

Deep Learning Untuk Klasifikasi Motif Batik Papua Menggunakan EfficientNet dan Transfer Learning

Suhardi Aras¹, Arief Setyanto², Rismayani³

^{1,2} Magister of Informatics Engineering University of AMIKOM Yogyakarta

³Program studi Software Engineering, Universitas Dipa Makassar

e-mail: *¹suhardi.1172@students.amikom.ac.id , ²arief.s@amikom.ac.id,

³rismayani@undipa.ac.id

Abstrak

Merupakan warisan budaya Indonesia, batik Papua hadir dengan ragam motif, selain dikenal dengan motif daerah asal pembuatannya, motif corak budaya serta corak flora dan fauna pun mewarnai keragaman motif batik dari Papua. Kemampuan untuk mengenal motif – motif tersebut, menjadi tantangan untuk menemukan model dalam mengklasifikasi motif batik dari Papua untuk melestarikannya.

Penelitian ini menggunakan deep learning dalam mengklasifikasi motif batik dari Papua dengan melakukan transfer learning menggunakan arsitektur EfficientNet dengan transfer learning dan teknik augmentasi data

Hasil pengujian menggunakan empat kelas dataset memperoleh dengan arsitektur EfficientNet-B2 dengan fine tuning memberikan akurasi 72% dan ditambahkan teknik augmentasi tertinggi dengan menggunakan teknik ColorJitter dan Contrast dengan hasil 90%.

Kata kunci— deep learning, transfer learning, data augmentation, batik papua, EfficientNet

1. PENDAHULUAN

Batik papua yang mulai hadir dan diperkenalkan pada tahun 1984 [1] yang motifnya beragam seperti rumah adat, tifa, patung korwar, patung asmat juga flora dan fauna seperti cendrawasih, kasuari, buaya dan anggrek [2] perlu dilestarikan karena merupakan warisan budaya Indonesia yang diakui oleh UNESCO. Pelestariannya dapat dilakukan dengan adanya tools pengenalan atas motif batik dari Papua bagi masyarakat awam yang saat ini pahami oleh kalangan tertentu atau yang telah berpengalaman.

Motif batik telah menjadi objek penelitian dalam mengklasifikasi menggunakan machine learning maupun deep learning seperti menggunakan metode Gray level Co-Occurrence Matrices (GLCM) [3], Algoritma classifier K-Nearest Neighbor dengan feature extraction menggunakan Multi Texton Histogram [4], Algoritma Artificial Neural Network dengan feature Texture Shape [5]. Pada algoritma machine learning ekstraksi warna, tekstur dan edge masih dilakukan secara manual, menggunakan Convolution Neural Network terdapat ekstraksi fitur sendiri [6].

Penelitian klasifikasi batik dengan algoritma CNN antara lain dengan membandingkan arsitektur GoogleNet, Residual Network dan Inception, diperoleh hasil akurasi 70,84% dan waktu komputasi 636 ms pada algoritma Inception yang lebih baik daripada arsitektur lainnya pada kinerja mengklasifikasi 11 kelas motif batik [7]. Ketersediaan dataset batik secara umum masih

