

Analisis Laju Pembelajaran untuk Pengenalan Nyeri Melalui Metode Viola-Jones dan Pembelajaran Mendalam

Raihan Islamadina^{1,2}, Khairun Saddami³, Fitri Arnia³, Taufik Fuadi Abidin³, Rusdha Muharar³, Muhammad Irwandi², Aulia Syarif Aziz²

¹ Program Doktor Ilmu Teknik, Fakultas Teknik, Universitas Syiah Kuala, Banda Aceh, Aceh 23111, Indonesia

² Program Studi Pendidikan Teknologi Informasi, Fakultas Tarbiyah dan Keguruan, Universitas Islam Negeri Ar-Raniry, Banda Aceh, Aceh 23111, Indonesia

³ Departemen Teknik Elektro dan Teknik Komputer, Fakultas Teknik, Universitas Syiah Kuala, Banda Aceh, Aceh 23111, Indonesia

[Diserahkan: 30 Agustus 2023, Direvisi: 1 November 2023, Diterima: 14 Maret 2024]

Penulis Korespondensi: Fitri Arnia (email: f.arnia@unsyiah.ac.id)

INTISARI — Pembelajaran mendalam (*deep learning*) makin berkembang dan digunakan secara luas di berbagai bidang kehidupan. Salah satunya adalah pengenalan rasa nyeri melalui ekspresi pasien yang memiliki kesulitan berkomunikasi. Viola-Jones adalah algoritma sederhana yang memiliki kemampuan deteksi waktu nyata dengan akurasi cukup tinggi dan kebutuhan daya komputasi rendah. Laju pembelajaran merupakan parameter yang secara signifikan berdampak pada hasil pembelajaran mendalam. Penelitian ini mengenali rasa nyeri menggunakan metode Viola-Jones dan pembelajaran mendalam. *Dataset* yang digunakan adalah citra termal yang diperoleh dari basis data Multimodal Intensity Pain (MIntPAIN). Langkah-langkah yang dilakukan meliputi segmentasi, pelatihan, dan pengujian. Segmentasi dilakukan dengan menggunakan metode Viola-Jones untuk mendapatkan area penting citra wajah. Proses pelatihan dilakukan dengan menggunakan empat model *benchmark* pembelajaran mendalam, yaitu DenseNet201, MobileNetV2, ResNet101, dan EfficientNetb0. Selain itu, pembelajaran mendalam memiliki sebuah parameter yang sangat penting untuk ditentukan, yaitu laju pembelajaran, yang berdampak pada hasil pembelajaran mendalam. Terdapat lima nilai laju pembelajaran, yaitu 10^{-1} , 10^{-2} , 10^{-3} , 10^{-4} , dan 10^{-5} . Nilai laju pembelajaran kemudian dibandingkan dengan empat model pembelajaran mendalam untuk mendapatkan hasil akurasi yang tinggi dalam waktu singkat dan dengan algoritma yang sederhana. Terakhir, proses pengujian dilakukan pada data uji menggunakan tolok ukur pembelajaran mendalam yang sesuai dengan proses pelatihan. Hasil penelitian menunjukkan bahwa laju pembelajaran sebesar 10^{-2} dari metode MobileNetV2 menghasilkan kinerja yang optimal dengan akurasi validasi pelatihan sebesar 99,60% dalam waktu 05.12.28 jam.

KATA KUNCI — Pengenalan Rasa Nyeri, Metode Viola-Jones, Laju Pembelajaran, Pembelajaran Mendalam, Akurasi.

I. PENDAHULUAN

Manusia memiliki kecenderungan alamiah untuk memanifestasikan emosinya melalui ekspresi wajah, yang merupakan media komunikasi nonverbal yang kuat. Fenomena pemanfaatan isyarat wajah untuk mengungkapkan emosi ini memiliki hubungan yang signifikan dalam konteks evaluasi rasa nyeri [1]. Biasanya, penilaian nyeri sangat bergantung pada deskripsi verbal seseorang. Namun, permasalahan dapat muncul pada kasus individu yang menderita penyakit terminal dan tidak mampu berkomunikasi secara konvensional, sehingga pengungkapan rasa nyeri menjadi sebuah teka-teki yang cukup rumit untuk dipecahkan. Hal ini tentu saja dapat berpotensi menyebabkan salah tafsir dan kekeliruan penarikan kesimpulan.

