

Klasifikasi Jenis Tari Bali Menggunakan Hyperparameter Tuning CNN dan Transfer Learning ResNet18

I Gede Surya Diva Ananda^{a1}, Ida Ayu Gde Suwiprabayanti Putra^{a2}, Ida Bagus Gede Sarasvananda^{a3}

^aProgram Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Udayana
Jalan Raya Kampus Udayana, Bukit Jimbaran, Kuta Selatan, Badung, Bali, Indonesia

¹ananda.2308561090@student.unud.ac.id

²iagsuwiprabayantiputra@unud.ac.id

³sarasvananda@unud.ac.id

Abstract

Balinese dance is a cultural heritage that carries deep philosophical and historical values. In the field of computer vision, image classification of Balinese dance poses a unique challenge due to similarities in movement patterns, costumes, and backgrounds. This research compares two approaches to Balinese dance image classification: a Convolutional Neural Network (CNN) model enhanced with hyperparameter tuning via grid search, and a transfer learning model based on ResNet18. The dataset consists of seven dance classes, each with approximately 240 to 254 images, which are balanced to ensure fair evaluation. The CNN model's hyperparameters, including learning rate, dropout rate, batch size, and optimizer, were optimized using grid search, achieving a top training accuracy of 96.51% and validation accuracy of 72.30%. Meanwhile, the ResNet18 model, leveraging transfer learning from ImageNet, outperformed with a training accuracy of perfect 100% and a validation accuracy of 96.79%. The experimental results suggest that transfer learning significantly boosts performance compared to CNNs trained from scratch, even when carefully tuned. These findings highlight the practical advantage of leveraging pre-trained models in cultural heritage preservation tasks through computer vision.

Keywords: Balinese dance, Image classification, CNN, Hyperparameter tuning, Grid search, Transfer learning, ResNet18

1. Pendahuluan

Indonesia merupakan negara yang terkenal akan keragaman suku dan budaya yang melahirkan berbagai bentuk warisan budaya takbenda, salah satunya adalah seni tari. Di antara ribuan tradisi tari yang ada, tarian Bali memegang posisi istimewa dengan keunikan dan makna filosofis yang mendalam. Tujuh di antara tarian tersebut yakni tari Baris, Barong, Condong, Janger, Kecak, Pendet, dan Rejang Sari, tarian tersebut merepresentasikan spektrum luas dari narasi ritual, penyambutan, hingga drama tari yang menjadi identitas budaya masyarakat Bali. Namun, di tengah era globalisasi dan kemajuan teknologi digital, upaya pelestarian dan pewarisan seni tari tradisional menghadapi tantangan signifikan, terutama dalam hal dokumentasi dan edukasi kepada generasi muda [1].

Perkembangan teknologi khususnya pada bidang kecerdasan buatan (*Artificial Intelligence*) dan penglihatan komputer (*Computer Vision*) menawarkan solusi inovatif untuk mengatasi tantangan tersebut. Pemanfaatan teknologi digital tidak hanya memungkinkan dokumentasi warisan budaya dalam format yang lebih modern dan mudah diakses, tetapi juga membuka peluang untuk pengenalan dan klasifikasi otomatis [2]. Klasifikasi citra tari secara otomatis menjadi sebuah tugas yang relevan namun menantang. Hal ini disebabkan oleh beberapa faktor seperti kemiripan visual pada kostum dan tata rias, variasi dalam pose dan gerakan antar penari, serta kondisi pencahayaan yang beragam saat pementasan. Oleh karena itu, diperlukan sebuah sistem cerdas

yang mampu mengenali dan membedakan berbagai jenis tarian secara akurat berdasarkan citra visual.

