

Augmentasi Data Pengenalan Citra Batik Yogyakarta Menggunakan Pendekatan Random Crop, Rotate, Dan MixUp

Muhammad Mega Nugraha¹, Moch Dani Ferdian Saputra², Daffa Athallah Fauzan³, Eva Yulia Puspaningrum^{4*}

^{1,2,3,4*} Informatika, Universitas Pembangunan Nasional “Veteran” Jawa Timur

122081010213@student.upnjatim.ac.id

222081010147@student.upnjatim.ac.id

322081010117@student.upnjatim.ac.id

4*evapuspaningrum.if@upnjatim.ac.id

Abstrak : Batik Yogyakarta merupakan salah satu warisan budaya Indonesia yang kaya akan nilai estetika dan filosofis. Dalam upaya mengklasifikasikan citra batik secara otomatis, terdapat tantangan berupa kompleksitas pola visual dan keterbatasan data pelatihan. Penelitian ini bertujuan untuk mengevaluasi efektivitas teknik augmentasi data, meliputi random crop, random rotate, dan MixUp, dalam meningkatkan performa klasifikasi enam motif batik Yogyakarta menggunakan arsitektur ResNet50. Tiga skenario pelatihan diterapkan: skenario tanpa augmentasi (Skenario A), skenario augmentasi geometris (Skenario B), dan skenario kombinasi augmentasi geometris dengan MixUp (Skenario C). Dataset yang digunakan terdiri dari 1.350 gambar yang kemudian dibagi menggunakan metode stratified sampling, dengan pelatihan berbasis transfer learning. Hasil pengujian menunjukkan bahwa augmentasi data secara signifikan meningkatkan performa model. Skenario A, sebagai baseline, mencapai akurasi 84,96%. Skenario B, dengan penerapan random crop dan rotate, menunjukkan peningkatan akurasi menjadi 86,67%. Sementara itu, Skenario C, yang menambahkan MixUp, berhasil memperoleh akurasi tertinggi sebesar 87,22%. Penerapan MixUp terbukti memberikan regularisasi tambahan yang memperkuat kemampuan generalisasi model terhadap data uji, khususnya pada dataset yang terbatas. Dengan demikian, kombinasi augmentasi geometris dan MixUp merupakan strategi yang efektif dalam pengenalan citra batik, serta berpotensi untuk diterapkan pada tugas klasifikasi visual lainnya dalam upaya pelestarian warisan budaya.

Kata Kunci : augmentasi data, batik Yogyakarta, ResNet50, MixUp, random crop, rotate.

I. PENDAHULUAN

Batik Yogyakarta merupakan salah satu warisan budaya Indonesia yang kaya akan nilai estetika dan filosofis. Motif-motif seperti ceplok, kawung, nitik, parang, sidoluhur, dan truntum tidak hanya menjadi bagian dari ekspresi seni, tetapi juga merepresentasikan identitas kearifan lokal yang mendalam [1]. Seiring perkembangan teknologi, pelestarian batik kini mulai diarahkan pada digitalisasi, salah satunya melalui klasifikasi citra berbasis kecerdasan buatan.

Salah satu tantangan utama dalam klasifikasi citra batik adalah kompleksitas pola visual yang tinggi serta keterbatasan varian data pelatihan. Pada dataset kami, tiga kelas pertama: kawung, parang dan truntum memiliki 250 citra dan 3 kelas sisanya: ceplok, nitik, dan sidoluhur, memiliki 250 citra. Jumlah ini masih terbatas untuk pelatihan model *deep learning*

secara optimal. Keterbatasan data ini dapat menyebabkan model mengalami *overfitting* dan gagal melakukan generalisasi yang baik terhadap data baru. Oleh karena itu, diperlukan strategi augmentasi data untuk memperkaya variasi input dan meningkatkan performa model [2].

Augmentasi data memperkenalkan variasi yang lebih banyak pada data yang kemudian membantu model mengenali pola dari berbagai sudut pandang dan skenario pencahayaan. Teknik seperti *random crop* dan *rotate* telah terbukti efektif dalam memperluas representasi spasial dari citra dan menambah keragaman posisi fitur [3]. Sementara itu, pendekatan MixUp, yaitu menggabungkan dua citra beserta labelnya, memberikan efek regularisasi yang baik dan meningkatkan kemampuan generalisasi model, terutama saat bekerja dengan dataset kecil [4][5].

Dalam penelitian ini, digunakan arsitektur ResNet50 yang dikenal handal dalam tugas klasifikasi citra berkat pendekatan *residual learning*-nya. ResNet50 dapat mengekstraksi fitur dari citra dengan lebih mendalam tanpa mengalami degradasi akurasi saat jaringan semakin dalam [6]. Selain itu, ResNet50 telah banyak diterapkan dalam klasifikasi citra batik dan menunjukkan hasil yang kompetitif [7].

Penelitian ini bertujuan untuk membandingkan performa model klasifikasi motif batik Yogyakarta menggunakan ResNet50 pada tiga skenario dataset: tanpa augmentasi, dengan augmentasi random crop dan rotate, serta dengan penambahan MixUp. Evaluasi ini diharapkan dapat memberikan rekomendasi teknik augmentasi yang paling efektif untuk meningkatkan akurasi dan stabilitas model dalam mengenali motif batik Yogyakarta.