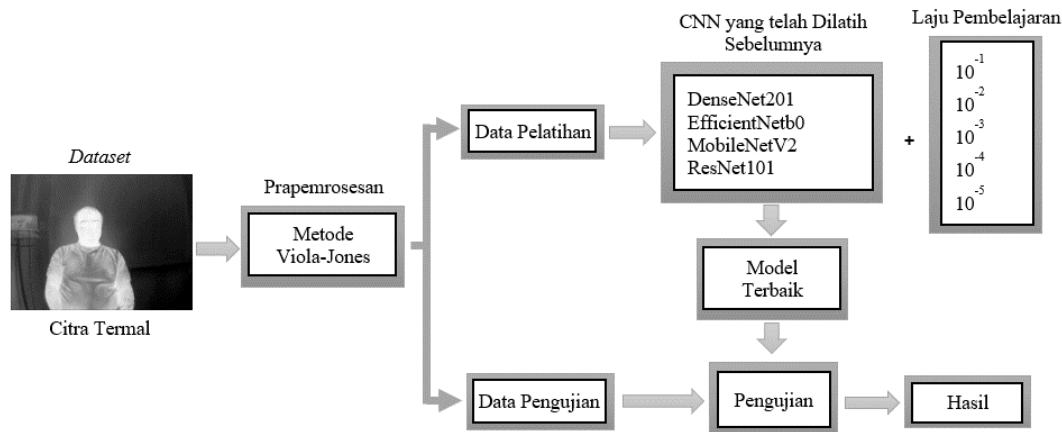
Identifikasi rasa nyeri melalui analisis ekspresi wajah merupakan tantangan yang rumit dengan banyak aspek, sehingga membutuhkan pengembangan dan implementasi metodologi yang cukup tangguh. Proses pengenalan wajah mencakup tiga fase penting, yaitu deteksi awal wajah, ekstraksi fitur yang berbeda-beda, dan pengenalan atribut wajah. Dalam bidang deteksi wajah, algoritma yang diusulkan oleh Viola-Jones merupakan solusi yang paling terkenal dan banyak diadopsi secara luas [2]. Algoritma ini dikenalkan pada tahun 2001 [3].

Terkenal akan efektivitasnya, algoritma Viola-Jones telah banyak dipuji terutama karena kesederhanaan dan kemahirannya yang luar biasa dalam mendeteksi wajah secara

waktu nyata. Pendekatan ini menawarkan keseimbangan yang luar biasa antara akurasi dan kebutuhan sumber daya komputasi, sehingga banyak digunakan pada berbagai aplikasi [4]–[6]. Kapasitas inheren algoritma untuk deteksi yang cepat dan akurat menjadikan algoritma ini alat yang sangat dibutuhkan, terutama untuk skenario yang membutuhkan respons dan efisiensi yang baik.

Eksplorasi pengenalan nyeri merupakan bukti keberhasilan konvergensi di ranah metodologi pembelajaran mendalam (*deep learning*), yang menandai kemajuan signifikan dalam domain ini [7]. Pembelajaran mendalam digunakan untuk ekstraksi fitur-fitur yang rumit, sehingga dapat membantu mendeteksi nyeri melalui analisis ekspresi wajah [8], [9]. Selain itu, penelitian penting lainnya telah memanfaatkan ketangguhan pembelajaran mendalam untuk menavigasi lanskap pengenalan rasa nyeri, secara khusus berfokus pada intensitas rasa nyeri yang dilaporkan sendiri oleh penderita menggunakan *visual analogue scale* (VAS) [10].

Teknik pembelajaran mendalam dalam bidang pengenalan nyeri terus berkembang dengan memanfaatkan *dataset* citra RGB yang luas yang bersumber dari basis data Multimodal Intensity Pain (MIntPAIN). Sebuah penelitian penting telah menghasilkan tingkat akurasi yang mengesankan, yaitu sebesar 92,26% [11]. Pencapaian ini sama dengan penelitian lain yang menghasilkan tingkat akurasi sebesar 92,44%, sehingga menegaskan kembali kemampuan metodologi pembelajaran mendalam dalam menangani tugas rumit pengenalan rasa nyeri



Gambar 1. Tahapan penelitian.

