

Pengaruh *Learning Rate* dan Regularisasi pada Kinerja ResNet50 untuk Klasifikasi Motif Kain Tenun Palembang

¹Hadiguna Setiawan, ²Sri Dianing Asri

^{1,2}Fakultas Teknik dan Informatika, Universitas Dian Nusantara

¹hadiguna.setiawan@dosen.undira.ac.id, ²sri.dianing.asri@undira.ac.id

Article Info

Article history:

Received, 2026-06-23

Revised, 2026-07-04

Accepted, 2026-07-13

Kata Kunci:

ResNet50,
transfer learning,
learning rate,
regularisasi,
Tenun Palembang

ABSTRAK

Kain Tenun Palembang merupakan salah satu warisan budaya Indonesia yang memiliki beragam motif dengan karakteristik visual yang khas sehingga memerlukan metode identifikasi yang akurat untuk mendukung pelestarian dan digitalisasi budaya. Penelitian ini bertujuan menganalisis pengaruh variasi learning rate dan teknik regularisasi terhadap performa model ResNet50 berbasis transfer learning dalam mengklasifikasikan motif Kain Tenun Palembang. Dataset yang digunakan terdiri atas 800 citra dari delapan kelas motif dengan pembagian data 70% untuk pelatihan, 15% untuk validasi, dan 15% untuk pengujian. Seluruh citra melalui tahap preprocessing berupa resize menjadi 224×224 piksel dan normalisasi. Model dilatih menggunakan optimizer Adam selama 50 epoch dengan tiga variasi learning rate (0,01; 0,001; dan 0,0001) serta dua teknik regularisasi, yaitu L2 Regularization dan Dropout. Evaluasi dilakukan menggunakan metrik Accuracy, Precision, Recall, dan F1-Score serta analisis kurva pelatihan untuk mengamati proses konvergensi model. Hasil penelitian menunjukkan bahwa kombinasi learning rate dan teknik regularisasi memberikan pengaruh terhadap performa klasifikasi. Konfigurasi terbaik diperoleh pada learning rate 0,001 dengan teknik Dropout yang menghasilkan train accuracy sebesar 99,11%, validation accuracy 96,67%, dan test accuracy 95,83%, lebih tinggi dibandingkan konfigurasi lainnya.

Keywords:

ResNet50,
transfer learning,
learning rate,
regularization,
Tenun Palembang

ABSTRACT

Palembang woven fabric is one of Indonesia's cultural heritages, characterized by diverse motifs with distinctive visual patterns that require accurate identification methods to support cultural preservation and digitalization. This study aims to analyze the effect of learning rate and regularization techniques on the performance of a transfer learning-based ResNet50 model for Palembang woven fabric motif classification. The dataset consisted of 800 images representing eight motif classes, divided into 70% training, 15% validation, and 15% testing sets. All images underwent preprocessing, including resizing to 224×224 pixels and normalization. The ResNet50 model was trained using the Adam optimizer for 50 epochs with three learning rates (0.01, 0.001, and 0.0001) and two regularization techniques, namely L2 Regularization and Dropout. Model performance was evaluated using Accuracy, Precision, Recall, and F1-Score, while training and validation curves were analyzed to assess model convergence. The experimental results demonstrate that both learning rate and regularization techniques significantly influence classification performance. The best performance was achieved using a learning rate of 0.001 with Dropout, resulting in a training accuracy of 99.11%, validation accuracy of 96.67%, and testing accuracy of 95.83%, outperforming all other configurations.

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



Penulis Korespondensi:

Hadiguna Setiawan
Fakultas Teknik dan Informatika
Universitas Dian Nusantara, Indonesia
Email: hadiguna.setiawan@dosen.undira.ac.id

1. PENDAHULUAN

Kain Tenun Palembang merupakan salah satu warisan budaya Indonesia yang memiliki nilai seni, sejarah, dan ekonomi yang tinggi [1], [2]. Setiap motif pada kain Tenun Palembang memiliki karakteristik visual yang berbeda, seperti pola geometris, bentuk floral, serta ornamen khas yang merepresentasikan filosofi budaya masyarakat Sumatera Selatan [3], [4]. Seiring berkembangnya teknologi digital, dokumentasi dan identifikasi motif kain secara otomatis menjadi penting untuk mendukung pelestarian budaya, digitalisasi koleksi, pengembangan katalog digital, serta membantu proses pengenalan motif pada industri kreatif dan perdagangan Tekstil [5].

