terutama tipe 18 dan 16, yang sering ditemukan di Indonesia. [4]. HPV merupakan infeksi umum yang dapat ditularkan melalui hubungan seksual. Beberapa faktor peningkatan risiko antara lain adalah berhubungan seksual di usia dini, memiliki banyak pasangan seksual, kebiasaan merokok, memiliki banyak anak, status sosial ekonomi rendah, penggunaan pil kontrasepsi oral (baik dengan adanya HPV maupun tidak), infeksi menular

seksual, serta gangguan pada sistem kekebalan tubuh [5]. Pada tahapan awal dan pra-kanker, penderita kanker serviks biasanya tidak bergejala yang jelas [6].

Pap smear merupakan teknik pengambilan sel mulut rahim dengan peralatan khusus, kemudian sel-sel tersebut ditempatkan pada kaca objek dan diwarnai menggunakan metode Papanicolaou untuk memperjelas komponen sel. Slide kaca yang dapat menampung hingga 300.000 sel dianalisis secara manual menggunakan mikroskop oleh ahli sitototik [7]. Tes ini berfungsi untuk mendeteksi perubahan sel serviks akibat infeksi virus human papilloma virus (HPV) [19]. Meskipun tes pap smear memiliki peran penting dalam upaya pencegahan kanker serviks, terdapat beberapa kelemahan yang harus diperhatikan [15]. Interpretasi visual manual dari citra pap smear memiliki keterbatasan yang signifikan, termasuk kebutuhan akan waktu yang lama dan risiko kesalahan prosedur. Pemrosesan citra medis telah mendapat manfaat dari teknologi deep learning dalam beberapa tahun terakhir. Ini memungkinkan pengolahan data mentah seperti gambar berdimensi 3 dan ekstraksi fitur secara otomatis untuk deteksi, segmentasi, dan klasifikasi [21]. Berdasarkan beberapa penelitian, metode (CNN) telah terbukti efektif dalam mengklasifikasikan gambar dan mengklasifikasi kanker serviks pada citra pap smear [8].

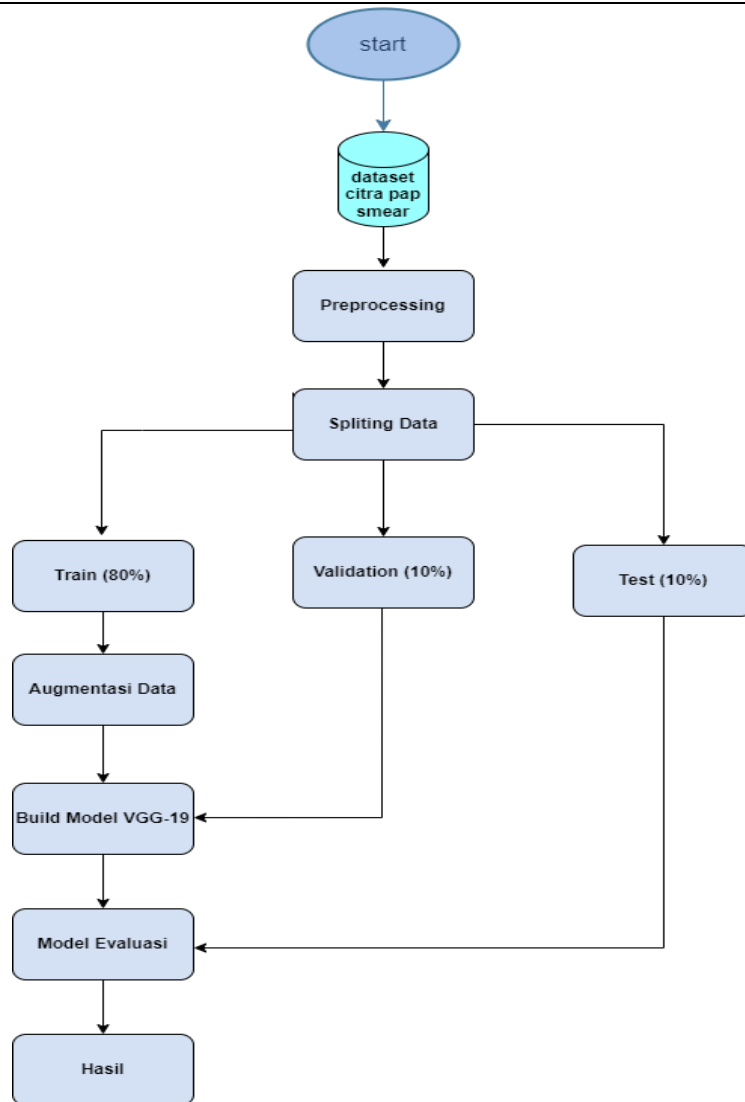
Dari latar belakang tersebut, dapat disimpulkan bahwa penelitian ini harus dilakukan untuk membantu mengidentifikasi kanker serviks melalui gambar pap smear. Pada penelitian ini, metode CNN digunakan untuk membantu mengidentifikasi kanker serviks melalui citra pemeriksaan pap smear. CNN dipilih karena CNN pengembangan dari MLP (*Multilayer Perceptron*) dikhususkan pada pemrosesan data 2Dimensi. Selain itu, CNN menyediakan berbagai model, seperti ResNet dan VGG [11], [12]. Dalam mengidentifikasi penyakit kanker serviks melalui citra, proses klasifikasi diperlukan untuk membagi setiap gambar ke dalam kategori yang sesuai berdasarkan karakteristiknya. Teknik pengenalan gambar ini sangat penting karena memungkinkan identifikasi objek dalam kumpulan data dan pengelompokannya berdasarkan kelas atau tingkat tertentu.