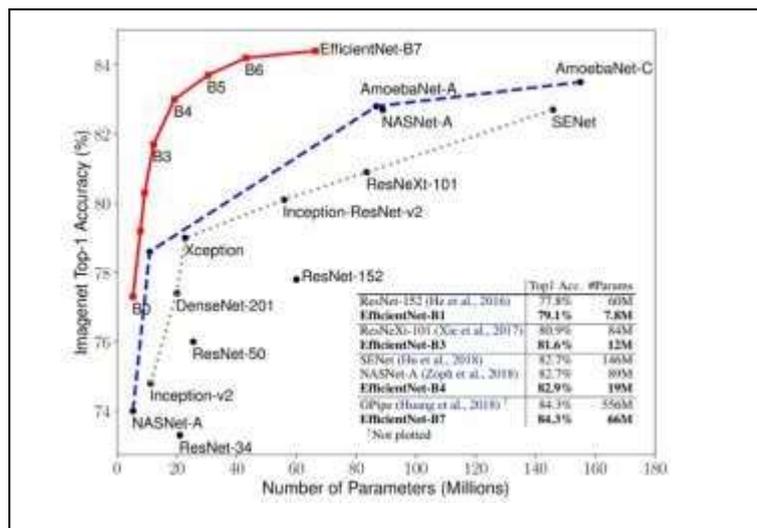
sulit ditemukan harus diproduksi sendiri, sehingga potensi terjadi overfitting karena dataset yang berukuran kecil, pendekatan dengan data augmentasi dapat menjadi solusi untuk penambahan dataset[8]. Penelitian lain dengan memanfaatkan algoritma CNN dengan arsitektur VGG16 dan arsitektur VGG19 yang ditambahkan data augmentasi, diperoleh peningkatan kinerja akurasi pada 10%. Diperoleh juga untuk augmentasi dibesarkan dan diputar sebanyak dua kali tidak memberikan peningkatan kinerja yang baik dengan akurasi 56%[9]. Arsitektur VGG16 pada penelitian lain memberikan akurasi 98,96% dengan ditambahkan data augmentasi dan yang sebelumnya tanpa augmentasi diperoleh akurasi 95,83%, delapan augmentasi yang dilakukan yaitu pergeseran lebar, pergeseran tinggi, pergeseran channel, perbesar, menghapus, memutar, merubah kecerahan dan menggeser derajat serta ditambahkan kombinasi pada delapan augmentasi tersebut dalam mengklasifikasi lima kelas batik[10]. Penelitian lain menggunakan Arsitektur Resnet50 dengan dataset batik sebanyak 300 buah gambar yang dilakukan empat augmentasi data yaitu memutar, memperbesar, berbalik horizontal dan berbalik vertical diperoleh penambahan dataset hingga 1200 buah memberikan hasil yang baik dengan akurasi hingga 96% [11].

Pemanfaatan transfer learning pada arsitektur neural network pra-latih VGGNet, GoogleNet, ResNet dan AlexNet memberikan hasil kinerja yang tinggi pada klasifikasi kelenjar getah bening torako-abdominal [12] dan pada penelitian mengklasifikasi citra sel darah putih bekerja dengan baik pada empat arsitektur tersebut[13]. Pada penelitian klasifikasi batik yang memanfaatkan transfer learning pre-trained dengan arsitektur MobileNetV2, dengan dataset yang tidak besar dilakukan empat data augmentasi untuk mencegah terjadinya overfitting memberikan validasi akurasi mencapai 94,74% [14]. Pemanfaatan lain dengan transfer learning dengan arsitektur EfficientNet[15] dalam mengklasifikasi gambar MRI tumor otak dengan hasil yang terbaik mencapai akurasi 96% dari delapan tingkat kategori EfficientNet pada EfficientNet-B1 dan EfficientNet-B2 [16].