Klasifikasi citra berbasis *deep learning* telah menjadi salah satu pendekatan yang banyak digunakan dalam pengenalan objek karena mampu mengekstraksi fitur secara otomatis tanpa memerlukan proses *feature engineering* secara manual [6], [7], [8], [9]. Salah satu arsitektur *Convolutional Neural Network* (CNN) yang banyak digunakan adalah ResNet50, yang memanfaatkan mekanisme *residual learning* untuk mengatasi permasalahan *vanishing gradient* sehingga mampu membangun jaringan yang lebih dalam dengan performa klasifikasi yang tinggi. Selain itu, penerapan *transfer learning* pada ResNet50 memungkinkan model memanfaatkan bobot awal yang telah dilatih menggunakan dataset ImageNet sehingga proses pelatihan menjadi lebih efisien, terutama ketika jumlah data relatif terbatas.

Meskipun demikian, performa model ResNet50 sangat dipengaruhi oleh pemilihan parameter selama proses pelatihan. Salah satu parameter yang memiliki peran penting adalah *learning rate*, yang menentukan besar kecilnya langkah pembaruan bobot pada setiap iterasi optimasi. Nilai *learning rate* yang terlalu besar dapat menyebabkan proses pelatihan menjadi tidak stabil dan gagal mencapai titik konvergensi, sedangkan nilai yang terlalu kecil mengakibatkan proses pembelajaran berjalan lambat dan berpotensi terjebak pada solusi yang kurang optimal [10].


Selain *learning rate*, teknik regularisasi juga berperan penting dalam meningkatkan kemampuan generalisasi model. Model *deep learning* dengan jumlah parameter yang besar rentan mengalami *overfitting*, yaitu kondisi ketika model mampu mengenali data pelatihan dengan sangat baik namun mengalami penurunan performa pada data baru. Dua teknik regularisasi yang banyak digunakan adalah L2 Regularization dan Dropout [11].

Beberapa penelitian terdahulu telah menunjukkan bahwa *Convolutional Neural Network* (CNN) efektif digunakan untuk klasifikasi motif kain tenun. Santoso dan Defit (2024) menerapkan CNN untuk mengklasifikasikan pola kain Tenun Melayu dan menunjukkan bahwa pendekatan *deep learning* mampu mengenali karakteristik visual setiap motif [12]. Kumala dkk. (2023) menggunakan CNN untuk mengklasifikasikan pola motif kain Tenun Bumpak Desa Kampai Seluma dan memperoleh hasil yang baik dalam membedakan berbagai motif tenun berdasarkan citra [13]. Selanjutnya, Baso dan Huda (2025) mengembangkan model CNN-Support Vector Machine (SVM) untuk klasifikasi jenis Tenun Timor, yang memanfaatkan CNN sebagai pengekstraksi fitur dan SVM sebagai pengklasifikasi sehingga meningkatkan kemampuan klasifikasi [14]. Sementara itu, Dabbo dan Bisilisin (2024) menerapkan CNN berbasis citra untuk klasifikasi motif kain Tenun Sabu Raijua dan menunjukkan bahwa metode *deep learning* mampu mengidentifikasi motif tenun dengan karakteristik geometris, flora, dan fauna [15]. Meskipun berbagai penelitian tersebut telah membuktikan keberhasilan CNN dalam klasifikasi motif kain tenun, kajian mengenai pengaruh konfigurasi parameter, khususnya variasi *learning rate* dan teknik regularisasi pada model ResNet50 berbasis *transfer learning* untuk klasifikasi motif Kain Tenun Palembang, masih relatif terbatas. Oleh karena itu, penelitian ini melakukan analisis pengaruh kedua faktor tersebut terhadap performa model guna memperoleh konfigurasi yang menghasilkan kemampuan generalisasi terbaik.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk menganalisis pengaruh variasi *learning rate* (0,01; 0,001; dan 0,0001) serta teknik regularisasi (L2 Regularization dan Dropout) terhadap kinerja model ResNet50 berbasis *transfer learning* dalam mengklasifikasikan motif Kain Tenun Palembang. Evaluasi dilakukan menggunakan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score*, serta analisis kurva pelatihan untuk mengamati proses konvergensi model. Hasil penelitian ini diharapkan dapat memberikan rekomendasi konfigurasi parameter yang optimal sehingga meningkatkan akurasi klasifikasi sekaligus menjadi referensi dalam pengembangan sistem pengenalan motif kain tradisional berbasis kecerdasan buatan.

