

Model HSI-EfficientNetB7 Untuk Analisis Citra Histopatologi Kanker Payudara

Anita Ratnasari

Fakultas Teknik dan Informatika, Universitas Dian Nusantara, Indonesia

anita.ratnasari@undira.ac.id

Article Info

Article history:

Received, 2024-09-06

Revised, 2024-11-11

Accepted, 2024-11-30

Kata Kunci:

kanker payudara

EfficientNetB7

deep learning

Keywords:

breast cancer

EfficientNetB7

deep learning

ABSTRAK

Praktik analisis berkembang seiring dengan kemajuan ilmu komputer dan teknologi gambar histopatologi. Menggabungkan berbagai jenis pembelajaran, seperti pembelajaran mendalam, pembelajaran mesin, dan pemrosesan gambar, adalah salah satu cara untuk mendapatkan tingkat Presisi tertinggi. Tujuan dari penelitian yang telah diusulkan adalah untuk mengevaluasi efektivitas pendekatan transfer learning EfficientNetB7 dalam menilai histologi kanker payudara. Investigasi ini dibagi menjadi tiga tahap utama: pengumpulan data, kategorisasi gambar, dan analisis. EfficientNetB7 transfer learning adalah metodologi yang digunakan untuk klasifikasi data. Gambar histopatologis spesimen kanker payudara dengan resolusi 50 x 50 digunakan sebagai sumber data yang dievaluasi (198.738 kelas negatif dan 78.786 kelas positif). Evaluasi pelatihan akurasi, validitas, dan pengujian citra spesimen histopatologi kanker payudara dengan resolusi 50 x 50 (198.738 kelas negatif dan 78.786 kelas positif) diperoleh akurasi 91,63% (tahap pelatihan) dan 90,34% ccuracy (tahap validasi), dan hasil akurasi (tahap pengujian) sebesar 62,67%. Ini adalah hasil akhir dari evaluasi akurasi pelatihan, validitas, dan pengujian gambar spesimen histopatologis kanker payudara. Skor 0,1158 diperoleh untuk Cohen's Kappa, skor 0,5422 diperoleh untuk F1-Score, skor 0,6558 diperoleh untuk Presisi, dan skor 0,6267 untuk Recall.

ABSTRACT

The practice of analysis is expanding in tandem with the advancement of computer science and histopathology image technologies. Combining different types of learning, such as deep learning, machine learning, and image processing, is one way to get the highest level of Precision. The purpose of the research that has been proposed is to evaluate the effectiveness of the EfficientNetB7 transfer learning approach in assessing the histology of breast cancer. This investigation is divided into three primary stages: data gathering, image categorization, and analysis. EfficientNetB7 transfer learning is the methodology that is utilized for data classification. Histopathological pictures of breast cancer specimens with a resolution of 50 x 50 were used as the source of the evaluated data (198,738 negative classes and 78,786 positive classes). Evaluation of the training accuracy, validity, and testing of breast cancer histopathological specimen images with a resolution of 50 x 50 (198,738 negative class and 78,786 positive class) obtained 91.63% accuracy (training stage) and 90.34% accuracy (validation stage), and the accuracy result (testing stage) is 62.67%. This is the final result of evaluating the training accuracy, validity, and testing of the breast cancer histopathological specimen images. A score of 0.1158 was acquired for Cohen's Kappa, a score of 0.5422 was obtained for the F1-Score, a score of 0.6558 was obtained for Precision, and a score of 0.6267 was received for Recall for the alternative evaluation model.

This is an open access article under the CC BY-SA license.



Penulis Korespondensi:

Anita Ratnasari

Fakultas Teknik dan Informatika,

Universitas Dian Nusantara, Indonesia

Email: anita.ratnasari@undira.ac.id

1. PENDAHULUAN

Kanker payudara paling umum yang diderita oleh pasien wanita. Hal ini terjadi karena ada penyimpangan dari jaringan sehat yang terindikasi sebagai kanker. Namun, analisis diperlukan untuk menentukan apakah penyimpangan dari jaringan sehat didiagnosis sebagai kanker oleh ahli patologi. Analisis dapat dilakukan dengan mempelajari gambar histopatologis milik pasien sehingga lokasi spesifik dan tingkat bahaya penyakit [1]–[8].