[12]. Selain itu, cakrawala aplikasi pembelajaran mendalam diperluas untuk mencakup pemanfaatan *dataset* citra termal dari basis data MIntPAIN, sebagaimana ditunjukkan oleh penelitian sebelumnya [13]. Upaya tersebut menghasilkan tingkat akurasi yang cukup tinggi, yaitu sebesar 83,5%, sehingga menekankan keserbagunaan pendekatan pembelajaran mendalam dalam domain pengenalan rasa nyeri yang beragam.

Penelitian ini merupakan sebuah evolusi signifikan yang dibangun di atas landasan yang sudah ditetapkan oleh penelitian sebelumnya [13], yang berfokus pada identifikasi rasa nyeri dengan memanfaatkan kombinasi Viola-Jones dan metodologi pembelajaran mendalam. Dalam upaya yang progresif ini, *dataset* inti yang diteliti terdiri atas citra termal yang diekstrak dari basis data MIntPain. Lintasan metodologis meliputi tahap-tahap yang berbeda, yaitu segmentasi, pelatihan, dan pengujian lanjutan.

Tahap awal, yaitu segmentasi, mengacu pada metode Viola-Jones, yang secara efektif menunjukkan area penting pada citra wajah untuk tugas pengenalan rasa nyeri. Langkah strategis ini berfungsi sebagai mekanisme penyaringan awal, yang memilah-milah data visual untuk diidentifikasi fitur-fitur menonjolnya. Tahap selanjutnya adalah tahap pelatihan. Tahap ini dilakukan dengan memanfaatkan kehebatan empat *benchmark* pembelajaran mendalam sebagai pilar dasar. Keempat tolok ukur ini meliputi berbagai macam model, yaitu model *dense convolutional network model* (DenseNet201) [14], MobileNetV2 [15], *residual network* (ResNet101) [16], dan EfficientNetb0 [17].

Hal lain yang turut menentukan keberhasilan penelitian ini adalah penentuan laju pembelajaran, yang merupakan sebuah hiperparameter yang sangat penting untuk mengatur tingkat penyesuaian model sebagai respons terhadap estimasi kesalahan selama bobot diperbarui [18]. Dalam upaya ini, digunakan lima laju pembelajaran, yaitu 10^{-1} , 10^{-2} , 10^{-3} , 10^{-4} , dan 10^{-5} . Masing-masing laju pembelajaran ini memainkan peranan penting dalam membentuk hasil dari proses pembelajaran mendalam berikutnya [18].

Pada dasarnya, penelitian ini berusaha untuk membandingkan keempat model pembelajaran mendalam yang berbeda secara komprehensif, kemudian menyandingkan kinerja model-model tersebut dengan variasi nilai laju pembelajaran. Terdapat dua tujuan utama, yaitu mencapai tingkat akurasi yang lebih tinggi dalam jangka waktu yang lebih singkat dan mempertahankan kesederhanaan yang melekat pada metodologi algoritmik yang digunakan.

Tahap terakhir dari penelitian ini adalah pengujian ketat terhadap model yang telah dikembangkan. Data yang secara khusus digunakan untuk validasi diuji dengan cermat menggunakan model tolok ukur pembelajaran mendalam yang sama dengan model yang sudah dikembangkan pada tahap pelatihan. Kesesuaian antara model pelatihan dan pengujian ini digunakan untuk autentikasi translasi kerangka kerja yang dikembangkan, memastikan bahwa informasi yang diperoleh dari proses pelatihan terwujud dengan baik dalam skenario dunia nyata.

II. METODOLOGI

Tahap-tahap yang dilakukan dalam penelitian ini disajikan pada Gambar 1.


A. PENGUMPULAN DATA

Untuk tujuan penelitian ini, *dataset* yang dianalisis berasal dari basis data MIntPAIN, khususnya dalam format citra termal. Basis data ini memiliki 9.366 variabel yang berasal dari 20 subjek [19]. Untuk membantu proses evaluasi yang komprehensif, *dataset* dibagi secara sistematis menjadi dua bagian yang berbeda: *dataset* pelatihan dan *dataset* pengujian.

Dataset pelatihan terdiri atas 5.000 citra termal, sedangkan *dataset* pengujian terdiri atas 1.600 citra. *Dataset* ini secara kolektif mencakup spektrum intensitas nyeri dengan total lima tingkat nyeri yang berbeda; masing-masing dimulai dari tingkat 0, yang menunjukkan “tidak terasa nyeri”, hingga tingkat 4 yang menandakan “nyeri yang paling berat,” seperti yang ditunjukkan pada Gambar 2. Kategorisasi tingkat nyeri ini menawarkan perspektif bernuansa yang menangkap keragaman pengalaman nyeri, sehingga membantu dalam melatih dan memvalidasi model untuk pengenalan rasa nyeri yang efektif.