Dari latar belakang ini, terdapat hanya sedikit penelitian yang menerapkan metode CNN untuk mengidentifikasi penyakit kanker serviks melalui gambar pap smear. Salah satu penelitian yang menjadi referensi dalam penelitian ini adalah yang dilakukan oleh Za'imatus Niswati, Rahayuning Hardatin, Meia Noer Muslimah, dan Siti Nur Hasanah pada tahun 2021 [8]. Penelitian ini dilakukan menggunakan metode CNN dengan model arsitektur ResNet50 dan Resnet101. Studi ini mencapai nilai akurasi 91% pada ResNet50 dan 89% pada Resnet101. Penelitian sebelumnya dengan menggunakan model VGG-19, dilakukan oleh Rahma Shinta, Jasril, Muhammad Irsyad, Febi Yantod, dan Suwanto Sanjaya (2023) dengan judul "Klasifikasi Citra Penyakit Daun Tanaman Padi Menggunakan CNN dengan Arsitektur VGG-19" dengan hasil akurasi sebesar 94% [10]. Penelitian sebelumnya dengan menggunakan CNN Handcraft Model, Transfer Learning (VGG-16, VGG-19 dan ResNet-50), dilakukan oleh Jalu Nusantoro, Faldo Fajri Afrinanto, Wana Salma Labibah, Zamah Sari, Yufis Azhar (2022) dengan judul "Detection of Covid-19 on X-Ray Image of Human Chest Using CNN and Transfer Learning" dengan hasil CNN skenario 1 akurasi sebesar 95%, pada skenario 2 VGG-16 akurasi sebesar 93%, skenario 3 VGG-19 akurasi sebesar 90% dan ResNet-50 dengan akurasi sebesar 80% [13]. Dilakukan klasifikasi dengan kasus sama yang menggunakan dataset pada rumah sakit Hospital Universitario de Caracas di Caracas, Venezuela. Pada penelitian ini menggunakan metode Random forest tree dan K-Neast Neighbour dengan akurasi 88,7% untuk Random Forest dan 90,6% untuk KNN [18].

Oleh karena itu, berdasarkan penjelasan diatas, penelitian bertujuan untuk mencapai hasil yang optimal dalam mendeteksi kanker serviks dengan memanfaatkan model VGG-19. Diharapkan bahwa penelitian ini akan melampaui hasil penelitian sebelumnya dalam deteksi penyakit kanker serviks dan akan memberikan kontribusi untuk peneliti lain yang berminat melakukan penelitian sejenis.