2. METODE PENELITIAN

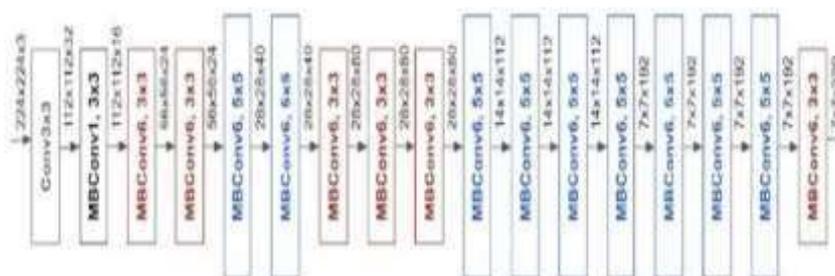
2.1 Arsitektur Model

Perubahan sebuah arsitektur CNN seperti MobileNetV1[17] menjadi MobileNetV2[18] atau perkembangan ResNet [19] menjadi ResNet50 dilakukan untuk memperoleh kinerja yang lebih baik dengan merubah ketiga komponen yaitu layer, filter dan citra masukan. Peningkatan kinerja itu dilakukan secara manual dengan merubah salah satu komponen seperti menambahkan jumlah layer yang digunakan dari sebelumnya atau menambahkan filter agar lebih lebar dari sebelumnya atau resolusi citra masukan lebih tinggi. Dalam perubahan masing – masing komponen akan menambah waktu komputasi data lebih lama. Pada gambar 1 menunjukkan perbandingan jumlah layer yang digunakan pada beberapa arsitektu CNN



Gambar 1 Jumlah Layer

Arsitektur EfficientNet diklaim efisiensi dan kinerja yang lebih baik dari model sebelumnya disebabkan melakukan perubahan scaling dengan pengaturan kedalaman, resolusi dan lebar [15] yang membuat penambahan parameter tidak banyak sehingga waktu komputasi yang lebih cepat dengan kinerja yang lebih baik dari model sebelumnya. Pada gambar 1 terlihat ilustrasi dari Arsitektur EfficientNet.



Gambar 2 Arsitektur EfficientNet

2.2 Dataset

Motif batik dari Papua yang dijadikan dataset dalam penelitian ini terdiri atas empat kelas yang diklasifikasi menurut daerah asal pembuatan, corak budaya dan flora fauna yang digunakan sebagai motif batik. Motif batik dari Papua lainnya belum disertakan dalam penelitian ini karena untuk motif – motif tertentu membutuhkan pengetahuan atau pengalaman mengenal motif – motif tersebut. Motif batik dari Papua belum pernah ditemukan dalam penelitian – penelitian klasifikasi dengan mesin pembelajaran, sehingga penelitian ini diharapkan dapat mendorong terwujudnya klasifikasi motif batik dari Papua yang lebih komprehensif.

Motif batik Raja Ampat, motif batik Cendrawasih, Motif batik Asmat dan Motif Batik Tifa Honai yang masing – masing gambarnya diperoleh dari pencarian pada internet dan pengambilan foto peneliti sendiri di Kota Sorong, adapun jumlah gambar masing – masing kelas terlihat pada tabel 1 Dataset Batik.

Table 1 Pembagian Dataset

Motif Batik	Jumlah Data
Motif Batik Cendrawasih	43 gambar
Motif Batik Tifa Honai	52 gambar
Motif Batik Asmat	65 gambar
Motif Batik Raja Ampat	53 gambar

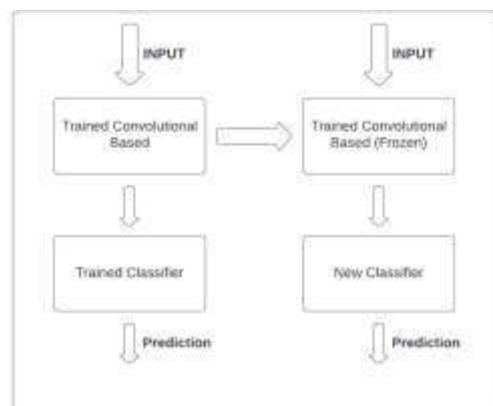
Gambar 3 Motif batik dari Papua memperlihatkan gambar – gambar motif dari kelas yang akan digunakan dalam penelitian.



Gambar 3 Motif Batik dari Papua

2.3 Transfer Learning

Transfer learning merupakan metode memanfaatkan model yang sudah dilatih sebelumnya untuk mengklasifikasi data yang baru[20], sehingga tidak harus melakukan training dari awal yang akan membutuhkan waktu proses yang lama. Melakukan transfer learning akan menjadikan proses pembelajaran data lebih efisien. Cara kerja dari transfer learning dengan tetap mempertahankan lapisan konvolusion dan pooling serta mengubah layer terakhir yang memuat nilai prediksi masing – masing kelas dalam bentuk array 1 dimensi yang dilakukan tuning menyesuaikan kelas pada dataset yang digunakan.