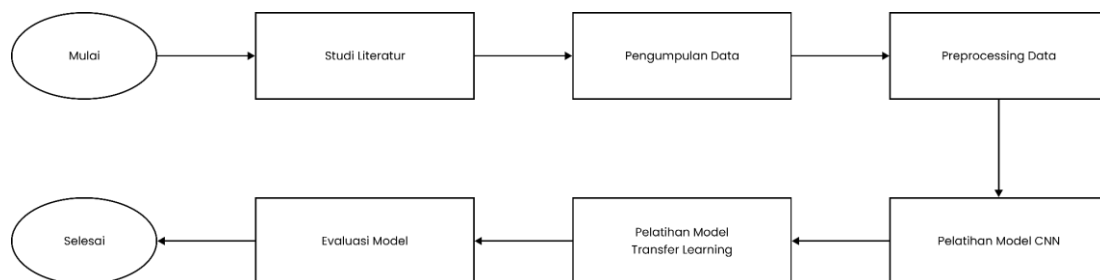
Deep learning sebagai salah satu cabang dari *machine learning* telah menunjukkan kinerja yang luar biasa dalam berbagai tugas klasifikasi citra. Salah satu arsitektur yang paling populer dan efektif adalah *Convolutional Neural Network* (CNN). CNN merupakan salah satu metode *Deep Learning* yang sering digunakan untuk pengolahan citra. Tujuan utama dari metode ini adalah untuk mengekstraksi fitur dari citra masukan secara otomatis. Proses ini sangat terinspirasi dari cara kerja *visual cortex* pada manusia, yang memiliki kemampuan untuk mengolah informasi dari sebuah citra [3]. Kemampuan ini menjadikan CNN sebagai kandidat utama untuk membangun model klasifikasi tari Bali.

Di sisi lain, melatih model CNN dari awal (*from scratch*) seringkali membutuhkan *dataset* yang sangat besar dan sumber daya komputasi yang intensif untuk mencapai performa yang optimal. Sebagai alternatif, teknik *transfer learning* hadir sebagai pendekatan yang efisien. *Transfer learning* adalah metode yang menggunakan sebuah *network* yang sudah dilatih sebelumnya sebagai titik awal untuk mempelajari tugas baru [4]. Arsitektur seperti ResNet (*Residual Network*) telah terbukti sangat efektif dalam pendekatan *transfer learning* karena kemampuannya untuk melatih jaringan yang sangat dalam tanpa mengalami masalah *vanishing gradient*, sehingga mampu menangkap fitur yang lebih kaya dan kompleks [5].

Oleh karena itu, penelitian ini bertujuan untuk membangun dan mengevaluasi sistem klasifikasi citra untuk tujuh tarian tradisional Bali. Studi ini melakukan analisis komparatif antara dua pendekatan utama, pertama adalah membangun model CNN dari awal yang dioptimalkan melalui *hyperparameter tuning*, dan kedua adalah mengimplementasikan metode *transfer learning* menggunakan arsitektur ResNet18. Perbandingan ini akan memberikan wawasan mendalam mengenai efektivitas, akurasi, dan efisiensi masing-masing metode dalam konteks pelestarian budaya digital, khususnya untuk klasifikasi citra tari Bali.

2. Metode Penelitian

2.1. Tahapan Penelitian



Gambar 1. Tahapan Penelitian

Tahapan penelitian ini dirancang mengikuti alur sistematis yang diilustrasikan pada Gambar 1. Tahap fundamental penelitian diawali dengan studi literatur untuk mendalami konsep klasifikasi citra menggunakan CNN dan *transfer learning*. Berdasarkan landasan teori tersebut, dilakukan pengumpulan *dataset* yang terdiri dari citra tujuh jenis tari Bali yang berhasil ditemukan pada situs kaggle. Sebelum digunakan, seluruh data mentah melewati tahap *preprocessing* yang mencakup penyeragaman ukuran citra (*resize*), serta normalisasi nilai piksel untuk mengoptimalkan dan menstabilkan proses pelatihan model.