2. Metode


Berikut rancangan penelitian pada Gambar 1.



Gambar 1. Alur Penelitian

2.1 Data

Dataset yang digunakan berupa gambar pemeriksaan Pap Smear, yang terdiri dari 4049 gambar yang diambil dari situs Kaggle dengan judul "Cervical Cancer largest dataset (SipakMed)". Dataset ini terbagi menjadi lima kelas, yaitu im_Superficial-Intermediate, im-Parabasal, im_Metaplastic, im_Koilocytotic, dan im_Dyskeratotic. Untuk pembuatan model, data dibagi data latih, validasi, dan uji dengan rasio 80:10:10 dengan 4049 gambar. Model dibangun menggunakan data latih dan validasi. Gambar dataset dilihat pada Gambar 2 dibawah ini.




Gambar 2. a) *im_Dyskeratotic*, b) *im_Koilocytotic*, c) *im_Metaplastic*, d) *im_Parabasal*, e) *im_Superficial-Intermediate*

2.2 Preprocessing

Tahap kedua adalah membagia data tersebut terdiri dari 3237 data untuk latih, 403 data untuk validasi, dan 409 data untuk uji [8].

2.3 Data Augmentasi


Augmentasi merupakan teknik untuk mengatasi overfitting dalam pembelajaran mesin. Teknik ini memperluas data asli dengan menghasilkan data baru melalui berbagai transformasi [11][16]. Penelitian ini, dilakukan dengan 'ImageDataGenerator'. Augmentasi meliputi rotasi gambar acak hingga 30 derajat, kemiringan gambar hingga 20%, zoom in dan zoom out hingga 2.5%, pembalikan gambar secara horizontal secara acak, serta pengaturan Brightness Range yang meningkatkan kecerahan gambar secara acak antara 1 hingga 1.1 kali dari nilai aslinya. Gambar hasil augmentasi pada Gambar 3.



Gambar 3. *Dataset Hasil Augmentasi*

2.4 VGG -19

Pengembangan terbaru CNN VGG-16. Arsitektur ini mempunyai 16 lapisan convolusi yang menggunakan aktivasi ReLU, serta lapisan fully connected 3 yang juga menggunakan aktivasi ReLU [10]. Penelitian ini menerapkan arsitektur VGG-19 dengan tujuan meningkatkan performa klasifikasi gambar skala besar, menggunakan filter konvolusi kecil 3x3 yang terbukti efektif [14]. Model VGG-19 diimplementasikan dengan bobot pra-latih dari dataset ImageNet dan dilengkapi lapisan fully-connected. Model dikompilasi menggunakan optimisi adam, fungsi los categorical crossentropy, dan metrik akurasi, lalu dilatih selama 100 epoch. Proses pelatihan menggunakan dataset latih dan validasi, dengan verbose=1 untuk menampilkan perkembangan akurasi dan loss di setiap epoch. Di bawah ini adalah ilustrasi arsitektur VGG-19 yang digunakan dalam penelitian ini. Gambar 4 menampilkan model VGG-19.



Gambar 4. Arsitektur VGG-19 [19]

2.5 Transfer Learning

Teknik pembelajaran mendalam yang dikenal sebagai transfer learning yaitu dengan melatih model pada suatu masalah untuk diterapkan pada masalah lainnya [17]. Tujuan dari penggunaan transfer learning adalah untuk membuat pelatihan dengan dataset yang berbeda menjadi lebih efisien dan efektif [20].