2. METODE PENELITIAN

Penelitian ini menggunakan dataset motif Tenun Palembang sebanyak 800 citra yang terdiri dari 8 kelas, dengan pembagian data 70% training, 15% validation, dan 15% testing, serta dilakukan pra-pemrosesan berupa resize 224×224 piksel, normalisasi. Model ResNet50 berbasis *transfer learning* dilatih menggunakan optimizer Adam selama 50 epoch dengan variasi *learning rate* (0,01; 0,001; 0,0001) dan teknik regularisasi (L2 Regularization dan Dropout). Adapun alur penelitian dapat dilihat pada **Gambar 1**.



Gambar 1 Alur Penelitian


Penelitian ini menggunakan dataset citra motif Tenun Palembang yang terdiri atas 800 citra dari 8 kelas motif, yaitu Bintang Melati, Bunga Bintang, Bunga Mawar, Kucing Tidur, Naga Besaung, Pucuk Rebung Balai Anak, Pucuk Rebung Penuh, dan Tampuk Manggis, dengan masing-masing kelas berjumlah 100 citra. Dataset dibagi menjadi 70% data training, 15% data validation, dan 15% data testing, sehingga diperoleh 560 citra untuk pelatihan, 120 citra untuk validasi, dan 120 citra untuk pengujian. Sebelum pelatihan, seluruh citra melalui tahap prapemrosesan berupa resize menjadi 224×224 piksel, dan normalisasi.

Model yang digunakan adalah ResNet50 berbasis transfer learning dengan bobot awal dari ImageNet. Arsitektur model dimodifikasi dengan menambahkan Global Average Pooling, Fully Connected Layer, teknik regularisasi, dan lapisan Softmax sebagai klasifikasi delapan kelas. Pengujian dilakukan menggunakan tiga nilai learning rate, yaitu 0,01, 0,001, dan 0,0001, serta dua teknik regularisasi, yaitu L2 Regularization dan Dropout, sehingga diperoleh enam kombinasi eksperimen. Seluruh model dilatih menggunakan optimizer Adam, batch size 32, dengan jumlah 50 epoch.

Evaluasi model dilakukan menggunakan data testing dengan metrik Accuracy, Precision, Recall, dan F1-Score. Selain itu, performa pelatihan dianalisis melalui grafik training accuracy, validation accuracy, training loss, dan validation loss untuk mengamati proses konvergensi model serta mendeteksi overfitting atau underfitting. Hasil dari setiap kombinasi learning rate dan teknik regularisasi kemudian dibandingkan untuk menentukan konfigurasi terbaik pada klasifikasi motif Tenun Palembang.


3. HASIL DAN ANALISIS

Pada eksperimen pertama, model ResNet50 diuji menggunakan learning rate 0,01 dengan teknik L2 Regularization. Hasil pelatihan menunjukkan train accuracy sebesar 95,18%, sedangkan validation accuracy dan test accuracy masing-masing mencapai 88,33% dan 87,50%. Selisih yang cukup besar antara akurasi pelatihan dan pengujian menunjukkan bahwa model mampu mempelajari data latih dengan baik, namun kemampuan generalisasinya masih terbatas, seperti yang terlihat pada **Gambar 2**.




Gambar 2. Eksperimen dengan LR 0.01

Pada eksperimen kedua, model ResNet50 diuji menggunakan learning rate 0,001 dengan dua teknik regularisasi, yaitu L2 Regularization dan Dropout. Penggunaan L2 Regularization menghasilkan train accuracy sebesar 98,21%, validation accuracy 94,17%, dan test accuracy 93,33%, sedangkan penerapan Dropout meningkatkan kinerja model menjadi 99,11% pada train accuracy, 96,67% pada validation accuracy, dan 95,83% pada test accuracy. Hasil ini menunjukkan bahwa learning rate 0,001 memberikan proses pembelajaran yang lebih stabil dibandingkan eksperimen pertama, seperti yang terlihat pada **Gambar 3**.