Setelah data siap, penelitian memasuki tahap inti yaitu pelatihan dan eksperimen model yang terbagi menjadi dua. Skenario pertama adalah pengembangan model *Convolutional Neural Network* (CNN) dari awal. Dalam skenario ini, dilakukan pencarian *hyperparameter* secara ekstensif menggunakan metode *Grid Search* untuk menemukan arsitektur dan konfigurasi pelatihan yang paling efektif. Skenario kedua adalah implementasi metode *transfer learning*

dengan memanfaatkan arsitektur ResNet18 yang telah teruji. Pada skenario ini, dilakukan proses *fine-tuning*, di mana bobot dari model yang sudah terlatih pada dataset ImageNet diadaptasi untuk tugas klasifikasi citra tari Bali dengan melatih ulang lapisan terakhirnya.

Tahap akhir dari metodologi ini adalah evaluasi dan analisis komparatif. Kedua model yang telah dilatih dari masing-masing skenario, model CNN terbaik hasil *hyperparameter tuning* dan model ResNet18 hasil *fine-tuning*, kemudian diuji performanya menggunakan set data uji yang sama. Proses evaluasi ini menggunakan metrik kuantitatif yang berasal dari *confusion matrix* dan *classification report* untuk mengukur akurasi, presisi, dan metrik relevan lainnya.

2.2. Pengumpulan Data

Dataset yang digunakan dalam penelitian ini merupakan *dataset* publik yang bersumber dari platform Kaggle, yaitu "*Balinese Dance Image Classification Dataset*" yang diunggah oleh Adi Paramartha [6]. *Dataset* ini menyediakan kumpulan citra tari tradisional Bali yang beragam. Namun, untuk menjaga kualitas dan validitas model yang akan dibangun, dilakukan proses seleksi dan kurasi data terlebih dahulu.

Dari total 9 kelas yang tersedia pada *dataset* asli, penelitian ini hanya menggunakan 7 kelas, yaitu tari Baris, Barong, Condong, Janger, Kecak, Pendet Penyambutan, dan Rejang Sari. Keputusan untuk mengecualikan dua kelas lainnya didasarkan pada observasi bahwa citra-citra pada kelas tersebut diekstraksi dari *frame* sebuah video latihan tari tunggal. Hal ini menyebabkan kurangnya variasi dalam hal penari, kostum, latar belakang, dan sudut pengambilan gambar. Penggunaan data dengan keragaman yang rendah sangat berisiko menghasilkan model yang *overfitting* di mana model hanya menghafal data latih sehingga tidak mampu melakukan generalisasi dengan baik pada data baru dari skenario dunia nyata [7]. Oleh karena itu, proses filtrasi ini krusial untuk memastikan setiap kelas memiliki keragaman data yang memadai.

Tabel 1. Pembagian *Dataset*

Kelas Tari	Jumlah <i>Training Set</i>	Jumlah <i>Validation Set</i>	Jumlah <i>Dataset</i>
Baris	196	49	245
Barong	196	49	245
Condong	192	48	240
Janger	203	51	254
Kecak	193	48	241
Pendet Penyambutan	195	49	244
Rejang Sari	200	50	250



Gambar 2. Contoh *Dataset*

Setelah proses seleksi, total *dataset* yang digunakan adalah sebanyak 1.719 citra. Untuk keperluan pelatihan dan evaluasi, keseluruhan *dataset* dibagi menjadi dua bagian: 80% sebagai data latih (*training set*) dan 20% sebagai data validasi (*validation set*). Data latih dimanfaatkan untuk proses penyesuaian bobot pada model, sedangkan data validasi digunakan untuk memantau performa selama pelatihan sekaligus menjadi dasar untuk evaluasi akhir model. Rincian lengkap mengenai distribusi jumlah citra pada setiap kelas disajikan pada Tabel 1, dan beberapa contoh citra representatif ditampilkan pada Gambar 2.

2.3. Preprocessing Data

Tahap *preprocessing* data merupakan langkah yang bertujuan untuk menyeragamkan format seluruh citra agar dapat diproses secara optimal oleh model *deep learning*. Proses ini melibatkan serangkaian transformasi dasar yang mencakup penyesuaian ukuran citra, konversi format gambar menjadi Tensor PyTorch, dan normalisasi nilai piksel. Meskipun langkah dasarnya serupa, terdapat perbedaan perlakuan yang spesifik dan disengaja antara kedua arsitektur yang diuji.