II. KAJIAN PUSTAKA

A. Batik Yogyakarta

Batik adalah warisan budaya Indonesia yang diakui UNESCO sebagai warisan dunia. Setiap daerah di Indonesia memiliki ragam motif batik yang berbeda, lengkap dengan filosofi dan maknanya masing-masing. Perbedaan ini dipengaruhi oleh ciri khas dan makna yang ingin disampaikan oleh setiap daerah.

Yogyakarta dikenal kental akan budaya batiknya. Batik Yogyakarta memiliki ciri khas warna dasar cokelat, hitam, dan putih. Sebagian besar motifnya berupa pola

geometris, serta tiap motif memiliki makna tersendiri dan digunakan pada acara-acara tertentu. Yogyakarta memiliki beragam jenis motif batik, seperti ceplok, kawung, parang, truntum, nitik, dan sidoluhur, yang dapat dibedakan berdasarkan polanya. Salah satu motif batik Yogyakarta yang terkenal adalah motif kawung, yang memiliki pola empat lingkaran atau elips mengelilingi lingkaran kecil sebagai pusatnya, tersusun memanjang secara diagonal miring ke kanan atau ke kiri secara berselang-seling. Motif ini melambangkan keinginan besar serta usaha keras yang akan selalu membuahkan hasil.

Tahapan augmentasi data merupakan proses modifikasi gambar dalam dataset untuk menciptakan variasi baru, sehingga data menjadi lebih beragam [11]. Augmentasi data adalah salah satu teknik yang dapat mengurangi *overfitting* dengan meningkatkan variasi *dataset* secara minimal. Data umumnya diaugmentasi dengan melakukan transformasi, atau dengan kata lain, membuat salinan dari sumber data tanpa mengubah label yang tertera pada setiap bagian data tersebut [12]. Teknik ini bertujuan untuk meningkatkan keragaman data pelatihan tanpa perlu mengumpulkan data baru secara manual. Berbagai teknik augmentasi yang umum digunakan meliputi rotasi (*rotate*) untuk memutar gambar dan pemotongan (*crop*) untuk mengambil bagian tertentu dari gambar. Berikut adalah contoh augmentasi tersebut.



Gambar 1 Contoh Teknik Rotate

Teknik *rotate* atau rotasi adalah metode augmentasi yang memutar gambar dengan sudut tertentu, seperti 15° , 45° , atau bahkan secara acak dalam rentang tertentu. Tujuannya adalah untuk membuat model lebih fleksibel dalam mengenali objek dari berbagai orientasi. Misalnya, dalam pengenalan objek atau pola visual seperti batik atau tulisan tangan, rotasi membantu model tidak hanya menghafal bentuk dalam satu arah, melainkan mampu mengenali walau tampil dari sudut berbeda.

Gambar 2 Contoh Teknik Crop



Teknik *crop* atau pemotongan dilakukan dengan cara mengambil sebagian area dari gambar asli, baik dari tengah maupun dari sisi gambar. Metode ini dapat membantu model belajar dari bagian penting gambar dan tetap memahami konteks meskipun sebagian informasi visual dihilangkan. *Crop* sering digunakan untuk mensimulasikan situasi di mana objek hanya terlihat sebagian, seperti dalam pengenalan wajah di kerumunan atau saat objek terhalang.



Gambar 3 Contoh Teknik MixUp

Teknik MixUp adalah pendekatan augmentasi yang mencampurkan dua gambar secara linier, termasuk label dari masing-masing gambar, untuk membentuk satu gambar dan label baru. Teknik ini mendorong model untuk melakukan generalisasi lebih baik karena model dilatih pada kombinasi fitur dari dua kelas yang berbeda. Selain meningkatkan performa klasifikasi, MixUp juga membantu meredam *noise* dan membuat model lebih tahan terhadap fluktuasi data atau ketidakteraturan visual yang ada pada gambar-gambar nyata.

B. Resnet 50

Residual Neural Network (ResNet) adalah arsitektur CNN yang memenangi kompetisi ILSVRC pada tahun 2015 dengan error hanya sebesar 3,57%. ResNet menerapkan pembelajaran residual, sebuah metode yang meningkatkan efisiensi pelatihan dengan memanfaatkan input setiap layer sebagai acuan. Meskipun memiliki layer yang lebih banyak daripada arsitektur VGG, ResNet tetap mampu mempertahankan kompleksitas yang rendah. Salah satu varian populer dari arsitektur ini adalah ResNet-50, yang terdiri dari 50 lapisan [13].

ResNet-50 bekerja dengan konsep *residual block* atau blok residu, yang menjadi inti arsitektur ini. Setiap blok terdiri dari tiga lapisan konvolusi berurutan (1x1, 3x3, dan 1x1) yang dikenal sebagai *bottleneck block*. Lapisan 1x1 pertama berfungsi mengurangi dimensi, lapisan 3x3 untuk ekstraksi fitur, dan lapisan 1x1 terakhir mengembalikan dimensi asli. Ciri khas ResNet-50 adalah adanya *shortcut connection* yang menghubungkan input awal langsung ke output blok tanpa melewati proses non-linear di tengah. Alur ini memungkinkan jaringan untuk hanya mempelajari selisih (residu) antara input dan output, sehingga pelatihan menjadi lebih stabil dan efisien. Dengan 50 lapisan yang tersusun dari beberapa blok residu, ResNet-50 mampu membangun representasi fitur yang sangat dalam tanpa penurunan performa yang sering terjadi pada jaringan tradisional yang lebih dalam.