Dengan perkembangan ilmu komputer, metode untuk analisis gambar histopatologis juga berkembang. Metode pemrosesan gambar, pembelajaran mesin, dan pembelajaran mendalam dapat digabungkan untuk mendapatkan akurasi terbaik [9]–[22]. Pemilihan himpunan data dan metode yang sesuai akan secara signifikan mempengaruhi hasil pengolahan data [1], [4], [9], [15], [23]–[26].

Analisis citra histopatologis dapat dilakukan dengan berbagai metode pengolahan citra atau machine learning. Metode ekstraksi fitur tekstur atau warna dan metode SVM atau *random forest* adalah metode yang paling banyak diterapkan. Citra histopatologis dianalisis berdasarkan *area of interest* (ROI) yang ditentukan untuk mempersempit area analisis. Hasil analisis ini sangat berguna untuk mengetahui tindakan klinis yang harus dilakukan pada pasien. Kesalahan diagnostik akan berdampak pada kesalahan klinis dan memperburuk kondisi pasien [1], [7], [27]–[32].

Penelitian Saha et al. (2018) membahas penggunaan model deep learning untuk menganalisis citra histopatologi payudara. Penelitian ini menggunakan model arsitektur deep learning yang terdiri dari empat *rectified linear unit* (ReLU), empat max-pooling layer dan lima convolution layer. Penelitian ini menggunakan dataset *Whole-slide imaging* (WSI) pada histopatologi payudara. Dari hasil pengolahan data, penelitian ini memperoleh nilai presisi 92%, recall 88% dan F-score 90% [33].

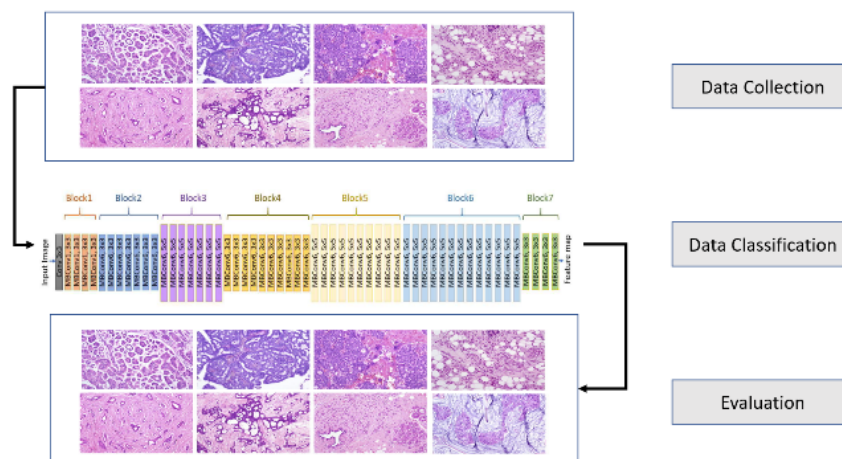
Penelitian Hameed et al. (2020) ini membahas pemodelan *deep learning* untuk menganalisis citra histopatologi payudara. Penelitian ini melakukan percobaan dengan menggunakan model arsitektur VGG16 dan VGG19. Dalam melakukan penelitian, dataset yang digunakan adalah *whole slide images* (WSI) dataset yang dikumpulkan oleh pasien kanker payudara sendiri dengan bantuan ahli patologi. Dari hasil penelitian, model VGG16 dan VGG19 yang disempurnakan mendapatkan nilai akurasi keseluruhan sebesar 95,29% dengan skor F1 sebesar 95,29% [34].