B. PRAPEMROSESAN DATA

Tahap prapemrosesan data dalam penelitian ini dilakukan dengan cara menerapkan metode Viola-Jones yang andal. Viola-Jones adalah sebuah teknik yang digunakan untuk mengekstrak area wajah pada citra. Langkah awal ini melibatkan manipulasi citra masukan dengan cara secara efektif mengisolasi dan mengekstrak komponen wajah yang teridentifikasi sebagai bagian penting analisis selanjutnya. Proses ini diawali dengan penggunaan teknik fitur *Haar-like*, yang merupakan sebuah metode yang secara sistematis membagi citra menjadi beberapa area terpisah, dimulai dari sudut kiri atas ke sudut kanan bawah. Peningkatan mendasar teknik ini adalah penggabungan prosedur *integral image*, yang merupakan sebuah strategi komputasi yang dirancang untuk mempercepat pendeteksian objek [3].



Gambar 2. Dataset tingkat rasa nyeri, (a) citra RGB wajah, (b) citra termal wajah.


Sebuah langkah mutakhir ditambahkan, yaitu penggunaan teknik Adaptive Boosting. Pada teknik ini, beberapa *classifier* lemah digabung ke *classifier* yang lebih kuat. Teknik ini berfungsi sebagai sebuah mekanisme untuk secara sinergis memanfaatkan kekuatan *classifier* yang lemah, sehingga menghasilkan formulasi *classifier* yang kuat dan andal. Proses ini dimulai dengan perhitungan bobot, kemudian diikuti dengan evaluasi nilai fitur untuk setiap *classifier* lemah [3]. Keputusan selanjutnya bergantung pada penilaian nilai fitur ini; jika nilainya di bawah 0, citra dikategorikan tidak memiliki objek. Sebaliknya, jika nilainya melebihi 1, citra dianggap memiliki objek. Pendekatan *cascade classifier* meningkatkan kompleksitas dengan mengintegrasikan *classifier* yang rumit ke dalam kerangka kerja hierarkis, sehingga menghasilkan deteksi objek yang lebih cepat.

Puncak dari tahap prapemrosesan ini ditandai dengan penerapan teknik *bounding box* yang berperan penting dalam membatasi dan menggambarkan entitas wajah yang terdeteksi [3]–[5]. Proses ini dilakukan untuk mengisolasi area wajah penting. Strategi ini kemudian diterapkan pada kumpulan data citra pelatihan dan pengujian. Area wajah yang digambarkan kemudian dipotong (*cropping* atau *truncating*), sehingga menghasilkan ekstraksi kontur wajah tertentu. Strategi pemotongan ini penting karena dapat membantu proses identifikasi kontur wajah selanjutnya, sehingga secara efektif menyederhanakan keseluruhan proses. Prosedur ini juga menyebabkan terjadinya transformasi dimensi citra, yaitu dari 640×480 piksel menjadi 104×104 piksel. Dengan kata lain, citra menjadi lebih ringkas setelah tahapan pemotongan dilakukan. Representasi visual dari hasil prosedur pemotongan *bounding box* dan area wajah dapat diamati pada Gambar 3. Gambar ini menyajikan gambaran sekilas hasil yang dicapai pada tahap prapemrosesan ini.

C. PELATIHAN DATA

Dalam penelitian ini, proses pelatihan dilakukan melalui integrasi teknik pembelajaran transfer (*transfer learning*) dengan model *convolutional neural network* (CNN) yang sebelumnya telah dilatih. Mengingat pentingnya efisiensi dan kemanfaatan, pendekatan ini menggunakan model yang sudah ada, seperti DenseNet201, EfficientNetb0, MobileNetV2, dan ResNet101.