III. METODE PENELITIAN

Penelitian ini kami susun secara metodis dengan guna menguji efektivitas teknik augmentasi data terhadap kinerja klasifikasi motif batik Yogyakarta dengan memanfaatkan arsitektur ResNet50. Langkah-langkah penelitian ini mencakup pengumpulan data, pra pemrosesan, augmentasi data, pengembangan model, dan evaluasi.

A. Pengumpulan Data

Penelitian ini menggunakan data yang terdiri dari enam kelas motif batik tradisional Yogyakarta, meliputi ceplok, kawung, nitik, parang, sidoluhur, dan truntum [2][9]. Data tersebut dikumpulkan dari berbagai sumber, termasuk dataset publik Kaggle, repositori Batik-Pattern-Classification [14], serta dataset Batik 300 [15]. Pendekatan multisumber ini diterapkan untuk memperkaya keberagaman data, suatu praktik yang lazim dalam bidang visi komputer guna meningkatkan ketahanan model [16].

B. Preprocessing

Tahap pra-pemrosesan data diawali dengan melakukan analisis terhadap distribusi kelas pada dataset yang telah dihimpun. Dataset ini mencakup enam kelas motif batik, Dengan 3 kelas pertama, kawung, parang dan truntum memiliki 250 citra dan 3 kelas sisanya, ceplok, nitik, dan sidoluhur, memiliki 250 citra. Perbedaan jumlah sampel antar kelas tersebut menghasilkan rasio ketidakseimbangan kelas yang tergolong tidak signifikan. Dalam konteks klasifikasi citra menggunakan Convolutional Neural Networks (CNNs), ketidakseimbangan kelas pada tingkat ringan seperti ini umumnya tidak dipandang sebagai hambatan signifikan terhadap performa model, terutama apabila strategi augmentasi data yang memadai diterapkan pada tahap pelatihan. Beberapa panduan bahkan merekomendasikan dilakukannya evaluasi awal terhadap distribusi data asli dalam kasus ketidakseimbangan ringan sebelum memutuskan untuk menerapkan teknik penyeimbangan data secara eksplisit. Meskipun terdapat berbagai pendekatan penyeimbangan data yang berpotensi meningkatkan kinerja model [17], penelitian ini secara sadar memilih untuk tidak menggunakan metode sampling seperti *undersampling* maupun *oversampling*. Keputusan ini dilandasi oleh pertimbangan bahwa tingkat ketidakseimbangan yang ada relatif kecil serta diyakini dapat diminimalkan melalui penerapan strategi augmentasi data yang komprehensif, meliputi *random crop*, *random rotation*, dan MixUp, yang diterapkan secara eksklusif pada data pelatihan.

Dataset kemudian dibagi menjadi data pelatihan dan data pengujian dengan rasio 80:20, sehingga menghasilkan 1080 gambar untuk pelatihan dan 270 gambar untuk pengujian. Pembagian ini menggunakan *stratified sampling* agar distribusi kelas tetap proporsional di kedua set data [19]. Penting untuk dicatat bahwa pembagian ini dilakukan sebelum proses augmentasi data untuk memastikan bahwa data pengujian tidak terkontaminasi oleh variasi buatan, sehingga menjaga integritas proses evaluasi model [19]. Augmentasi data hanya diterapkan pada set data pelatihan.

C. Augmentasi Data

Dalam penelitian ini, augmentasi data diimplementasikan secara online selama fase pelatihan model. Pendekatan ini memanfaatkan fungsionalitas dari library PyTorch, khususnya modul `torchvision.transforms`, untuk menerapkan transformasi secara dinamis pada setiap batch data sebelum diumpankan ke *neural network*. Berbeda dengan metode augmentasi *offline*

yang bertujuan memperbanyak jumlah sampel data secara fisik, augmentasi online berfokus pada peningkatan variansi data pelatihan. Artinya, model diekspos pada representasi data yang terus berubah dan beragam dari masa ke masa, tanpa meningkatkan jumlah data asli yang tersimpan. Strategi ini dirancang untuk meningkatkan kemampuan generalisasi model dengan mengajarkannya invariansi terhadap berbagai transformasi dan mengurangi risiko *overfitting*, karena model belajar dari spektrum variansi data yang lebih luas daripada dari dataset statis yang diperbesar.

Untuk mengevaluasi dampak teknik augmentasi secara sistematis terhadap performa klasifikasi, penelitian ini mengembangkan tiga skenario pelatihan berdasarkan tiga konfigurasi dataset:

1. Skenario A: Tidak menggunakan augmentasi (*baseline*)
2. Skenario B: Menggunakan teknik *random crop* dan *random rotation*.
3. Skenario C: Menggunakan data yang sama dengan Skenario B namun dengan penambahan teknik MixUp yang diimplementasikan secara *online* dalam *pipeline* pelatihan.