Penelitian Nahid et al. (2018) juga membahas metode deep learning untuk mengolah dataset citra histopatologi payudara. Dataset yang digunakan adalah dataset BreakHis yang berisi gambar rinci kanker payudara. Penelitian ini menggunakan pendekatan deep learning dengan menerapkan metode Long-Short-Term-Memory (LSTM), metode Convolutional Neural Network (CNN), dan kombinasi metode CNN dan LSTM. Dari hasil eksperimen, penelitian ini memperoleh akurasi 91,00% dan presisi 96,00% [35].

Berdasarkan penelitian di atas, metode deep learning merupakan salah satu metode yang memiliki kinerja yang baik untuk dataset histopatologi payudara. Penelitian ini akan menggunakan metode lain yaitu, EfficientNetB7, dengan judul analisis histopatologi kanker payudara menggunakan metode transfer learning EfficientNetB7.

2. METODE PENELITIAN

Penelitian ini terdiri dari 3 tahap utama yaitu, pengumpulan data, klasifikasi citra, dan evaluasi, seperti yang ditunjukkan pada **Gambar 1** berikut.



Gambar 1 Tahapan Penelitian

Pengumpulan Data. Himpunan data terdiri dari 162 gambar dudukan slide dari semua spesimen histopatologi kanker payudara yang dipindai pada 40x. Kemudian, *preprocessing* gambar menghasilkan 277.524 patch berukuran 50 x 50 (198.738 kelas negatif dan 78.786 kelas positif). Setiap nama diberi nama dalam format `uxXyYclassC.png` (misalnya `10253idx5x1351y1101class0.png`). Deskripsi namanya adalah bahwa `u` adalah ID pasien (`10253idx5`), `X` adalah koordinat `x` dari mana bagian gambar histopatologis ini diambil, `Y` adalah koordinat `y` dari mana gambar histopatologis ini diambil, dan `C` adalah kelas di mana `0` adalah kelas negatif dan `1` adalah kelas positif. **Klasifikasi Data.** Klasifikasi data menggunakan metode transfer learning EfficientNetB7. Arsitektur EfficientNetB7 dengan MBConv adalah blok dasar. Arsitektur keseluruhan dapat dibagi menjadi tujuh blok yang ditampilkan dalam berbagai warna. Blok dasar jaringan adalah MBConv (mobile inverted bottleneck convolution). Setiap blok MBConvX ditampilkan dengan ukuran filter yang sesuai dan `X = 1` dan `X = 6` mewakili fungsi aktivasi standar untuk ReLU dan ReLU6, masing-masing. **Evaluasi.** Pada penelitian ini dilakukan kinerja metode transfer learning dihitung dengan menggunakan metode penilaian akurasi. Akurasi ditentukan oleh rumus berikut [36]:

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN}$$

3. HASIL DAN ANALISIS

Dataset terdiri dari 277.524 patch dengan ukuran 50 x 50 dan 198.738 kelas IDC negatif dan 78.786 kelas IDC positif. Dalam penelitian ini, hanya 6.396 gambar yang digunakan, dengan 4338 untuk pelatihan, 1083 untuk validasi, dan 975 untuk pengujian. Kami menggunakan model pembelajaran transfer EfficientNetb7. Penelitian ini mengolah data dengan menggunakan model Sequential di Keras.

Layer yang digunakan adalah *layer efficientnetb7*. Data diproses dengan format (batch_size, tinggi, lebar, kedalaman) pada lapisan *efficientnetb7*. Format atau dimensi pertama mewakili ukuran batch gambar, dan tiga dimensi lainnya mewakili dimensi gambar, yaitu tinggi, lebar, dan kedalaman. Nilai untuk kedalaman gambar ditentukan berdasarkan jumlah saluran warna. Misalnya, gambar RGB akan memiliki kedalaman 3, dan gambar skala abu-abu akan memiliki kedalaman 1.