2.6 Evaluasi Model

Pada tahapan ini, pengujian klasifikasi dilakukan dengan menggunakan confusion matrik digunakan mengukur akurasi, recall, presisi, F1-score, dan metrik evaluasi lainnya. Ini bertujuan untuk menilai seberapa efektif model dalam memberikan prediksi yang akurat dalam mengklasifikasikan. Berikut adalah rumus dalam metode Confusion Matrix.

$$\text{Recal} = \frac{TP}{TP+FN} \quad (1)$$

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (3)$$

$$\text{F1score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

3. Hasil dan Pembahasan


3.1 Evaluasi

Arsitektur VGG-19 akan dianalisis untuk menilai kinerjanya dan dibandingkan dengan model dari penelitian sebelumnya [8]. Selain itu, evaluasi ini memberikan pedoman untuk pengembangan model di masa depan dan membantu menemukan potensi perbaikan.

3.2 Accuracy dan Loss

Grafik yang menunjukkan training dan validation accuracy selama 100 epoch menunjukkan bahwa model berkinerja lebih baik di awal pelatihan. Akurasi pelatihan, yang ditunjukkan oleh garis biru, stabil sekitar 95% setelah beberapa epoch setelah mengalami peningkatan cepat. Ini mengindikasikan bahwa seiring bertambahnya epoch, model semakin baik dalam mengklasifikasikan data pelatihan. Sementara itu, akurasi validasi, yang digambarkan oleh garis hijau, juga meningkat di awal pelatihan, tetapi setelah beberapa epoch, akurasinya stabil dan berfluktuasi sekitar 90%.


Grafik training loss dan validation loss selama 100 epoch menunjukkan penurunan signifikan pada training loss seiring bertambahnya epoch. Garis biru yang mewakili training loss menunjukkan penurunan yang stabil, yang berarti model dapat mempelajari pola dari data dengan baik dan mengurangi kesalahan prediksi, terutama setelah awal pelatihan. Secara keseluruhan, grafik pada penelitian menunjukkan bahwa model penelitian ini telah mempelajari data pelatihan dengan baik, namun masih perlu penyesuaian agar kinerjanya pada data validasi juga optimal. Gambar Training dan Validation Accuracy pada Gambar 5.



Gambar 5. Grafik Accuracy dan loss VGG19

3.3 Confusion Matrix

Penggunaan Confusion Matrik menunjukkan seberapa efektif mengklasifikasikan data uji ke dalam kelas yang sesuai berdasarkan hasil evaluasi model.



Gambar 6. Confusion Matrix

Gambar 6 menunjukkan bahwa sebagian besar sampel berhasil diklasifikasikan dengan akurat oleh model. Sebagai contoh, 76 sampel dari kelas "im_Dyskeratotic", 70 sampel dari kelas "im_Koilocytotic", dan 82 sampel dari kelas "im_Superficial-Intermediate" diklasifikasikan dengan benar. Namun, terdapat beberapa kesalahan klasifikasi, seperti empat sampel dari kelas "im_Parabasal" dan dua sampel dari kelas "im_Dyskeratotic" yang keliru dikategorikan sebagai "im_Metaplastic". Analisis confusion matrix ini menunjukkan bahwa meskipun model mengklasifikasikan sebagian besar data dengan benar, masih ada kesalahan yang perlu diperhatikan, yang mungkin disebabkan oleh kesamaan fitur antar kelas atau keterbatasan model dalam membedakan karakteristik tertentu dari gambar.

3.4 Perbandingan Performa Model

Berdasarkan hasil evaluasi model klasifikasi, kinerja model diukur dengan beberapa metrik, yaitu recall, precision, f1-score, dan support perkelasnya. Hasil dari metode ini dengan akurasi keseluruhan sebesar 92%, yang berarti 92% dari prediksi model sesuai dengan label sebenarnya. Selain itu, rata-rata precision, recall, dan f1-score dihitung dengan dua metode: macro average dan weighted average, keduanya bernilai 0.92. Macro average menghitung rata-rata dari semua kelas secara seimbang tanpa memperhatikan jumlah sampel, sedangkan weighted average mempertimbangkan distribusi sampel per kelas. Penjelasan mengenai evaluasi model terdapat di Gambar 7.