DenseNet201 membangun koneksi antara setiap lapisan dengan cara *feed-forward*. Prinsip kerja DenseNet201 melibatkan penggabungan keluaran lapisan sebelumnya. Awalnya, ukuran citra $28 \times 28 \times 3$ disebarkan di 24 saluran, sehingga menghasilkan ukuran citra $28 \times 28 \times 24$. Selanjutnya, 12 fitur dengan lebar dan tinggi yang sama digunakan di setiap lapisan konvolusi berikutnya, sehingga menghasilkan lapisan keluaran $28 \times 28 \times 12$. Masukan pada lapisan berikutnya adalah



Gambar 3. Representasi visual (a) citra *bounding box* pada area wajah, (b) area wajah yang dipotong.

$28 \times 28 \times 24 + 12$; kemudian, pada lapisan berikutnya adalah $28 \times 28 \times 24 + 12 + 12$, dan seterusnya. Dengan cara ini, DenseNet201 dapat mengurangi *overfitting* dan menggunakan lebih sedikit parameter [14].

MobileNetV2 dapat meningkatkan kinerja model *mobile* dalam berbagai tugas dan tolok ukur di seluruh spektrum ukuran model yang berbeda. MobileNetV2 didasarkan pada struktur residu terbalik yang koneksi *bypass*-nya berada di antara lapisan tipis *bottleneck*. Arsitektur MobileNet diubah dengan mengganti operator konvolusi penuh dengan faktorisasi yang membagi konvolusi menjadi dua lapisan, yaitu *depthwise convolution layer* dan *pointwise convolution layer* [15].

ResNet101 adalah model terlatih yang dapat mengelola lapisannya tanpa memerlukan konfigurasi khusus. ResNet101 digunakan untuk mengatasi penurunan kinerja pada jaringan dalam. Model ini dapat membangun jaringan yang lebih dalam dan menemukan jumlah lapisan yang dioptimalkan untuk gradien yang hilang. ResNet101 memiliki 101 lapisan dan mampu mengklasifikasikan 1.000 kategori citra [16].

EfficientNetb0 melakukan penskalaan semua dimensi, dari kedalaman, lebar, dan resolusi, secara seragam menggunakan koefisien majemuk, sehingga memberikan kinerja yang lebih

TABEL I
JARINGAN YANG TELAH DILATIH SEBELUMNYA

Jaringan	Kedalaman	Ukuran (MB)	Parameter (juta)	Ukuran Masukan Citra
DenseNet201	201	77	20,0	224 × 224
EfficientNetb0	82	20	5,3	224 × 224
MobileNetV2	53	13	3,5	224 × 224
ResNet101	101	167	44,6	224 × 224

baik. Menggunakan parameter yang lebih sedikit, EfficientNet mampu melakukan transfer dengan baik dan mencapai akurasi terbaik pada CIFAR-100 (91,7%), *flower* (98,8%), dan tiga *dataset* pembelajaran transfer lainnya [17]. Model-model ini dilengkapi dengan pengetahuan yang sebelumnya sudah ada dan pola-pola yang diekstrak dari banyak pelatihan *dataset*, sehingga menjadikannya sebagai titik awal yang optimal untuk pelatihan lebih lanjut.

Pembelajaran transfer, yang merupakan aspek utama dari pendekatan ini, beroperasi dengan menggunakan model yang sudah dilatih sebagai kerangka pendukung dasar dan kemudian menyempurnakan parameternya melalui *fine-tuning* untuk menyelaraskannya dengan *dataset* baru yang akan digunakan. Teknik ini memanfaatkan kekayaan pengetahuan yang terangkum dalam model yang sudah dilatih. Selain itu, melalui penyesuaian berulang, teknik ini dapat beradaptasi dengan berbagai fitur tertentu dan seluk-beluk *dataset* target. Tujuan utama dari pembelajaran transfer adalah untuk memanfaatkan kemampuan model yang sebelumnya sudah ada dalam domain aslinya dan memperluas kegunaannya untuk menyelesaikan masalah di domain yang berbeda.

Model yang sudah terlatih berfungsi sebagai pengekstrak fitur, menyaring representasi citra tingkat tinggi yang memiliki signifikansi di berbagai domain. Dengan menyesuaikan parameter model yang sebelumnya telah dilatih sehingga selaras dengan *dataset* baru, kemampuan model disesuaikan dengan kompleksitas tugas tertentu.