Bentuk output dari lapisan *efficientnetb7* ini adalah (None, 2, 2, 2560) dengan total parameter 64097687. Nilai "None" dari bentuk output menunjukkan bahwa ukuran batch apa pun akan diterima. Pengaturan ke nilai "None" tidak membatasi pemrosesan data. Pada saat yang sama, variabel `params#` menunjukkan parameter yang dapat dilatih dan tidak dapat dilatih dari setiap lapisan.

Lapisan berikutnya adalah global average pooling. Lapisan ini adalah operasi pooling yang dirancang untuk menggantikan fully connected layer dalam CNN. Salah satu keuntungan dari fully connected global average pooling adalah bahwa ia lebih asli dari struktur konvolusi dengan menegakkan korespondensi antara feature map dan kategori. Dengan demikian, *feature map* dapat dengan mudah ditafsirkan sebagai *confidence map*. Keuntungan lain adalah tidak ada parameter untuk mengoptimalkan *global average pooling*, sehingga *overfitting* dihindari pada *layer* ini.

Blok 2D Global average pooling dapat menggantikan blok *fully connected layer* CNN. Blok ini mengambil ukuran (lebar input) x (tinggi input) x (saluran input) dan menghitung rata-rata semua nilai di seluruh matriks (lebar input) x (tinggi input) untuk setiap matriks (saluran input). Blok ini melakukan operasi yang sama dengan blok *2D Average pooling*, kecuali bahwa ukuran pool (yaitu, *Horizontal pooling factor* x *Vertical pooling factor*) adalah ukuran seluruh blok input, yaitu, menghitung nilai rata-rata tunggal untuk setiap blok saluran input (saluran input). Bentuk output dari lapisan *2D Global average pooling* ini adalah None, 2560. Berikut ini adalah model arsitektur EfficientNetB7 yang dapat dilihat pada **Gambar 2**.

```
Model: "sequential"
```


Layer (type)	Output Shape	Param #
efficientnetb7 (Functional)	(None, 2, 2, 2560)	64097687
global_average_pooling2d (GlobalAveragePooling2D)	(None, 2560)	0
dropout (Dropout)	(None, 2560)	0
dense (Dense)	(None, 1)	2561

```


Total params: 64,100,248
Trainable params: 63,789,521
Non-trainable params: 310,727
    
```

Gambar 2 Arsitektur Usulan

Hasil evaluasi kinerja model Sequential EfficientNetb7 diukur menggunakan model akurasi. Pada tahap pelatihan, akurasi setiap *epoch* cenderung meningkat hingga berakhir pada *epoch* ke-50, sedangkan tahap validasi menghasilkan akurasi setiap *epoch* yang bervariasi dan tidak terstruktur tetapi berakhir sama pada *epoch* pertama dan epoch ke-50. Hasil akurasi untuk tahapan pelatihan dan validasi dapat dilihat pada **Gambar 3** berikut.



Gambar 3 Hasil Perhitungan Akurasi



Gambar 4 Hasil Perhitungan Loss

Sebagai hasil akhir, evaluasi pelatihan akurasi, validitas dan pengujian citra spesimen histopatologi kanker payudara dengan resolusi 50 x 50 (198.738 kelas negatif dan 78.786 kelas positif) diperoleh akurasi 91,63% (tahap pelatihan) dan akurasi 90,34% (tahap validasi). Selain itu, hasil akurasi (tahap pengujian) sebesar 62,67%. Nilai model evaluasi lainnya memperoleh skor 0,1158 untuk Cohens Kappa, skor 0,5422 untuk F1-Score, skor 0,6558 untuk Presisi dan skor 0,6267 untuk Recall. Hasil ringkasan kinerja model Sequential EfficientNetb7 dapat dilihat pada **Tabel 1**.