Pada *random crop*, bagian berukuran 224×224 piksel diambil secara acak dari gambar asli. Teknik ini mensimulasikan variasi alami seperti pergeseran posisi kamera atau pemotongan pola, sehingga model belajar mengenali fitur yang lebih umum [21]. Ukuran 224×224 dipilih karena sesuai dengan input standar dari arsitektur ResNet50. Sementara itu, *random rotation* dilakukan dengan rotasi acak dalam rentang 0 hingga +15 derajat untuk meningkatkan invariance model terhadap orientasi pola [5].

Pada Skenario C, teknik MixUp diimplementasikan secara online dalam *pipeline* pelatihan menggunakan data dasar yang sama dengan Skenario B. MixUp diterapkan selama proses pelatihan di mana dua gambar dan labelnya dikombinasikan secara linear menggunakan rumus:

$$\tilde{x} = \lambda x^i + (1 - \lambda)x^j, \quad \tilde{y} = \lambda y^i + (1 - \lambda)y^j$$

Dengan λ diambil dari distribusi Beta. Teknik ini meningkatkan variansi data dan memperkenalkan *soft labels*, yang dapat mengurangi *overfitting* dan meningkatkan generalisasi [13]. Berbeda dengan augmentasi pada Skenario B yang dilakukan sebelum pelatihan, MixUp pada Skenario C dilakukan secara *real-time* selama proses pelatihan. Dengan demikian, Skenario C dilatih menggunakan teknik augmentasi yang identik dengan Skenario B, tetapi dengan tambahan transformasi MixUp yang diterapkan secara dinamis pada setiap *batch* data sebelum diumpankan ke jaringan saraf.

D. Pengembangan Model

Penelitian ini mengadopsi arsitektur ResNet50, sebuah jaringan residual dalam yang telah terbukti sangat efektif untuk tugas klasifikasi citra [6], sebagai kerangka dasar untuk tiga

model eksperimental. Model ini diinisialisasi dengan bobot pra-latih dari dataset ImageNet. Pendekatan ini, yang dikenal sebagai *transfer learning*, memungkinkan model untuk memanfaatkan fitur-fitur visual tingkat rendah yang telah dipelajari dari dataset berskala besar, sehingga dapat mencapai kinerja tinggi pada tugas spesifik dengan data yang lebih sedikit dan waktu pelatihan yang lebih singkat [22]. Implementasi dilakukan melalui penggantian lapisan klasifikasi akhir (*fully connected layer*) agar sesuai dengan enam kelas motif batik Yogyakarta.

Setiap model dilatih dengan strategi spesifik untuk mengevaluasi dampak augmentasi data. Untuk menjaga komparabilitas, parameter pelatihan fundamental distandarisasi di seluruh model, dengan adaptasi khusus untuk mengakomodasi MixUp pada Skenario C.

Optimasi model dilakukan menggunakan AdamW, sebuah varian dari optimizer Adam yang memisahkan mekanisme *weight decay* dari pembaruan gradien. Pendekatan ini terbukti dapat meningkatkan kemampuan generalisasi model dibandingkan dengan implementasi L2 *regularization* pada optimizer Adam konvensional [23]. Learning rate awal ditetapkan sebesar 0.0001 dan disesuaikan secara dinamis saat pelatihan menggunakan *scheduler* ReduceLROnPlateau. Mekanisme ini secara adaptif mengurangi *learning rate* ketika metrik pada data validasi (dalam hal ini *validation loss*) berhenti menunjukkan perbaikan, memungkinkan model untuk melakukan konvergensi yang lebih halus menuju titik optimal.

Fungsi *loss* yang digunakan disesuaikan dengan sifat data input. Untuk Skenario A dan B, yang dilatih pada label kategori yang jelas (*hard labels*), digunakan fungsi CrossEntropyLoss. Namun, untuk Skenario C yang menggunakan MixUp, label targetnya merupakan hasil interpolasi linear sehingga bersifat lunak (*soft labels*). Oleh karena itu, diimplementasikan fungsi *soft cross-entropy* kustom selama fase pelatihan, sejalan dengan metodologi yang diperkenalkan dalam paper MixUp [4].

Regularisasi lebih lanjut diterapkan melalui early stopping dengan *patience* 5 *epoch*. Teknik ini secara efektif mencegah *overfitting* dengan menghentikan proses pelatihan ketika kinerja model pada set data validasi tidak lagi membaik [24]. Selain itu, *model checkpointing* memastikan bahwa bobot model yang disimpan adalah yang menghasilkan *validation loss* terendah selama keseluruhan proses pelatihan.

E. Evaluasi

Evaluasi performa model dilakukan secara komprehensif dengan Test-Time Augmentation (TTA). Metode ini diadopsi untuk menilai ketahanan model dan berpotensi meningkatkan akurasi prediksi dengan cara mengevaluasi beberapa versi teraugmentasi dari setiap gambar uji. Proses TTA yang dilakukan meliputi pembuatan beberapa varian dari setiap gambar dalam set pengujian (misalnya, dengan augmentasi *cropping* dan *flipping*). Model kemudian membuat prediksi untuk setiap varian tersebut. Prediksi-prediksi ini selanjutnya diagregasi (misalnya, dengan merata-ratakan probabilitas prediksi) untuk menghasilkan satu prediksi akhir yang lebih andal untuk gambar asli tersebut.