Pendekatan pelatihan ini memiliki beberapa manfaat, sebagaimana disajikan pada Tabel I. Model yang sebelumnya telah dilatih tidak hanya menghasilkan akurasi yang tinggi, tetapi juga menghasilkan kecepatan dan kekompatan, sehingga menjadikannya pilihan yang sangat tepat untuk tujuan penelitian ini. Dengan membangun dasar yang telah dibuat oleh model-model tersebut, penelitian ini mencapai sintesis dari pengetahuan yang ada dan wawasan baru, berupa kerangka pengenalan nyeri yang efisien dan efektif.

Proses pembelajaran transfer dalam penelitian ini dilakukan dengan cermat melalui pemanfaatan Deep Learning Toolbox™ MATLAB yang canggih. *Toolbox* khusus ini menawarkan kerangka kerja yang kuat, sehingga mendorong para peneliti dan praktisi untuk merancang dan menggunakan *deep neural network* (DNN) dengan lancar, serta memanfaatkan berbagai algoritma, jaringan yang sudah terlatih, dan metodologi aplikasi model. Integrasi saling menguntungkan dari sumber daya ini mampu menyederhanakan proses pembelajaran transfer dan mengoptimalkan implementasinya.

Penelitian ini memanfaatkan ketangguhan jaringan yang sudah terlatih sebagai landasan pembelajaran transfer. Jaringan-jaringan yang sudah terlatih ini berfungsi sebagai dasar tugas pengenalan rasa nyeri dalam penelitian ini. Kelincahan dan efisiensi yang ditawarkan oleh jaringan yang sudah terlatih ini secara signifikan mempercepat proses

TABEL II
PARAMETER YANG DIGUNAKAN PADA DESAIN MODEL DENSENET201, MOBILENETV2, RESNET101, DAN EFFICIENTNETB0

Parameter	DenseNet201, ResNet101, dan EfficientNetb0 Models
<i>Epoch</i>	100
<i>Minibatch</i>	24
<i>Optimizer</i>	<i>Stochastic gradient descent</i> (SGD)
Laju Pembelajaran Awal	10^{-1} , 10^{-2} , 10^{-3} , 10^{-4} , dan 10^{-5}
<i>Momentum Optimizer</i>	0,9
<i>WeightLearnRateFactor</i>	10
<i>BiasLearnRateFactor</i>	10

pembelajaran, sehingga model dapat dengan cepat beradaptasi dengan rumitnya *dataset* baru. Pembelajaran transfer biasanya digunakan dalam aplikasi pembelajaran mendalam. Jaringan yang sudah terlatih dapat diambil dan digunakan sebagai titik awal untuk mempelajari tugas baru. Menyempurnakan jaringan dengan pembelajaran transfer jauh lebih cepat dan lebih mudah daripada melakukan pelatihan dari awal. Keuntungan dari pembelajaran transfer adalah jaringan yang telah terlatih sudah mempelajari banyak fitur yang dapat diterapkan pada berbagai tugas serupa lainnya. Pembelajaran transfer menawarkan beberapa keuntungan: memungkinkan untuk mentransfer fitur-fitur yang telah dipelajari dari jaringan yang telah terlatih ke permasalahan baru, lebih cepat dan lebih mudah daripada melatih jaringan baru, mengurangi waktu pelatihan dan ukuran *dataset*, dan melakukan pembelajaran mendalam tanpa perlu mempelajari cara membuat jaringan yang baru [20].

Untuk menerapkan model-model yang telah terlatih di MATLAB ini, langkah awal yang penting adalah pemasangan model yang telah terlatih melalui perintah *add-ons* [21]. Prosedur pemasangan ini sangat penting untuk dilakukan agar integrasi model ke dalam kerangka kerja MATLAB berjalan lancar, sehingga memungkinkan penerapannya pada tahap-tahap penelitian selanjutnya. Pengaturan yang cermat terhadap proses pembelajaran transfer dalam Deep Learning Toolbox™ pada MATLAB menekankan komitmen penelitian ini untuk memanfaatkan alat dan teknik yang mutakhir demi tercapainya tujuan penelitian.