Tabel 1 Kinerja EfficientNetb7


Paramater	Hasil
Accuracy of Training	0.9163
Accuracy of Validation	0.9034
Accuracy of Testing	0.6267
Cohens Kappa	0.1158
F1_score	0.5422
Precision	0.6558
Recall	0.6267

Selain itu, penelitian ini menggunakan Estimasi Akurasi dengan metode *Confusion Matrix*. Metode ini menilai label yang dapat digunakan sebagai referensi dalam mengukur kinerja model dan mewakili jumlah nilai yang diprediksi dan nilai aktual. Hasil dari *Confusion Matrix* dapat dilihat pada **Gambar 5**.

True Label	555	23
	341	56

Gambar 5 Confusion Matrix

Untuk melihat dan menilai kinerja model Sequential EfficientNetb7 dalam mengklasifikasikan citra spesimen histopatologi kanker payudara dengan resolusi 50 x 50 ke dalam kelas negatif dan positif, penelitian ini menggunakan beberapa sampel gambar yang telah diklasifikasikan oleh model Sequential EfficientNetb7 secara otomatis. Keterangan gambar biru menunjukkan bahwa klasifikasi berhasil, sedangkan keterangan gambar merah menunjukkan bahwa klasifikasi tidak berhasil. Hasil klasifikasi dapat dilihat pada **Gambar 6**.



Gambar 6 Hasil Prediksi Algoritma

4. KESIMPULAN

Penelitian yang diusulkan bertujuan untuk mengetahui kinerja metode transfer learning EfficientNetB7 dalam menganalisis histopatologi kanker payudara. Penelitian ini terdiri dari 3 tahap utama: pengumpulan data, klasifikasi citra, dan evaluasi. Klasifikasi data menggunakan metode transfer learning EfficientNetB7. Data yang dianalisis adalah citra histopatologi spesimen kanker payudara dengan resolusi 50 x 50 (198.738 kelas negatif dan 78.786 kelas positif). Sebagai hasil akhir, evaluasi pelatihan akurasi, validitas dan pengujian citra spesimen histopatologi kanker payudara dengan resolusi 50 x 50 (198.738 kelas negatif dan 78.786 kelas positif) memperoleh akurasi 91,63% (tahap pelatihan) dan akurasi 90,34% (tahap validasi), dan hasil akurasi (tahap pengujian) sebesar 62,67%. Nilai model evaluasi lainnya memperoleh skor 0,1158 untuk Cohens Kappa, skor 0,5422 untuk F1-Score, skor 0,6558 untuk Presisi dan skor 0,6267 untuk Recall.

UCAPAN TERIMA KASIH

Terima kasih kepada Universitas Dian Nusantara yang telah mendanai penelitian ini melalui skema penelitian internal dengan No. Kontrak: 11/94/H-SPK/II/2024.