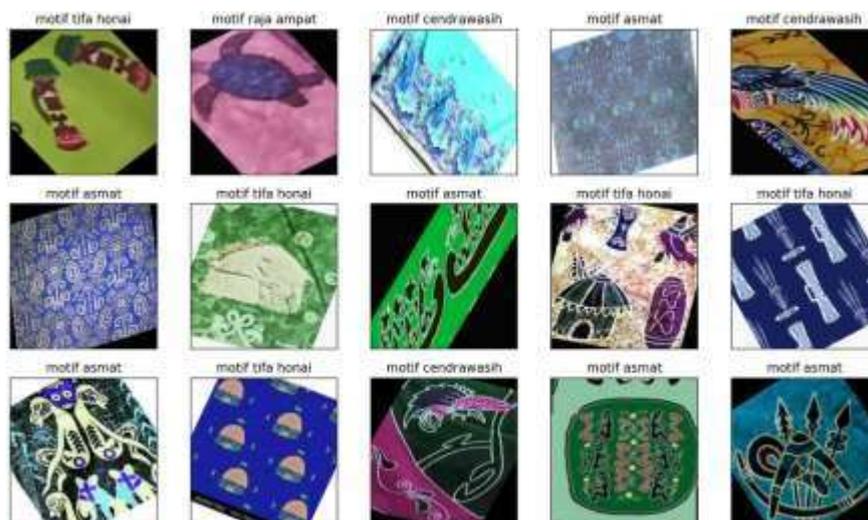


Gambar 4 Mengubah Layer Klasifikasi

Pada transfer learning, terjadinya overfitting pada pelatihan data baru dapat diminimalisir selama data baru memiliki kesamaan fitur dengan tugas sebelumnya yang datasetnya lebih besar daripada data baru.

2.4 Data Augmentation

Permasalahan ketersediaan data yang kecil akan menyebabkan terjadi overfitting sehingga data augmentasi dapat menjadi metode untuk peningkatan ukuran jumlah data dan kualitas pembelajaran pada dataset yang terbatas [8] Augmentasi data dapat menambahkan jumlah dataset dengan melakukan manipulasi gambar dengan berbagai teknik seperti merubah skala, memutar, berbalik, memotong, perubahan warna dengan merubah parameternya sebagaimana terlihat pada gambar 5.



Gambar 5 Hasil Proses Augmentasi Data

2.5 Metode yang diusulkan

Kami mengusulkan menggunakan arsitektur EfficientNet-B2 untuk mengklasifikasi motif batik dari Papua dengan menggunakan metode transfer learning dan menambahkan augmentasi data dalam trainingnya, dan akan membandingkan hasil akurasi yang diperoleh. Melatih arsitektur efficientNet menggunakan fine tuning dengan membekukan layer atas dan menggantikan layer klasifikasi yang sesuai dengan jumlah kelas yang digunakan.

Split dataset yang digunakan dengan komposisi 80% data latih sebanyak 169 gambar, 10% data validasi sebanyak 22 gambar dan 10% data test sebanyak 22 gambar. Dengan dataset yang tidak besar, diharapkan dengan teknik augmentasi yang akan digunakan membuat model tidak menjadi overfitting. Adapun teknik augmentasi yang dilakukan terlihat pada tabel 2 dibawah ini

Table 2 Nilai Parameter Operasi Augmentasi

Data Augmentation	Nilai
Resize Crop	Ukuran 200 x 150 skala 80%
Rotation	45
Color Jitter	Brightness = 40%, Contrast = 40%, saturation = 40%, Hue = 40%
Flip	Horizontal, Vertical
Grayscale	Random
Invert	Random
Affine	Degrees = 30, 70 translate = 0.1, 0.3 scale = 50% - 75%
Solarize	Random
Sharpned	Random
Contrast	Random
Grayscale	Random
Invert	Random
Posterize	Random

Pada penelitian ini juga dilakukan beberapa kombinasi operasi pada proses augmentasi. Pada **Table 3**, terlihat kombinasi augmentasi yang digunakan.