Gambar 3. Eksperimen dengan LR 0,001

Pada eksperimen ketiga, model ResNet50 diuji menggunakan learning rate 0,0001 dengan teknik L2 Regularization dan Dropout. Penggunaan L2 Regularization menghasilkan train accuracy sebesar 96,96%, validation accuracy 93,33%, dan test accuracy 92,50%, sedangkan Dropout memberikan peningkatan performa dengan train accuracy 97,68%, validation accuracy 94,17%, dan test accuracy 93,33%. Hasil tersebut menunjukkan bahwa learning rate 0,0001 mampu menghasilkan proses pelatihan yang stabil, seperti pada **Gambar 4**.



Gambar 4. Eksperimen dengan LR 0,0001

Berdasarkan hasil pengujian, kombinasi learning rate dan teknik regularisasi memberikan pengaruh terhadap performa model ResNet50 dalam mengklasifikasikan motif Tenun Palembang. Berdasarkan hasil pengujian, kombinasi learning rate dan teknik regularisasi berpengaruh terhadap performa model ResNet50, di mana learning rate 0,001 menghasilkan kinerja terbaik dibandingkan 0,01 dan 0,0001. Hasil lengkap dari eksperimen dapat dilihat pada **Tabel 1**.

Tabel 1. Hasil Eksperimen Learning Rate dan Regularisasi pada Model ResNet50

Learning Rate	Regularisasi	Train Accuracy (%)	Validation Accuracy (%)	Test Accuracy (%)
0,01	L2	95,18	88,33	87,50
0,01	Dropout	93,75	89,17	88,33
0,001	L2	98,21	94,17	93,33
0,001	Dropout	99,11	96,67	95,83
0,0001	L2	96,96	93,33	92,50
0,0001	Dropout	97,68	94,17	93,33

Pada learning rate 0,01, model menghasilkan akurasi pengujian sebesar 87,50% dengan L2 Regularization dan 88,33% dengan Dropout, yang menunjukkan bahwa nilai learning rate yang terlalu besar belum mampu menghasilkan konvergensi yang optimal. Ketika learning rate diturunkan menjadi 0,001, performa model meningkat secara signifikan, dengan L2 Regularization memperoleh test accuracy 93,33%, sedangkan Dropout mencapai hasil terbaik dengan train accuracy 99,11%, validation accuracy 96,67%, dan

test accuracy 95,83%. Sementara itu, pada learning rate 0,0001, model masih menunjukkan performa yang baik, yaitu 92,50% menggunakan L2 Regularization dan 93,33% menggunakan Dropout, namun sedikit lebih rendah dibandingkan learning rate 0,001 karena proses pembelajaran yang lebih lambat.

4. KESIMPULAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa variasi *learning rate* dan teknik regularisasi memberikan pengaruh terhadap performa model ResNet50 berbasis *transfer learning* dalam mengklasifikasikan motif Kain Tenun Palembang. Nilai *learning rate* yang terlalu besar (0,01) menghasilkan proses konvergensi yang kurang optimal sehingga akurasi pengujian masih relatif rendah, sedangkan *learning rate* yang terlalu kecil (0,0001) mampu menghasilkan pelatihan yang stabil, namun memerlukan proses pembelajaran yang lebih lambat. Konfigurasi terbaik diperoleh pada *learning rate* 0,001 dengan teknik Dropout, yang menghasilkan *train accuracy* sebesar 99,11%, *validation accuracy* 96,67%, dan *test accuracy* 95,83%, sehingga menunjukkan kemampuan generalisasi model yang lebih baik dibandingkan kombinasi parameter lainnya. Hasil penelitian ini menunjukkan bahwa pemilihan *learning rate* yang tepat serta penerapan teknik regularisasi Dropout berperan penting dalam meningkatkan performa klasifikasi citra berbasis ResNet50.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Lembaga Riset dan Pengabdian kepada Masyarakat (LRPM) Universitas Dian Nusantara (UNDIRA) atas dukungan pendanaan yang diberikan melalui skema Penelitian Internal sehingga penelitian ini dapat terlaksana dengan baik. Penulis juga menyampaikan apresiasi kepada Dr. Handrie Noprisson, S.T., M.Kom yang telah menyediakan dataset motif Kain Tenun Palembang serta memberikan dukungan dalam pelaksanaan penelitian ini.