REFERENSI

- [1] B. Geceer, S. Aksoy, E. Mercan, L. G. Shapiro, D. L. Weaver, and J. G. Elmore, "Detection and classification of cancer in whole slide breast histopathology images using deep convolutional networks," *Pattern Recognit.*, vol. 84, pp. 345–356, 2018.
- [2] P. J. Sudharshan, C. Petitjean, F. Spanhol, L. E. Oliveira, L. Heutte, and P. Honeine, "Multiple instance learning for histopathological breast cancer image classification," *Expert Syst. Appl.*, vol. 117, pp. 103–111, 2019.
- [3] P. Alirezazadeh, B. Hejrati, A. Monsef-Esfahani, and A. Fathi, "Representation learning-based unsupervised domain adaptation for classification of breast cancer histopathology images," *Biocybern. Biomed. Eng.*, vol. 38, no. 3, pp. 671–683, 2018.
- [4] C. Kaushal, S. Bhat, D. Koundal, and A. Singla, "Recent trends in computer assisted diagnosis (CAD) system for breast cancer diagnosis using histopathological images," *Irbm*, vol. 40, no. 4, pp. 211–227, 2019.
- [5] J. Xie, R. Liu, J. Luttrell IV, and C. Zhang, "Deep learning based analysis of histopathological images of breast cancer," *Front. Genet.*, vol. 10, p. 80, 2019.
- [6] M. Sadikin, M. I. Fanany, and T. Basaruddin, "A New Data Representation Based on Training Data Characteristics to Extract Drug Name Entity in Medical Text," *Comput. Intell. Neurosci.*, vol. 2016, 2016.
- [7] I. Nurhaida *et al.*, "Implementation of Deep Learning Predictor (LSTM) Algorithm for Human Mobility Prediction," *Int. J. Interact. Mob. Technol.*, vol. 14, no. 18, p. 132, Nov. 2020.
- [8] H. Oda *et al.*, "BESNet: boundary-enhanced segmentation of cells in histopathological images," in *International conference on medical image computing and computer-assisted intervention*, 2018, pp. 228–236.
- [9] H. Noprisson, E. Ermatita, A. Abdiansah, V. Ayumi, M. Purba, and M. Utami, "Hand-Woven Fabric Motif Recognition Methods: A Systematic Literature Review," in *2021 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 2021, pp. 90–95.
- [10] M. Purba, E. Ermatita, A. Abdiansah, V. Ayumi, H. Noprisson, and A. Ratnasari, "A Systematic Literature Review of Knowledge Sharing Practices in Academic Institutions," in *2021 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 2021, pp. 337–342.
- [11] H. Noprisson, "Earthquake Early Warning (EEW) System: System Architecture, Data Modelling, and User Interface Design," *Int. J. Sci. Res. Comput. Sci. Eng. Inf. Technol.*, pp. 650–657, Jun. 2021.
- [12] H. Noprisson, "Current Research Trend on Agile Software Development," *Int. J. Sci. Res. Comput. Sci. Eng. Inf. Technol.*, pp. 99–105, Sep. 2019.
- [13] H. Noprisson, "Exploring e-Tourism : Technology and Human Factors," *Int. J. Sci. Res. Sci. Eng. Technol.*, pp. 169–177, Sep. 2021.
- [14] D. Indra Sensuse *et al.*, "Lessons from Integrated Biodiversity Information System Implementation Initiatives," *Int. J. Adv. Sci. Eng. Inf. Technol.*, vol. 12, no. 4, p. 1657, Aug. 2022.
- [15] V. Ayumi, E. Ermatita, A. Abdiansah, H. Noprisson, M. Purba, and M. Utami, "A Study on Medicinal Plant Leaf Recognition Using Artificial Intelligence," in *2021 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 2021, pp. 40–45.
- [16] H. Noprisson, E. Ermatita, A. Abdiansah, V. Ayumi, M. Purba, and H. Setiawan, "Fine-Tuning Transfer Learning Model in Woven Fabric Pattern Classification," *Int. J. Innov. Comput. Inf. Control*, vol. 18, no. 06, p. 1885, 2022.
- [17] M. Purba *et al.*, "Effect of Random Splitting and Cross Validation for Indonesian Opinion Mining using Machine Learning Approach," *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 9, 2022.
- [18] V. Ayumi *et al.*, "Transfer Learning for Medicinal Plant Leaves Recognition: A Comparison with and without a Fine-Tuning Strategy," *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 9, 2022.
- [19] V. Ayumi, "Pengenalan Objek Bunga Berbasis Deep Learning Menggunakan Model Resnet50 dan MobileNet-v2," *JSAI (Journal Sci. Appl. Informatics)*, vol. 5, no. 3, pp. 188–193, 2022.
- [20] V. Ayumi, "Perbandingan Model Transfer Learning Untuk Klasifikasi Citra Agricultural Crop," *JSAI (Journal Sci. Appl. Informatics)*, vol. 5, no. 3, pp. 214–222, 2022.
- [21] H. Noprisson, "Fine-Tuning Model Transfer Learning VGG16 Untuk Klasifikasi Citra Penyakit Tanaman Padi," *JSAI (Journal Sci. Appl. Informatics)*, vol. 5, no. 3, pp. 244–249, 2022.
- [22] H. Noprisson, "Perbandingan Algoritma Xception dan VGG16 Untuk Pengenalan Lebah Pollen-Bearing," *JSAI (Journal Sci. Appl. Informatics)*, vol. 5, no. 3, pp. 223–227, 2022.
- [23] C. L. Srinidhi, O. Ciga, and A. L. Martel, "Deep neural network models for computational histopathology: A survey," *Med. Image Anal.*, vol. 67, p. 101813, 2021.
- [24] S. Liu *et al.*, "Isocitrate dehydrogenase (IDH) status prediction in histopathology images of gliomas using deep learning," *Sci. Rep.*, vol. 10, no. 1, pp. 1–11, 2020.
- [25] M. Toğaçar, K. B. Özkurt, B. Ergen, and Z. Cömert, "BreastNet: a novel convolutional neural network