Table 3 Kombinasi Augmentasi

Keterangan	Kombinasi Augmentasi
Kombinasi I	Colorjitter, solarize, contrast
Kombinasi II	Resizecrop, flip, affine, rotation
Kombinasi III	Resizecrop, flip, rotation
Kombinasi IV	Flip, colorjitter
Kombinasi V	Colorjitter, contrast
Kombinasi VI	Invert, Grayscale, Solarize, Posterize, Contrast

3 HASIL PEMBAHASAN

Pada penelitian ini dilakukan beberapa pengujian model. Yang pertama, pengujian model dengan melakukan perbandingan antara model fine-tuning dan tanpa fine-tuning pada arsitektur efficientNet. Kedua model tersebut tanpa adanya penambahan proses augmentasi. Selanjutnya, pengujian model fine-tuning dengan menambahkan proses augmentasi. Dan terakhir adalah pengujian model fine-tuning dengan menambahkan proses kombinasi augmentasi pada dataset. Berikut adalah **Tabel 4**, hasil perbandingan model dengan menggunakan fine-tuning dan tanpa fine-tuning pada arsitektur EfficientNet.

Table 4 Hasil Akurasi pada EfficientNet Arsitektur

Keterangan	Accuracy %
Dengan Fine Tuning	72
Tanpa Fine Tuning	45

Dari dua model diatas, dapat dilihat bahwa model dengan menggunakan fine-tuning pada arsitektur EfficientNet menghasilkan nilai akurasi yang lebih baik bila dibandingkan dengan model tanpa proses fine-tuning. Kemudian, penelitian ini mencoba menambahkan proses augmentasi pada model fine-tuning EfficientNet. Penelitian ini membandingkan model fine-tuning dengan menambahkan masing-masing operasi proses augmentasi. Untuk hasil akurasinya dapat dilihat pada **Tabel 5**, dibawah ini

Table 5 Hasil Akurasi Fine-Tuning EfficientNet dengan proses Augmentasi

No	Operasi Augmentasi	Accuracy (%)
1	Colorjitter	90
2	Contrast	90
3	Flip	86
4	Invert	86
5	Posterize	86
6	Grayscale	81
7	Resizecrop	86
8	Rotation	72
9	Sharpness	72
10	Solarize	81

Dari beberapa percobaan yang dilakukan terhadap tiap operasi pada proses augmentasi, dapat terlihat bahwa model fine-tuning arsitektur efficientNet dengan menambahkan proses augmentasi *colorjitter* ataupun *contrast* dapat menaikkan akurasi hingga 90%. Adapun hasil akurasi terbaik berikutnya terdapat pada operasi *flip*, *invert* dan *posterize* dengan nilai akurasi yang dicapai sebesar 86%.

Selanjutnya masih dengan menggunakan model fine-tuning, berikut adalah **Table 6**, terkait nilai akurasi yang dihasilkan dari kombinasi augmentasi yang telah disebutkan pada tabel sebelumnya

Table 6 Hasil Akurasi kombinasi Augmentasi

Kombinasi Augmentasi	Accuracy %
Kombinasi I	86
Kombinasi II	72
Kombinasi III	81
Kombinasi IV	86
Kombinasi V	86
Kombinasi VI	72

Dari percobaan kombinasi augmentasi yang ditambahkan pada model fine-tuning, didapatkan kombinasi I (*colorjitter*, *solarize*, *contrast*), kombinasi IV (*flip*, *colorjitter*), dan kombinasi V (*colorjitter*, *contrast*) memiliki akurasi yang terbaik sebesar 86% dibandingkan dengan nilai akurasi yang didapatkan dari kombinasi lainnya.