IV. HASIL DAN PEMBAHASAN

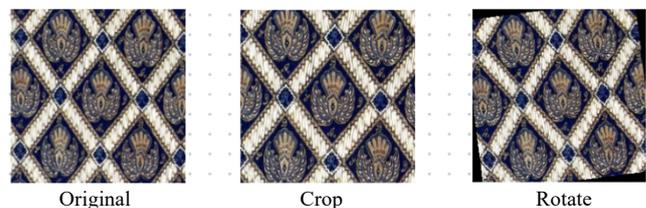
Bagian ini menyajikan hasil eksperimen klasifikasi motif batik Yogyakarta menggunakan arsitektur ResNet50 dengan berbagai skenario augmentasi data. Pembahasan difokuskan pada analisis kinerja model, dampak teknik augmentasi, dan implikasi temuan terhadap tantangan klasifikasi citra warisan budaya.

A. Visualisasi Hasil Augmentasi Data

Untuk memberikan pemahaman kualitatif mengenai bagaimana teknik augmentasi data meningkatkan keragaman data pelatihan, berikut disajikan contoh visual dari efek transformasi yang diterapkan berupa *crop*, *rotate*, dan MixUp. Visualisasi ini membantu mengkonkretkan konsep abstrak "peningkatan diversitas data" dan memungkinkan pemahaman yang lebih baik tentang bagaimana model ditantang untuk mempelajari fitur yang lebih variatif.

1. Efek *Random Crop* dan *Random Rotate*

Teknik *random crop* dan *random rotation* digunakan untuk meningkatkan kemampuan model dalam mengenali motif batik meskipun mengalami perubahan posisi, ukuran, dan arah. Dengan augmentasi ini, model menjadi lebih robust terhadap variasi skala, translasi, dan orientasi citra batik.



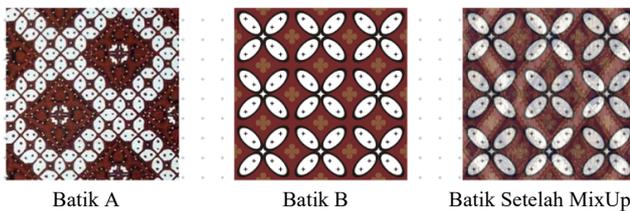
Gambar 4 Efek Random Crop dan Random Rotate

Pengambilan *crop* secara acak dari citra menghasilkan berbagai perspektif dari motif yang sama, sementara rotasi secara acak mensimulasikan variasi dari sudut pandang. Parameter augmentasi ini sengaja dipilih untuk mencapai keseimbangan antara pengenalan variabilitas yang cukup dan pelestarian karakteristik esensial motif, menghindari distorsi berlebihan yang dapat menghilangkan informasi penting. Manfaat dari *random crop* adalah model belajar untuk mengenali objek meskipun tidak seluruhnya terlihat atau berada pada skala yang berbeda dalam data pelatihan, yang sangat relevan untuk pola batik yang kompleks di mana *crop* yang berbeda dapat menyoroti bagian karakteristik yang berbeda dari suatu motif. Rotasi membantu mengatasi masalah variasi sudut pandang.

2. Efek MixUp

MixUp adalah teknik augmentasi yang bekerja dengan cara menginterpolasi secara linear dua citra acak beserta labelnya untuk menciptakan sampel pelatihan virtual baru. Teknik ini menghasilkan citra dan label campuran (*soft label*) yang mendorong model untuk membentuk batas

keputusan yang lebih halus di antara kelas. Selain meningkatkan kemampuan generalisasi, MixUp juga efektif dalam mengurangi *overfitting*, terutama pada dataset yang terbatas.



Gambar 5 Efek Random MixUp

Terlihat bahwa citra hasil MixUp merupakan gabungan visual dari dua citra asli, dan labelnya pun menjadi kombinasi probabilitas dari label asli. Meskipun citra hasil MixUp mungkin tampak tidak natural atau sulit diinterpretasi oleh manusia, teknik ini mendorong model untuk berperilaku linear di antara kelas-kelas, menghasilkan batas keputusan yang lebih halus dan meningkatkan kemampuan generalisasi, terutama pada dataset dengan jumlah sampel terbatas.

B. Kinerja Pelatihan Model

Analisis kinerja pelatihan memberikan gambaran mengenai bagaimana setiap model belajar dari data pelatihan dan data validasi sepanjang proses pelatihan. Berikut ini adalah tabel rincian perbandingan metrik dari tahap pelatihan tiap model.