Selain itu, *fine-tuning* dilakukan dengan mengatur nilai hiperparameter yang terdiri atas *initial learning rate* (ILR), jumlah *epoch* maksimum, ukuran *minibatch*, momentum, dan *optimizer*, serta mempertimbangkan durasi minimum dan nilai akurasi maksimum. Parameter yang digunakan untuk merancang model, yaitu DenseNet201, MobileNetV2, ResNet101, dan EfficientNetb0, ditunjukkan pada Tabel II. Model dilatih dengan *epoch* sejumlah 100, menggunakan momentum 0,9, dan ukuran *minibatch* 24. Parameter *WeightLearnRateFactor* dan *BiasLearnRateFactor* ditetapkan sebesar 10 menggunakan *stochastic gradient descent* (SGD) *optimizer*, dengan laju pembelajaran awal yaitu 10^{-1} , 10^{-2} , 10^{-3} , 10^{-4} , dan 10^{-5} [21]. Laju pembelajaran merupakan salah satu parameter pelatihan untuk menghitung nilai koreksi bobot selama proses pelatihan [18]. Nilai laju pembelajaran yang paling ideal adalah nilai yang menghasilkan tingkat akurasi optimal dan tidak membutuhkan waktu pelatihan yang lama.

D. PENGUJIAN DATA

Evaluasi pengujian data dalam penelitian ini mengacu pada keluaran yang dihasilkan selama proses pelatihan menggunakan model pembelajaran mendalam yang optimal

TABEL III
PERBANDINGAN MODEL PEMBELAJARAN MENDALAM DENGAN LAJU PEMBELAJARAN

		Model Pembelajaran Mendalam			
		DenseNet201	EfficientNetb0	MobileNetV2	ResNet101
Laju Pembelajaran 10 ⁻¹	VA (%)	93,00	96,20	99,00	97,00
	ET	2.039'' 28'	558'' 20'	325'' 32'	2.219'' 37'
Laju Pembelajaran 10 ⁻²	VA (%)	99,60	99,60	99,60	99,00
	ET	2.000'' 52'	578'' 25'	312'' 28'	3.508'' 2'
Laju Pembelajaran 10 ⁻³	VA (%)	99,60	99,40	99,60	99,60
	ET	2.138'' 18'	579'' 41'	336'' 27'	3.501'' 14'
Laju Pembelajaran 10 ⁻⁴	VA (%)	99,40	99,20	99,20	99,00
	ET	2.132'' 25'	585'' 44'	342'' 31'	3.524'' 27'
Laju Pembelajaran 10 ⁻⁵	VA (%)	99,40	85,60	99,00	99,00
	ET	2.100'' 42'	558'' 37'	330'' 13'	3.529'' 15'

Catatan:
VA = Validation accuracy (100%)
ET = Elapsed time

dan laju pembelajaran dengan tingkat akurasi tertinggi. Penilaian hasil pengujian melibatkan analisis yang komprehensif, mencakup akurasi, *recall*, presisi, dan metrik evaluasi kritis *F1-score* yang dihitung melalui persamaan berikut:

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$Sensitivitas (Recall) = \frac{TP}{TP+FN} \quad (2)$$

$$Presisi = \frac{TP}{TP+FP} \quad (3)$$

$$F1 - Score = 2 \times \frac{recall \times presisi}{recall + presisi} \quad (4)$$

Persamaan (1) sampai dengan (4) berperan penting dalam penghitungan nilai akurasi. Nilai akurasi sendiri merupakan indikator kemampuan model yang sangat penting dalam mengklasifikasikan citra. Dalam hal ini, setiap persamaan merangkum berbagai aspek kinerja model yang berbeda, sehingga memberikan pandangan holistik tentang kemampuan klasifikasi setiap model.

True positive (TP) menandakan klasifikasi akurat dari sampel positif, yang menunjukkan keberhasilan identifikasi citra yang menggambarkan rasa nyeri. Sebaliknya, komponen *true negative* (TN) menunjukkan klasifikasi yang benar dari sampel negatif, yang menandakan citra tanpa rasa nyeri. Skenario *false positive* (FP) terjadi ketika sampel negatif secara keliru dikategorikan sebagai sampel positif, sedangkan *false negative* (FN) muncul ketika sampel positif dilabeli sebagai sampel negatif. Keempat elemen ini bersama-sama membantu menguraikan interaksi rumit dari hasil klasifikasi.

Metrik akurasi yang menyeluruh merangkum kinerja komprehensif sistem di semua titik data, menekankan kapasitasnya untuk mengategorikan contoh positif dan negatif dengan tepat. Sensitivitas (dikenal sebagai *true positive rate* atau *recall*), yang merupakan sebuah parameter yang memerlukan klasifikasi data positif yang akurat, digunakan untuk mengukur kemampuan sistem dalam mengidentifikasi individu yang menunjukkan atribut positif (dalam kasus ini, mengalami rasa nyeri).