Dari keseluruhan model yang telah dibuat diatas, terlihat model yang menghasilkan nilai akurasi terbaik adalah model fine-tuning dengan menambahkan proses augmentation contrast atau colorjitter. Nilai akurasi yang dihasilkan sebesar pada dataset sebesar 90%. Dimana pada pengujian menggunakan data testing, nilai akurasi yang didapatkan dari masing-,masing kedua model tersebut dapat lihat pada Tabel 7 berikut.

Table 7 Hasil Akurasi Data Testing

Keterangan	Accuracy %
Model fine-tuning dengan augmentasi contrast	86.36%
Model fine-tuning dengan augmentasi colorjitter	86.36%

Kedua model tersebut juga menghasilkan nilai akurasi yang sama sebesar 86.36% pada data testing.

Perbandingan akurasi validasi atas teknik augmentation data yang memberikan akurasi tertinggi atas penelitian – penelitian klasifikasi batik sebelumnya dapat terlihat pada Tabel 8 Perbandingan Penelitian sebelumnya.

Table 8 Perbandingan Analisis Akurasi terhadap penelitian sebelumnya

Jumlah Dataset dan Class	Arsitektur	Data Augmentation	Accuracy %
500 gambar, 5 class [10]	VGG16	Width shift	97,92
		Zoom	
900 gambar, 5 class[9]	VGG19	Scaled 1.2	88,00
900 gambar, 5 class[9]	VGG16	Rotated 180	86,00
2092 gambar, 7 class[21]	Resnet50	Flip	81,90
2092 gambar, 7 class[21]	Resnet18	Random Erase	84,52
213 dataset, 4 class	EfficientNet-B2	Colorjitter	90,00
		Contrast	

4 KESIMPULAN

Dalam penelitian ini dilakukan analisis perbandingan performa arsitektur transfer learning, yaitu EfficientNet dengan menggunakan fine-tuning serta dengan menambahkan proses augmentasi pada setiap percobaan. Dari setiap percobaan yang dilakukan, didapatkan model dengan proses augmentasi contrast atau colorjitter melalui fine-tuning memiliki akurasi yang paling tinggi, sebesar 86.3%

5 SARAN

Selain mengumpulkan dataset motif batik dari Papua yang beragam menjadi tandatangan dalam menyediakan data yang besar, bentuk motif yang cenderung dominan nongeometric menjadi tantangan lain dalam menemukan model dengan kinerja baik.