TABEL I
PERBANDINGAN METRIK PELATIHAN AKHIR MODEL

Nama Model	Loss Pelatihan Akhir	Loss Validasi Akhir	Akurasi Pelatihan Akhir	Akurasi Validasi Akhir
Skenario A	0,2394	0,4690	92,48%	84,96%
Skenario B	0,1941	0,4358	93,61%	86,67%
Skenario C	0,7210	0,4424	88,53%	87,22%

Skenario A (ResNet50 Baseline) menunjukkan indikasi *overfitting* sejak awal pelatihan. Hal ini tercermin dari selisih yang cukup besar antara loss pelatihan (0.2394) dan loss validasi (0.4690), serta perbedaan akurasi pelatihan dan validasi yang cukup mencolok (92.48% vs 84.96%). Artinya, model belajar terlalu baik pada data pelatihan namun kesulitan menggeneralisasi ke data yang belum pernah dilihat.

Skenario B, yang menggunakan augmentasi Random Crop dan Rotate, memperlihatkan peningkatan performa generalisasi. Loss validasi menurun menjadi 0.4358 dan akurasi validasi meningkat ke 86.67%, disertai selisih yang lebih kecil antara metrik pelatihan dan validasi dibandingkan Skenario A. Hal ini menunjukkan bahwa augmentasi membantu mengurangi *overfitting* dan memperkuat kemampuan model dalam menangani variasi data.

Skenario C, yang menambahkan teknik MixUp di atas augmentasi Skenario B, menunjukkan karakteristik pelatihan yang berbeda. Loss pelatihan-nya jauh lebih tinggi (0.7210), yang merupakan ciri khas dari MixUp, karena model dilatih dengan data hasil interpolasi dan label lunak (*soft labels*). Dalam konteks ini, *loss* yang tinggi tidak berarti model bekerja buruk, melainkan mencerminkan ketidakpastian yang disengaja oleh MixUp untuk mencegah model menjadi terlalu yakin terhadap prediksi sebuah mekanisme regularisasi.

Menariknya, Skenario C menghasilkan akurasi validasi tertinggi (87.22%) di antara ketiga model, meskipun *loss*-nya tidak paling rendah. Ini mengindikasikan bahwa MixUp secara efektif meningkatkan generalisasi model. Meskipun proses konvergennya bisa melambat, hasil akhirnya menunjukkan kinerja yang kuat dan stabil. Maka, dalam konteks ini, MixUp terbukti sebagai teknik yang sangat bermanfaat untuk memperkuat ketahanan model terhadap *overfitting* dan variasi data baru

C. Evaluasi Kinerja Model Pada Data Uji

Evaluasi model dilakukan dengan mengidentifikasi lima prediksi tersulit dari setiap model berdasarkan nilai *loss* tertinggi. Temuan ini memberikan wawasan kritis terkait kelemahan spesifik model dalam mengenali motif batik tertentu, terutama pada kondisi ambiguitas visual

TABEL II
PERBANDINGAN METRIK PELATIHAN AKHIR MODEL

Model	Label Asli	Label Prediksi	<i>Confidence</i>	<i>Loss</i>
Skenario A	Kawung	Sidoluhur	0,9587	5,9667
	Sidoluhur	Parang	0,9958	5,8928
	Truntum	Parang	0,8677	5,7079
	Kawung	Sidoluhur	0,8466	4,9438
	Kawung	Ceplok	0,9029	9,0233
Skenario B	Ceplok	Kawung	0,9986	9,0233
	Nitik	Ceplok	0,9982	8,7313
	Sidoluhur	Kawung	0,9985	6,6886
	Nitik	Kawung	0,9985	6,6070
	Nitik	Truntum	0,9964	5,8685
Skenario C	Truntum	Nitik	0,9342	4,0435
	Nitik	Ceplok	0,9342	3,7321
	Nitik	Truntum	0,9469	3,4483
	Sidoluhur	Kawung	0,6017	3,1931
	Sidoluhur	Ceplok	0,7109	3,1440

Skenario A, dengan model yang dilatih tanpa augmentasi, menunjukkan *loss* prediksi tertinggi sebesar 5.97 pada salah satu sampel batik kawung, di mana motif batik-kawung diprediksi secara keliru sebagai batik sidoluhur meskipun tingkat kepercayaan model mencapai 95.9%. Hal ini menunjukkan bahwa model A memiliki keterbatasan dalam membedakan fitur khas antar kelas yang memiliki kemiripan

visual. Secara umum, kesalahan prediksi Model A cenderung terjadi pada pasangan kelas yang sering memiliki pola simetris atau geometris serupa, seperti batik-kawung dan batik-ceplok atau batik-sidoluhur dan batik-parang.

Skenario B, dengan model yang dilatih dengan augmentasi berupa *random crop* dan *rotate*, justru menunjukkan *loss* tertinggi yang lebih ekstrem. Pada salah satu sampel batik ceplok, model memprediksi motif batik-ceplok sebagai batik-kawung dengan tingkat kepercayaan hampir sempurna (99.86%), menghasilkan *loss* sebesar 9.02. Keempat dari lima prediksi tersulit pada Model B memiliki *confidence* di atas 99%, tetapi salah klasifikasi secara fatal, menunjukkan kecenderungan *overconfidence*. Ini mengindikasikan bahwa augmentasi konvensional saja belum cukup melatih model untuk mengatasi variasi data yang kompleks atau menantang.