Pada model CNN yang dibangun dari awal, setiap citra diubah ukurannya menjadi 128x128 piksel. Studi menunjukkan bahwa resolusi sedang seperti ini mampu mempertahankan performa klasifikasi dengan beban pelatihan yang lebih ringan dibandingkan resolusi tinggi sehingga bisa menjadi jalan tengah yang seimbang [8]. Sebaliknya, untuk model *transfer learning* ResNet18, ukuran citra wajib disesuaikan menjadi 224x224 piksel untuk menyamai dimensi input standar dari arsitektur ResNet yang telah dilatih pada *dataset* ImageNet [9]. Selain perbedaan ukuran, metode normalisasi juga disesuaikan. Model CNN menggunakan normalisasi standar, sementara model ResNet18 menggunakan nilai rerata (*mean*) dan simpangan baku (*standard deviation*) spesifik dari *dataset* ImageNet untuk memastikan konsistensi penuh dengan bobot *pre-trained*.

2.4. Pelatihan Model

Pada tahapan ini terdapat 2 proses pelatihan untuk kedua skenario yakni model CNN dari awal dan model *transfer learning* ResNet18 yang menggunakan fungsi *loss* yang sama, yaitu *Cross-Entropy Loss* yang umum digunakan untuk masalah klasifikasi multikelas. Namun, strategi dan *parameter* pelatihannya berbeda secara signifikan untuk setiap skenario.

a. Pelatihan Model CNN

Untuk mendapatkan performa terbaik dari model CNN yang dibangun dari awal, diterapkan pendekatan *hyperparameter tuning* secara menggunakan metode *Grid Search*. Metode ini bekerja dengan menguji setiap kemungkinan kombinasi dari sekumpulan *hyperparameter* yang telah ditentukan untuk menemukan konfigurasi yang menghasilkan akurasi validasi tertinggi.

Daftar *parameter* dalam proses *hyperparameter tuning* disajikan pada Tabel 3. Rentang *learning rate* (0.01, 0.001, 0.0001) dipilih untuk mencakup skala laju belajar yang berbeda, sebuah pendekatan standar dalam pencarian nilai optimal [10]. Untuk *dropout rate*, nilai 0.5 diuji karena terbukti efektif sebagai teknik regularisasi untuk mencegah *overfitting*, kemudian direkomendasikan untuk menggunakan nilai yang lebih kecil untuk *dropout rate* selanjutnya [11]. Ukuran *batch* 16 dan 32 dipilih karena merupakan praktik umum yang menyeimbangkan antara efisiensi penggunaan memori GPU dan stabilitas konvergensi model [12]. Terakhir, *optimizer* Adam dan SGD diuji karena keduanya merupakan metode optimisasi yang sering digunakan.

Tabel 2. *Parameter* Dalam Proses *Hyperparameter Tuning*

<i>Parameter</i>	Nilai #1	Nilai #2	Nilai #3
<i>Learning Rate</i>	0.01	0.001	0.0001
<i>Dropout Rate</i>	0.3	0.5	-
<i>Batch Size</i>	16	32	-
<i>Optimizer</i>	Adam	SGD	-

Pada akhirnya, akan terdapat 24 kemungkinan kombinasi dari 4 jenis *parameter* tersebut yang akan diuji satu per satu dengan pelatihan sejumlah 10 *epoch*. Ketika telah mendapatkan kombinasi terbaik, model kemudian dilatih kembali. Untuk mencegah *overfitting* selama pelatihan akhir, mekanisme *early stopping* dengan nilai *patience* 3 juga diimplementasikan, pelatihan akan dihentikan secara otomatis jika tidak mendapatkan nilai *validation loss* lebih baik selama tiga *epoch* berturut-turut, dan kemudian model dengan performa terbaik ini akan disimpan.

b. Pelatihan Model *Transfer Learning* ResNet18

Pada skenario kedua, pelatihan model menerapkan strategi *transfer learning* dengan pendekatan *full network fine-tuning*. Pendekatan ini memanfaatkan arsitektur ResNet18 *pre-trained* dan melatih kembali seluruh parameter di dalamnya. Tujuannya adalah untuk mengadaptasi secara halus seluruh pengetahuan visual yang dimiliki model mulai dari deteksi fitur dasar hingga kompleks agar lebih optimal untuk *dataset* tari Bali yang spesifik.