	precision	recall	f1-score	support
im_Dyskeratotic	0.93	0.90	0.92	84
im_Koilocytotic	0.84	0.92	0.88	76
im_Metaplastic	0.91	0.83	0.87	88
im_Parabasal	0.93	0.97	0.95	76
im_Superficial-Intermediate	0.98	0.96	0.97	85
accuracy			0.92	409
macro avg	0.92	0.92	0.92	409
weighted avg	0.92	0.92	0.92	409

Gambar 7. Classification Report VGG-19

Secara keseluruhan, model menunjukkan kinerja baik di sebagian besar kelas, dengan precision, recall, dan f1-score yang tinggi. Ini menunjukkan kemampuan model dalam mengidentifikasi pola pada dataset pelatihan dan validasi, meskipun masih ada potensi untuk perbaikan, terutama di kelas dengan performa lebih rendah.

Tabel 1. Perbandingan Performa Model

Model	Akurasi
VGG-19	92%
ResNet-50 [8]	91%
ResNet101 [8]	89%

Dari Tabel 1 diatas, terlihat bahwa model arsitektur VGG-19 dengan akurasi lebih tinggi daripada ResNet-50 dan ResNet-101 yang ditemukan dalam studi sebelumnya [8]. Ini menunjukkan bahwa VGG-19 lebih baik dalam menentukan kanker serviks melalui gambar pap smear.

4. Kesimpulan

Hasil penelitian menunjukkan model arsitektur VGG-19 dalam klasifikasi kanker serviks melalui gambar pap smear memiliki kinerja baik dengan akurasi 92%. Model ini lebih unggul dibandingkan ResNet-50 dan ResNet-101, yang masing-masing memiliki akurasi 91% dan 89% [8]. Dengan menerapkan teknik augmentasi data dan membekukan bobot lapisan konvolusi, VGG-19 menunjukkan kemampuan generalisasi yang lebih baik.