Sebaliknya, Skenario C, dengan model yang dilatih dengan tambahan teknik MixUp, menunjukkan performa yang lebih stabil dalam konteks kesalahan prediksi. *Loss* tertinggi pada Model C tercatat sebesar 4.04, hampir setengah dari nilai tertinggi Model B. Selain itu, *confidence* pada prediksi yang salah juga lebih rendah (antara 60%–96%), yang menunjukkan bahwa model memiliki estimasi ketidakpastian yang lebih sehat. Hal ini mengimplikasikan bahwa teknik MixUp efektif dalam mengurangi *overfitting* dan meningkatkan generalisasi terhadap data uji, terutama pada motif batik yang saling tumpang tindih secara visual

V. KESIMPULAN

Penelitian ini telah mengevaluasi kinerja tiga skenario model Resnet 50 dengan skenario augmentasi berbeda-beda dalam klasifikasi motif batik Yogyakarta dengan fokus pada analisis prediksi tersulit berdasarkan nilai *loss* tertinggi. Hasil evaluasi menunjukkan bahwa implementasi teknik augmentasi data memberikan dampak signifikan terhadap kemampuan generalisasi model. Skenario A (tanpa augmentasi) menunjukkan keterbatasan dalam membedakan fitur khas antar kelas dengan kemiripan visual, tercermin dari *loss* tertinggi sebesar 5.97 pada misklasifikasi motif kawung sebagai sidoluhur dengan *confidence* 95.9%. Skenario B (augmentasi konvensional) justru menghasilkan fenomena *overconfidence* yang problematis, dengan *loss* tertinggi mencapai 9.02 dan *confidence* di atas 99% pada prediksi yang salah, mengindikasikan bahwa augmentasi *random crop* dan *flip* belum efektif mengatasi kompleksitas visual motif batik Yogyakarta.

Sebaliknya, Skenario C dengan implementasi teknik MixUp menunjukkan performa superior dengan *loss* tertinggi hanya 4.04 (penurunan hampir 50% dibandingkan Skenario B) dan *confidence* yang lebih realistis (60%–96%) pada prediksi salah. Temuan ini membuktikan bahwa teknik MixUp efektif dalam mengurangi *overfitting* dan meningkatkan estimasi ketidakpastian model, terutama dalam menghadapi ambiguitas visual karakteristik motif batik tradisional Yogyakarta yang memiliki pola geometris dan simetris kompleks.

Dari temuan penelitian ini, kami sarankan teknik MixUp menjadi standar dalam pelatihan model klasifikasi motif batik

untuk meningkatkan kemampuan generalisasi model. Untuk penelitian selanjutnya, perlu dilakukan eksplorasi yang lebih lanjut terhadap teknik augmentasi yang lebih mutakhir seperti CutMix, AutoAugment, atau augmentasi *domain-specific* yang disesuaikan dengan karakteristik motif batik. Teknik *attention mechanism* bisa juga diterapkan untuk melakukan *pinpoint* yang lebih detail terhadap motif batik.

Untuk aplikasi praktis, kami sarankan untuk mengimplementasikan sistem *threshold* dalam menerapkan prediksi ketika model memberikan *confidence* tinggi pada kelas yang secara historis rentan misklasifikasi. Perlu juga dilakukan validasi silang yang berkelanjutan dengan data baru secara berkala untuk memantau konsistensi performa model. Selain itu, perluasan dataset dengan kurasi yang lebih juga diperlukan untuk aplikasi praktis yang akurat dan *foolproof*.

UCAPAN TERIMA KASIH

Penelitian ini dapat terwujud berkat dukungan dari berbagai pihak. Kami mengucapkan terima kasih yang sebesar-besarnya kepada Universitas Pembangunan Nasional "Veteran" Jawa Timur, khususnya Fakultas Ilmu Komputer, atas segala fasilitas dan sumber daya yang telah disediakan. Apresiasi juga kami sampaikan kepada rekan-rekan peneliti atas diskusi dan masukan yang membangun. Secara khusus, kami mengakui bahwa landasan metodologis penelitian ini berhutang budi pada karya-karya fundamental di bidang visi komputer. Kami berterima kasih kepada Kaiming He, Xiangyu Zhang, Shaoqing Ren, dan Jian Sun atas pengembangan arsitektur ResNet yang menjadi tulang punggung model kami. Kami juga berterima kasih kepada Hao Zhang, Moustapha Cisse, Yann N. Dauphin, dan David Lopez-Paz yang inovasinya pada teknik MixUp terbukti krusial dalam meningkatkan generalisasi model, serta kepada Ilya Loshchilov dan Frank Hutter atas penyempurnaan optimizer AdamW yang memastikan proses pelatihan yang stabil dan efektif.