- model through histopathological images for the diagnosis of breast cancer,” *Phys. A Stat. Mech. its Appl.*, vol. 545, p. 123592, 2020.
- [26] V. Ayumi, L. M. R. Rere, M. I. Fanany, and A. M. Arymurthy, “Random Adjustment - Based Chaotic Metaheuristic Algorithms for Image Contrast Enhancement,” *J. Ilmu Komput. dan Inf.*, vol. 10, no. 2, pp. 67–76, 2017.
- [27] Z. Gandomkar, P. C. Brennan, and C. Mello-Thoms, “MuDeRN: Multi-category classification of breast histopathological image using deep residual networks,” *Artif. Intell. Med.*, vol. 88, pp. 14–24, 2018.
- [28] H. Yang, J.-Y. Kim, H. Kim, and S. P. Adhikari, “Guided soft attention network for classification of breast cancer histopathology images,” *IEEE Trans. Med. Imaging*, vol. 39, no. 5, pp. 1306–1315, 2019.
- [29] V. Ayumi, “Application of Machine Learning for SARS-CoV-2 Outbreak,” *Int. J. Sci. Res. Sci. Eng. Technol.*, vol. 7, no. 5, pp. 241–248, Oct. 2021.
- [30] I. H. Ikasari, V. Ayumi, M. I. Fanany, and S. Mulyono, “Multiple regularizations deep learning for paddy growth stages classification from LANDSAT-8,” in *International Conference on Advanced Computer Science and Information Systems (ICACSIS)*, 2016, pp. 512–517.
- [31] D. Ramayanti *et al.*, “Tuberculosis Ontology Generation and Enrichment Based Text Mining,” in *2020 International Conference on Information Technology Systems and Innovation (ICITSI)*, 2020, pp. 429–434.
- [32] P. Sukmasetya, F. Nurhidayati, I. Permatasari, A. Rahmah, D. I. Sensesuse, and H. Noprisson, “Developing mobile expert web-based system using brainstorming method: Case: Tetanus and botulism diagnosis and treatment in goat,” in *2017 International Conference on Information Technology Systems and Innovation (ICITSI)*, 2017, pp. 303–308.
- [33] M. Saha, C. Chakraborty, and D. Racoceanu, “Efficient deep learning model for mitosis detection using breast histopathology images,” *Comput. Med. Imaging Graph.*, vol. 64, pp. 29–40, 2018.
- [34] Z. Hameed, S. Zahia, B. Garcia-Zapirain, J. Javier Aguirre, and A. María Vanegas, “Breast cancer histopathology image classification using an ensemble of deep learning models,” *Sensors*, vol. 20, no. 16, p. 4373, 2020.
- [35] A.-A. Nahid, M. A. Mehrabi, and Y. Kong, “Histopathological breast cancer image classification by deep neural network techniques guided by local clustering,” *Biomed Res. Int.*, vol. 2018, 2018.
- [36] M. Izadpanahkakhk, S. M. Razavi, M. Taghipour-Gorjikotaie, S. H. Zahiri, and A. Uncini, “Deep region of interest and feature extraction models for palmprint verification using convolutional neural networks transfer learning,” *Appl. Sci.*, vol. 8, no. 7, p. 1210, 2018.