Daftar Notasi

TP : benar Positif
FP : salah Positif

TN : benar Negatif

FN : salah Negatif

Referensi

- [1] Minarno, A. E., Mandiri, M. H. C., & Alfarizy, M. R. (2021). Klasifikasi COVID-19 menggunakan Filter Gabor dan CNN dengan Hyperparameter Tuning. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 9(3), 493.
- [2] Lasniari, S., Jasril, J., Sanjaya, S., Yanto, F., & Affandes, M. (2022). Klasifikasi Citra Daging Babi dan Daging Sapi Menggunakan Deep Learning Arsitektur ResNet-50 dengan Augmentasi Citra. *Jurnal Sistem Komputer Dan Informatika (JSON)*, 3(4), 450-457.
- [3] Ariono, H. W., & Maryam, S. (2022). *Sistem Pakar Pengklasifikasi Stadium Kanker Serviks Berbasis Mobile Menggunakan Metode Decision Tree* (Doctoral dissertation, Universitas Muhammadiyah Surakarta).
- [4] Dharma, A., Manalu, P., Sinaga, G. S., Siringoringo, R., Palangai, I. S., & Setiawan, K. (2020). Deteksi Pola Pasien Kanker Serviks dengan Algoritma Extra Trees dan K-Nearest Neighbor. *Jurnal Ilmu Komputer dan Sistem*
- [5] Arbain, D., Sriyanto, S., & Triloka, J. (2023, August). Perbandingan Kinerja Algoritma K-Medoids Dan K-Means Untuk Klasifikasi Penyakit Kanker Serviks. In *Prosiding Seminar Nasional Darmajaya* (Vol. 1, pp. 118-131).
- [6] Fauzi, H., Surya, G., Magdalena, R., Harsono, A. B., & Azhar, T. N. (2021). Sistem Deteksi Pra-Kanker Serviks dengan Pengolahan Citra Hasil Inspeksi Visual Asam Asetat. *Techno. Com*, 20(2), 290-299.
- [7] Wijaya, R. S. D., Suksmono, A. B., & Mengko, T. L. (2021). Segmentasi citra kanker serviks menggunakan markov random field dan algoritma K-means. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(1), 139-147.
- [8] Hardatin, R., Muslimah, M. N., & Hasanah, S. N. (2021). Perbandingan Arsitektur ResNet50 dan ResNet101 dalam Klasifikasi Kanker Serviks pada Citra Pap Smear. *Faktor Exacta*, 14(3), 160-167.
- [9] Minarno, A. E., Mandiri, M. H. C., & Alfarizy, M. R. (2021). Klasifikasi COVID-19 menggunakan Filter Gabor dan CNN dengan Hyperparameter Tuning. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 9(3), 493.
- [10] Shinta, R. (2023). Klasifikasi Citra Penyakit Daun Tanaman Padi Menggunakan CNN dengan Arsitektur VGG-19. *Klasifikasi Citra Penyakit Daun Tanaman Padi Menggunakan CNN dengan Arsitektur VGG-19*, 9(01), 37-45.
- [11] N. D. Girsang, "Literature Study of Convolutional Neural Network Algorithm for Batik Classification," *Brill. Res. Artif. Intell.*, vol. 1, no. 1, pp. 1–7, 2021, doi: 10.47709/brilliance.v1i1.1069
- [12] C. F. G. Dos Santos and J. P. Papa, "Avoiding Overfitting: A Survey on Regularization Methods for Convolutional Neural Networks," *ACM Comput. Surv.*, vol. 54, no. 10 s, 2022, doi: 10.1145/3510413.
- [13] Nusantoro, J., Afrianto, F. F., Labibah, W. S., Sari, Z., & Azhar, Y. (2022). Detection of Covid-19 on X-Ray Image of Human Chest Using CNN and Transfer Learning. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 6(3), 430-441.
- [14] Yohannes, Y., Udjulawa, D., & Febbiola, F. (2021). Klasifikasi Lukisan Karya Van Gogh Menggunakan Convolutional Neural Network-Support Vector Machine. *Jurnal Teknik Informatika Dan Sistem Informasi*, 7(1).
- [15] Suwiyoga, K. (2007). Kanker serviks: penyakit keganasan fatal yang dapat dicegah. *Indonesian Journal of Obstetrics and Gynecology*.
- [16] Bella Dwi Mardiana, Wahyu Budi Utomo, Ulfah Nur Oktaviana, Galih Wasis Wicaksono, and Agus Eko Minarno, "Herbal Leaves Classification Based on Leaf Image Using CNN Architecture Model VGG16," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 7, no. 1, pp. 20–26, Feb. 2023, doi: 10.29207/resti.v7i1.4550.
- [17] Alya, R. F., Wibowo, M., & Paradise, P. (2023). Classification of batik motif using transfer learning on convolutional neural network (CNN). *Jurnal Teknik Informatika (Jutif)*, 4(1), 161-170.
- [18] Andrian, S., Salim, E. S., Bindan, H., Pranoto, E., & Dharma, A. (2020). Analisa Metode Random Forest Tree dan K-Nearest Neighbor dalam Mendeteksi Kanker Serviks. *Jurnal Ilmu Komputer Dan Sistem Informasi (JIKOMSI)*, 3(2), 97-101.

- [19] Latifah, L., Nurachmah, E., & Hiryadi, H. (2020). Faktor yang berkontribusi terhadap motivasi menjalani pemeriksaan pap smear pasien kanker serviks di poli kandungan. *Jurnal Keperawatan Suaka Insan (JKSI)*, 5(1), 90-99.
- [20] W. G. Pamungkas, M. I. P. Wardhana, Z. Sari, and Y. Azhar, "Leaf Image Identification: CNN with EfficientNet-B0 and ResNet-50 Used to Classified Corn Disease," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 7, no. 2, pp. 326–333, Mar. 2023, doi: 10.29207/resti.v7i2.4736.
- [21] Ulfah Nur Oktaviana, Ricky Hendrawan, Alfian Dwi Khoirul Annas, and Galih Wasis Wicaksono, "Klasifikasi Penyakit Padi berdasarkan Citra Daun Menggunakan Model Terlatih Resnet101," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 6, pp. 1216–1222, Dec. 2021, doi: 10.29207/resti.v5i6.3607.