REFERENSI

- [1] Sariyatun, Sariyatun. "Pantulan Budaya Lokal "Makna Filosofis dan Symbolisme Motif Batik Klasik" untuk Penguatan Pendidikan Karakter." *Jurnal Pendidikan Sejarah Indonesia* 1.1 (2018): 23-39.
- [2] A. R. Dani dan I. Handayani, "Klasifikasi motif batik Yogyakarta menggunakan metode GLCM dan CNN," *Jurnal Teknologi Terpadu*, vol. 10, no. 2, hlm. 142-156, 2024.
- [3] J. Sanjaya dan M. Ayub, "Augmentasi data pengenalan citra mobil menggunakan pendekatan *random crop*, *rotate*, dan *MixUp*," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 6, no. 2, Agu. 2020.. Tersedia: <http://dx.doi.org/10.28932/jutisi.v6i2.2688>.
- [4] H. Zhang, M. Cisse, Y. N. Dauphin, dan D. Lopez-Paz, "MixUp: Beyond Empirical Risk Minimization," dalam *Prosiding International Conference on Learning Representations (ICLR)*, Vancouver, 2018.
- [5] C. Shorten dan T. M. Khoshgoftaar, "A survey on image data augmentation for deep learning," *Journal of Big Data*, vol. 6, no. 1, hlm. 60, 2019. doi: 10.1186/s40537-019-0197-0.
- [6] K. He, X. Zhang, S. Ren, dan J. Sun, "Deep Residual Learning for Image Recognition," dalam *Prosiding IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 2016, hlm. 770-778.
- [7] A. Prayoga, P. Sukmasetya, M. R. A. Yudianto, dan R. A. Hasani, "Arsitektur convolutional neural network untuk model klasifikasi citra

- batik Yogyakarta," *Journal of Applied Computer Science and Technology*, vol. 4, no. 2, hlm. 82-89, 2020.
- [8] A. A. Trixie, "Filosofi motif batik sebagai identitas bangsa Indonesia," *Folio*, vol. 1, no. 1, hlm. 1-9, 2020.
- [9] R. W. Tanjung, S. Suryaningsum, A. N. Maharani, R. H. Gusaptono, dan S. L. Murdianingrum, "Batik Yogyakarta dalam era revolusi industri 4.0," dalam *Prosiding Seminar Nasional Industri Kerajinan dan Batik*, Yogyakarta, Indonesia, 2019, vol. 1, no. 1, hlm. A3-1-A3-9.
- [10] A. Wulandari, *Batik Nusantara: Makna Filosofis, Cara Pembuatan, dan Industri Batik*. Yogyakarta, Indonesia: Penerbit Andi, 2022.
- [11] M. D. A. Pranatha, G. H. Setiawan, dan M. A. Maricar, "Utilization of ResNet Architecture and Transfer Learning Method in the Classification of Faces of Individuals with Down Syndrome," *Journal of Applied Informatics and Computing*, 2024.
- [12] R. Z. Fadillah, A. Irawan, dan M. Susanty, "Data augmentasi untuk mengatasi keterbatasan data pada model penerjemah bahasa isyarat Indonesia (BISINDO)," *Jurnal Informatika*, vol. 8, no. 2, hlm. 208-214, 2021.
- [13] M. R. Satria dan J. Pardede, "Image captioning menggunakan metode ResNet50 dan long short term memory," *Jurnal Tera*, vol. 2, no. 2, hlm. 84-94, 2022.
- [14] M. R. Farhansyah, "Batik Pattern Classification Repository," Repositori GitHub, 2022.. Tersedia: <https://github.com/rifqifarhansyah/batik-pattern-classification>.
- [15] A. E. Minarno dan N. Suciati, "Batik 300: A comprehensive dataset for batik pattern recognition," *Data in Brief*, vol. 40, hlm. 107694, 2022. doi: 10.1016/j.dib.2022.107694.
- [16] J. Deng, dkk., "ImageNet: A large-scale hierarchical image database," dalam *Prosiding 2009 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Miami, FL, USA, 2009, hlm. 248-255.
- [17] M. Buda, A. Maki, dan M. A. Mazurowski, "A systematic study of the class imbalance problem in convolutional neural networks," *Neural Networks*, vol. 106, hlm. 249-259, 2018.
- [18] I. Goodfellow, Y. Bengio, dan A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016.
- [19] R. Kohavi, "A study of cross-validation and bootstrap for accuracy estimation and model selection," dalam *Prosiding 14th International Joint Conference on Artificial Intelligence (IJCAI)*, Montreal, Canada, 1995, vol. 2, hlm. 1137-1143.
- [20] F. Chollet, *Deep Learning with Python*. Shelter Island, NY, USA: Manning Publications, 2017.
- [21] A. Krizhevsky, I. Sutskever, dan G. E. Hinton, "ImageNet classification with deep convolutional neural networks," dalam *Advances in Neural Information Processing Systems 25 (NIPS)*, 2012, hlm. 1097-1105.
- [22] J. Pardede dan A. S. Purohita, "The advantage of transfer learning with pre-trained model in CNN towards CT-scan classification," *Khazanah Informatika: Jurnal Ilmu Komputer dan Informatika*, vol. 9, no. 2, hlm. 155-161, 2023.
- [23] I. Loshchilov dan F. Hutter, "Decoupled Weight Decay Regularization," dalam *Prosiding International Conference on Learning Representations (ICLR)*, New Orleans, LA, USA, 2019.
- [24] L. Prechelt, "Early stopping — But when?," dalam *Neural Networks: Tricks of the Trade*, G. Montavon, G. B. Orr, dan K.-R. Müller, Ed., ed. ke-2. Berlin, Heidelberg: Springer, 2012, hlm. 53-67.