Untuk menjalankan skenario ini, digunakan konfigurasi yang meliputi penggunaan *optimizer* Adam serta *learning rate* yang diatur pada nilai yang sangat kecil yakni 0.0001. Kombinasi ini dipilih untuk memastikan proses adaptasi bobot pada seluruh lapisan berjalan stabil tanpa merusak fitur-fitur berharga yang telah dipelajari model dari ImageNet, sebuah pendekatan yang krusial untuk mencegah fenomena *catastrophic forgetting*.

Guna mengatasi *overfitting* maka mekanisme *early stopping* diterapkan kembali. Mekanisme ini menghentikan pelatihan dan menyimpan model dari *epoch* yang memiliki *validation loss* terbaik yakni dengan nilai terendah.

2.5. Evaluasi Model

Tahap evaluasi bertujuan untuk mengukur dan membandingkan performa dari model CNN dan ResNet18 yang telah dilatih. Dua alat utama yang digunakan untuk evaluasi adalah *Confusion Matrix* dan *Classification Report*. *Confusion Matrix* adalah sebuah tabel yang memvisualisasikan performa model dengan merangkum jumlah prediksi benar dan salah untuk setiap kelas. Matriks ini digunakan untuk menganalisis secara mendalam kelas mana yang berhasil dikenali dengan baik oleh model dan kelas mana yang masih sering tertukar.


Sementara itu, *Classification Report* menyajikan ringkasan metrik performa utama yang dihitung dari *Confusion Matrix*. Metrik-metrik inilah yang akan menjadi dasar perbandingan kuantitatif antar model. Metrik yang digunakan meliputi:

- Akurasi (*Accuracy*): Mengukur persentase prediksi yang benar secara keseluruhan.
- Presisi (*Precision*): Menilai ketepatan prediksi positif untuk setiap kelas.
- Recall: Mengukur kemampuan model mengidentifikasi semua sampel untuk setiap kelas.
- F1-Score: Menyediakan skor tunggal yang menyeimbangkan antara Presisi dan Recall.

3. Hasil dan Diskusi

3.1. Hasil Optimasi *Hyperparameter Tuning* CNN

Tahap pertama dalam analisis hasil adalah menentukan konfigurasi model CNN terbaik melalui proses optimasi *hyperparameter*. Seperti yang telah dijelaskan pada sub-bab 2.4.1, dilakukan metode *Grid Search* untuk menguji 24 kombinasi *hyperparameter* yang berbeda. Setiap kombinasi dilatih dan dievaluasi performanya berdasarkan nilai akurasi pada data validasi (*validation accuracy*).



Gambar 4. Hasil *Validation Accuracy* pada 24 Kombinasi *Hyperparameter*

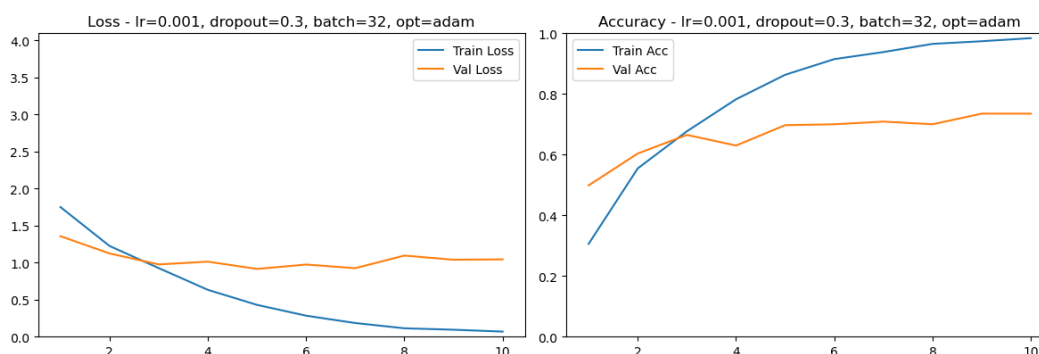
Berdasarkan hasil eksperimen *Grid Search*, ditemukan bahwa kombinasi *hyperparameter* yang menghasilkan performa terbaik pada data validasi adalah kombinasi dengan *learning rate* 0.001, *dropout rate* 0.3, *batch size* 32, dan *optimizer* Adam. Dengan menggunakan konfigurasi optimal ini, model kemudian dilatih kembali menggunakan mekanisme *early stopping* untuk mencegah *overfitting*.