REFERENSI

- [1] 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)*, IEEE, 2021, pp. 90–95.
- [2] 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, doi: <http://doi.org/10.24507/ijicic.18.06.1885>.
- [3] M. Mauladi and D. Hermanto, "Klasifikasi Motif Kain Jumputan Palembang Menggunakan Metode CNN dengan Arsitektur Resnet-50," *Arcitech J. Comput. Sci. Artif. Intell.*, vol. 5, no. 2, pp. 332–355, 2025.
- [4] I. D. Cahyati, S. Devella, and Y. Yohannes, "Pengenalan Motif Songket Palembang Menggunakan Convolutional Neural Network dengan Arsitektur ResNet-50," *Algoritma. J. Mhs. Tek. Inform.*, vol. 5, no. 1, pp. 78–87, 2024.
- [5] E. Asoka, H. Meileni, Y. Hapsari, I. Satriadi, N. Jumriatunnisah, and R. K. Laday, "Pendampingan Digitalisasi Pemasaran Songket Berbasis E-Commerce dan Media Sosial," *Cahaya Pengabdian*, vol. 3, no. 1, pp. 32–39, 2026.
- [6] V. Ayumi, H. Noprisson, and N. Ani, "Forest Fire Detection Using Transfer Learning Model with Contrast Enhancement and Data Augmentation," *J. Nas. Pendidik. Tek. Inform. JANAPATI*, vol. 13, no. 1, 2024.
- [7] V. Ayumi, "Perbandingan Model Transfer Learning Untuk Klasifikasi Citra Agricultural Crop," *JSAI (Journal Sci. Appl. Informatics)*, vol. 5, no. 3, pp. 214–222, 2022.
- [8] 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, doi: [10.14569/IJACSA.2022.0130917](https://doi.org/10.14569/IJACSA.2022.0130917).
- [9] H. Noprisson, V. Ayumi, M. Purba, and N. Ani, "Mobilenet Performance Improvements for Deepfake Image Identification Using Activation Function and Regularization," *JITK (Jurnal Ilmu Pengetah. dan Teknol. Komputer)*, vol. 10, no. 2, pp. 441–448, 2024.
- [10] R. Sharma and A. Singh, "VGG16 feature selection using PCA-big bang big algorithm," *J. Intell. Fuzzy Syst.*, pp. 1–15, 2023, doi: [10.3233/jifs-222517](https://doi.org/10.3233/jifs-222517).
- [11] Z. Farhadi, H. Bevrani, and M.-R. Feizi-Derakhshi, "Combining regularization and dropout techniques for deep convolutional neural network," in *2022 global energy conference (GEC)*, IEEE, 2022, pp. 335–339.

- [12] M. Santoso and S. Defit, "Penerapan Convolutional Neural Network pada Klasifikasi Citra Pola Kain Tenun Melayu," *J. CoSciTech (Computer Sci. Inf. Technol.*, vol. 5, no. 1, pp. 177–184, 2024.
- [13] R. Kumala, D. Diana, Y. Darmi, and N. D. M. Veronika, "Klasifikasi Pola Motif Kain Tenun Bumpak Desa Kampai Seluma Menggunakan Metode Convolutational Neural Network (CNN)," *REMIK Ris. dan E-Jurnal Manaj. Inform. Komput.*, vol. 7, no. 4, pp. 1917–1927, 2023.
- [14] B. Baso and N. Huda, "Hybrid Algoritma Convolutional Neural Network dengan Support Vector Machine untuk Klasifikasi Jenis Tenun Timor," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 12, no. 6, pp. 1233–1242, 2025.
- [15] P. Dabbo and F. Y. Bisilisin, "Klasifikasi Motif Kain Tenun Sabu Rajjua Menggunakan Convolutional Neural Network (CNN) Berbasis Citra," *KETIK J. Inform.*, vol. 1, no. 06, pp. 11–18, 2024.