6. REFERENSI

- [1] V. Marthen and I. Mambraku, "Motif Ragam Hias Batik Pada Ruang Publik," 2014.
- [2] A. P. Azhari and P. Sulistiyawati, "Perancangan Motif Batik Papua Dengan Karakter Burung," *Citrakara*, vol. 01, pp. 1–12, 2019.
- [3] I. Nurhaida, R. Manurung, and A. M. Arymurthy, "Performance comparison analysis features extraction methods for Batik recognition," *2012 Int. Conf. Adv. Comput. Sci. Inf. Syst. ICACSIS 2012 - Proc.*, pp. 207–212, 2012.
- [4] A. E. Minarno, A. S. Maulani, A. Kurniawardhani, F. Bimantoro, and N. Suciati, "Comparison of methods for Batik classification using multi texton histogram," *Telkomnika (Telecommunication Comput. Electron. Control.*, vol. 16, no. 3, pp. 1358–1366, 2018, doi: 10.12928/TELKOMNIKA.v16i3.7376.
- [5] A. A. Kasim, R. Wardoyo, and A. Harjoko, "Batik classification with artificial neural network based on texture-shape feature of main ornament," *Int. J. Intell. Syst. Appl.*, vol. 9, no. 6, pp. 55–65, 2017, doi: 10.5815/ijisa.2017.06.06.
- [6] A. E. Minarno, "Klasifikasi Jenis Batik Menggunakan Algoritma Convolutional Neural Network," *J. Repos.*, vol. 3, no. 2, pp. 199–206, 2021, doi: 10.22219/repositor.v3i2.1201.
- [7] A. Y. Wicaksono, N. Suciati, C. Fatichah, K. Uchimura, and G. Koutaki, "Modified Convolutional Neural Network Architecture for Batik Motif Image Classification," *IPTEK J. Sci.*, vol. 2, no. 2, pp. 26–30, 2017, doi: 10.12962/j23378530.v2i2.a2846.
- [8] C. Shorten and T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," *J. Big Data*, vol. 6, no. 1, 2019, doi: 10.1186/s40537-019-0197-0.
- [9] I. M. A. Agastya and A. Setyanto, "Classification of Indonesian batik using deep learning techniques and data augmentation," *Proc. - 2018 3rd Int. Conf. Inf. Technol. Inf. Syst. Electr. Eng. ICITISEE 2018*, pp. 27–31, 2018, doi: 10.1109/ICITISEE.2018.8720990.
- [10] C. U. Khasanah, E. Utami, and S. Raharjo, "Implementation of Data Augmentation Using Convolutional Neural Network for Batik Classification," *2020 8th Int. Conf. Cyber IT Serv. Manag. CITSM 2020*, pp. 20–24, 2020, doi: 10.1109/CITSM50537.2020.9268890.
- [11] B. S. Negara, E. Satria, S. Sanjaya, and D. R. Dwi Santoso, "ResNet-50 for Classifying Indonesian Batik with Data Augmentation," *2021 Int. Congr. Adv. Technol. Eng. ICOTEN 2021*, pp. 7–10, 2021, doi: 10.1109/ICOTEN52080.2021.9493488.
- [12] H. C. Shin *et al.*, "Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning," *IEEE Trans. Med. Imaging*, vol. 35, no. 5, pp. 1285–1298, 2016, doi: 10.1109/TMI.2016.2528162.
- [13] D. M. Wonohadidjojo, "Perbandingan Convolutional Neural Network pada Transfer Learning Method untuk Mengklasifikasikan Sel Darah Putih," *Ultim. J. Tek. Inform.*, vol. 13, no. 1, pp. 51–57, 2021, doi: 10.31937/ti.v13i1.2040.
- [14] F. A. Putra *et al.*, "Classification of Batik Authenticity Using Convolutional Neural Network Algorithm with Transfer Learning Method," pp. 1–6, 2021, doi: 10.1109/itic54025.2021.9632937.
- [15] T. Mingxing and V. Le Quoc, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks Mingxing," *Can. J. Emerg. Med.*, vol. 15, no. 3, p. 190, 2013, doi: 10.2310/8000.2013.131108.
- [16] A. Zhaputri, M. Hayaty, and A. D. Laksito, "Classification of Brain Tumour Mri Images Using Efficient Network," *ICOIACT 2021 - 4th Int. Conf. Inf. Commun. Technol. Role AI Heal. Soc. Revolut. Turbul. Era*, pp. 108–113, 2021, doi: 10.1109/ICOIACT53268.2021.9563922.
- [17] A. G. Howard *et al.*, "MobileNets: Efficient convolutional neural networks for mobile vision applications," *arXiv*, 2017.
- [18] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 4510–4520, 2018, doi: 10.1109/CVPR.2018.00474.
- [19] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 770–778, 2016, doi: 10.1109/CVPR.2016.90.
- [20] F. Zhuang *et al.*, "A comprehensive survey on transfer learning," *arXiv*, 2019.

- [21] S. F. Tumewu, D. H. Setiabud, and I. Sugiarto, "Klasifikasi Motif Batik menggunakan metode Deep Convolutional Neural Network dengan Data Augmentation," *J. Infra*, vol. 8, no. 2, pp. 189–194, 2020.
-