3.2. Pelatihan Model

Setelah mendapatkan konfigurasi optimal untuk model CNN, tahap selanjutnya adalah menganalisis proses pelatihan dari kedua model yakni CNN dan ResNet18. Analisis ini dilakukan dengan mengamati grafik riwayat pelatihan yang memetakan nilai akurasi dan *loss* pada setiap *epoch* untuk data latih dan data validasi.

a. Pelatihan Model CNN Terbaik

Model CNN dengan konfigurasi terbaik kemudian dilatih. Grafik riwayat pelatihan untuk model ini disajikan pada Gambar 5. Dari grafik tersebut, terlihat jelas adanya kesenjangan performa (*performance gap*) yang signifikan antara data latih dan data validasi. Akurasi pada data latih berhasil mencapai 96.51%, sementara akurasi pada data validasi hanya mampu mencapai nilai puncak sebesar 72.30%.




Gambar 5. Loss dan Akurasi Data Latih serta Data Validasi Pada Model CNN

Kesenjangan yang besar ini merupakan indikator kuat dari fenomena *overfitting*. Model menjadi terlalu "hafal" dengan karakteristik spesifik dari data latih, namun gagal melakukan generalisasi dengan baik pada data validasi yang belum pernah dilihat sebelumnya. *Overfitting* terlihat mulai terbentuk dari *epoch* ke-4 ketika mulai terdapat *performance gap*, baik dari nilai akurasi dan juga nilai *loss*.

3.3. Training dan Validasi Model Transfer Learning ResNet18

Performa pelatihan yang sangat berbeda ditunjukkan oleh model ResNet18, seperti yang divisualisasikan pada Gambar 6. Model ini menunjukkan kemampuan konvergensi yang jauh lebih cepat dan efektif. Akurasi pada data validasi berhasil mencapai puncaknya pada nilai 97.38% hanya dalam enam *epoch* pertama. Selain itu akurasi pada data latih berhasil mencapai nilai 100% pada *epoch* ke-5 yang pada awalnya memberikan tanda *overfitting* tetapi jika disandingkan dengan nilai akurasi data validasinya pada *epoch* yang sama yaitu pada angka 96.79%, kedua angka tersebut tidak jauh berbeda sehingga belum mengindikasikan *overfitting* seperti yang ada pada model CNN.




Gambar 6. Loss dan Akurasi Data Latih serta Data Validasi Pada Model *Transfer Learning* ResNet18

Meskipun akurasi latih juga mencapai nilai mendekati sempurna, kesenjangan performa antara data latih dan data validasi pada model ResNet18 jauh lebih kecil dibandingkan dengan model CNN. Hal ini menunjukkan bahwa pendekatan *transfer learning* dengan *full network fine-tuning* lebih tangguh terhadap *overfitting* dalam kasus ini. Pengetahuan awal yang dimiliki oleh bobot *pre-trained* ResNet18 memberikan fondasi yang kuat sehingga model tidak perlu belajar dari nol dan dapat lebih fokus untuk beradaptasi dengan *dataset* tari Bali secara efektif.


3.4. Confusion Matrix

Confusion Matrix dari kedua model disajikan pada Gambar 7 dan Gambar 8. Matriks ini secara visual menunjukkan kemampuan masing-masing model dalam membedakan tujuh kelas tari Bali.



Gambar 7. Confusion Matrix Model CNN Terbaik

Pada matriks model CNN terdapat banyak sel di luar diagonal utama yang terisi. Ini mengindikasikan bahwa model CNN sering melakukan kesalahan klasifikasi. Model ini menunjukkan kebingungan dalam membedakan beberapa tarian yang memiliki kemiripan visual, seperti sering keliru mengklasifikasikan antara tari Barong dan Kecak.



Gambar 8. Confusion Matrix Model Transfer Learning ResNet18

Sebaliknya, matriks model ResNet18 menunjukkan hasil yang nyaris sempurna. Mayoritas prediksi terkonsentrasi di sepanjang diagonal utama, dengan jumlah kesalahan klasifikasi yang sangat minim. Ini membuktikan bahwa pendekatan *transfer learning* mampu menangkap fitur-fitur pembeda yang lebih detail dan robas antar kelas tarian.

3.5. Classification Report

Tabel 3. Classification Report Model CNN Terbaik

Kelas Tari	Precision	Recall	F1-Score
Baris	0.69	0.80	0.74
Barong	0.68	0.82	0.74
Condong	0.72	0.62	0.67
Janger	0.72	0.62	0.67
Kecak	0.66	0.63	0.65
Pendet Penyambutan	0.70	0.66	0.68
Rejang Sari	0.89	0.89	0.89
Rata-rata	0.72	0.72	0.72

Tabel 4. *Classification Report Transfer Learning ResNet18*

Kelas Tari	Precision	Recall	F1-Score
Baris	0.97	1.00	0.99
Barong	1.00	1.00	1.00
Condong	1.00	1.00	1.00
Janger	0.95	0.89	0.92
Kecak	0.93	0.98	0.95
Pendet Penyambutan	0.96	0.91	0.93
Rejang Sari	0.96	0.98	0.97
Rata-rata	0.97	0.97	0.97

Data pada Tabel 3 dan Tabel 4 mengkonfirmasi superioritas dari model ResNet18. Keunggulan ini tidak hanya terlihat dari akurasi total, tetapi juga konsisten di seluruh metrik untuk setiap kelas. Nilai F1-Score rata-rata (*Macro Avg*) dari ResNet18 mencapai 0.97, sementara CNN hanya 0.72. Angka-angka ini membuktikan bahwa pendekatan *transfer learning* dengan *full network fine-tuning* pada arsitektur ResNet18 secara signifikan lebih efektif untuk tugas klasifikasi citra tari Bali dibandingkan dengan membangun model CNN dari awal walau dengan melakukan *hyperparameter tuning*.

Keunggulan signifikan dari model ResNet18 dapat diatribusikan pada kemampuannya memanfaatkan fitur-fitur visual tingkat rendah (seperti tepi dan tekstur) hingga tingkat tinggi (seperti bentuk dan pola objek) yang telah dipelajari dari *dataset* ImageNet yang masif. Pengetahuan awal ini memberikan fondasi yang jauh lebih kuat dibandingkan model CNN yang harus mempelajari semua fitur dari nol. Akibatnya, model ResNet18 tidak hanya lebih akurat, tetapi juga lebih tangguh terhadap *overfitting*, terutama saat dihadapkan pada *dataset* dengan jumlah yang relatif terbatas.

4. Kesimpulan

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan, dapat ditarik beberapa kesimpulan. Penelitian ini berhasil membandingkan dua pendekatan *deep learning* yakni model CNN yang dioptimalkan dengan *Hyperparameter Tuning* melalui *Grid Search* dan model *transfer learning* ResNet18, keduanya sama-sama dipergunakan untuk tugas klasifikasi tujuh jenis tari Bali.

Hasil penelitian secara jelas menunjukkan bahwa pendekatan *transfer learning* dengan ResNet18 secara signifikan lebih unggul daripada membangun model CNN dari awal untuk kasus ini. Model ResNet18 berhasil mencapai akurasi sebesar 97.38%, sementara model CNN terbaik hanya mencapai 72.30%. Perbedaan performa yang kontras ini menandakan efektivitas dari pemanfaatan pengetahuan *pre-trained* dalam mengatasi tantangan klasifikasi citra yang kompleks dengan *dataset* yang terbatas. Ditemukan pula bahwa model CNN dari awal rentan mengalami *overfitting* yang signifikan, sebuah masalah yang dapat diatasi dengan lebih baik oleh arsitektur ResNet18.

Penelitian ini mengonfirmasi bahwa *transfer learning* merupakan strategi yang sangat efektif dan efisien untuk aplikasi pelestarian budaya digital, khususnya dalam pengenalan citra seni tradisional Indonesia. Untuk penelitian di masa depan, disarankan untuk melakukan uji coba pada *dataset* lain yang juga memiliki nuansa Bali seperti topeng Bali atau sarana dan prasarana upacara adat menggunakan *transfer learning* serupa untuk memberikan konfirmasi akan pemanfaatan *transfer learning* pada pelestarian budaya Bali.

Daftar Pustaka

- [1] E. Krisnanik, B. S. Yulistiawan, I. H. Indriana, and B. Yuwono, "Pemanfaatan Teknologi Informasi dan Komunikasi (TIK) dalam Pelestarian Budaya Dan Wujud Bela Negara," *Jurnal Bela Negara UPN Veteran Jakarta*, vol. 1, no. 2, pp. 83–98, Dec. 2023.
- [2] G. P. I. Fanani, Y. Safitri, M. A. Mu'min, S. A. Wijaya, T. S. Famuji, and N. Trisanti, "Pengenalan Citra Batik Tradisional Menggunakan Deep Learning untuk Klasifikasi Motif Daerah," *Scientific: Journal of Computer Science and Informatics*, vol. 2, no. 1, Jan. 2025.
- [3] A. Peryanto, A. Yudhana, and R. Umar, "Rancang Bangun Klasifikasi Citra Dengan Teknologi Deep Learning Berbasis Metode Convolutional Neural Network," *Format : Jurnal Ilmiah Teknik Informatika*, vol. 8, no. 2, pp. 138–147, 2019.
- [4] D. M. Wonohadidjojo, "Perbandingan Convolutional Neural Network pada Transfer Learning Method untuk Mengklasifikasikan Sel Darah Putih," *Ultimatics : Jurnal Teknik Informatika*, vol. 13, no. 1, pp. 51–57, Jun. 2021.
- [5] G. M. A. Sihotang and J. Supardi, "Pengembangan Model CNN ResNet-18 untuk Klasifikasi Kondisi Gigi Berbasis Citra RGB sebagai Solusi Diagnostik Digital," *Jurnal Pendidikan dan Teknologi Indonesia (JPTI)*, vol. 4, no. 12, pp. 747–758, Dec. 2024.
- [6] A. Paramartha, "Dataset Tari Bali," Kaggle. Accessed: Jul. 04, 2025. [Online]. Available: <https://www.kaggle.com/datasets/adiparamartha/dataset-tari-bali/data>
- [7] C. Shorten and T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," *Journal of Big Data*, vol. 6, no. 1, Jul. 2019.
- [8] S. Tang *et al.*, "The effect of image resolution on convolutional neural networks in breast ultrasound," *Heliyon*, vol. 9, no. 8, p. e19253, Aug. 2023.
- [9] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, Jun. 2016, pp. 770–778.
- [10] cs231n, "CS231n Deep Learning for Computer Vision," Github.io. Accessed: Jul. 04, 2025. [Online]. Available: <https://cs231n.github.io/neural-networks-3/>
- [11] J. Brownlee, "A Gentle Introduction to Dropout for Regularizing Deep Neural Networks," Machinelearningmastery.com. [Online]. Available: <https://machinelearningmastery.com/dropout-for-regularizing-deep-neural-networks/>
- [12] D. Masters and C. Luschi, "On Large-Batch Training for Deep Learning: Generalization Gap and Sharp Minima," *Graphcore Research*, Apr. 2018.

Halaman ini sengaja dibiarkan kosong