Positive predictive value (PPV) adalah ukuran statistik yang menunjukkan besarnya kemungkinan hasil tes positif adalah benar. PPV dihitung dengan membagi jumlah TP dengan jumlah total hasil tes positif. PPV memainkan peranan penting dalam menilai ketepatan model dalam mengidentifikasi

citra yang berhubungan dengan rasa nyeri dalam prediksi kelas positif total. Metrik ini memberikan informasi tentang keakuratan sistem dalam menunjukkan contoh rasa nyeri pada konteks yang lebih luas dari prediksi positif [13], [22]. Melalui integrasi persamaan dan metrik ini, penelitian ini tidak hanya mengukur efektivitas model, tetapi juga menumbuhkan pemahaman tentang kemampuan dan keterbatasan model dalam tugas pengenalan rasa nyeri.

III. HASIL PENELITIAN

Hasil akhir dari upaya pembelajaran mendalam dipengaruhi oleh berbagai faktor. Salah satu faktor penentu yang terpenting adalah laju pembelajaran. Dalam tahap pelatihan, penelitian ini menggunakan model pembelajaran mendalam yang dirancang dengan cermat dan dengan analisis yang ketat yang bergantung pada laju pembelajaran 10⁻¹, 10⁻², 10⁻³, 10⁻⁴, dan 10⁻⁵. Proses pelatihan diulang sebanyak seratus *epoch*, meliputi berbagai siklus pembelajaran dan adaptasi.

Selama tahap pelatihan, model melewati proses penyempurnaan secara bertahap menggunakan data pelatihan yang tersedia. Setelah tahap pelatihan, efektivitas model diuji dengan menilai kinerjanya pada data uji. Penilaian dilakukan dengan menggunakan parameter akurasi validasi dan *elapsed time*. Keduanya merupakan aspek integral yang memberikan informasi mengenai efektivitas dan efisiensi model.

Metodologi validasi yang digunakan adalah validasi silang, yang merupakan sebuah teknik yang dicirikan oleh penyusunan beberapa iterasi pelatihan untuk mendapatkan nilai yang optimal. Pendekatan multifaset ini memastikan bahwa kinerja model dievaluasi dengan cermat, sehingga dari proses berulang ini diperoleh nilai akurasi validasi yang paling optimal.

Tujuan utama perbandingan laju pembelajaran ini adalah untuk memastikan konfigurasi paling optimal yang dapat menghasilkan hasil kinerja yang luar biasa, yang ditandai dengan meningkatnya akurasi dan semakin efisien waktu pelatihan. Melalui analisis dan evaluasi komprehensif terhadap interaksi antara laju pembelajaran, akurasi validasi, dan *elapsed time*, penelitian ini bertujuan untuk mengetahui gabungan terbaik, sehingga dapat membekali para peneliti dan praktisi dalam studi pembelajaran mendalam yang efektif dalam domain pengenalan rasa nyeri.

Hasil pelatihan yang berasal dari interaksi antara model pembelajaran mendalam dan berbagai laju pembelajaran dirinci secara komprehensif dalam Tabel III. Selama tahap pelatihan, laju pembelajaran sebesar 10⁻² menjadi laju pembelajaran yang sangat berpengaruh, yang memberikan hasil akurasi validasi

TABEL IV
CONFUSION MATRIX DARI MODEL PEMBELAJARAN MENDALAM

Model	Akurasi (%)	Sensitivitas	Presisi	F1-Score
DenseNet201	81,1	81,06	81,52	81,29
EfficientNetb0	78,2	78,24	78,46	78,35
MobileNetV2	79,4	79,38	80,04	79,80
ResNet101	78,2	78,24	78,58	78,41

luar biasa di seluruh model DenseNet201, EfficientNetb0, dan MobileNetV2. Model-model ini menunjukkan akurasi yang mengesankan sebesar 99,60%, ditambah dengan *elapsed time* selama 33.20.52 jam untuk DenseNet201, 09.38.25 jam untuk EfficientNetb0, dan 05.12.28 jam untuk MobileNetV2.

Namun demikian, model ResNet101 menunjukkan kinerja yang paling luar biasa. Model ini mencapai akurasi tertinggi, yaitu sebesar 99,60%. Kinerja ini dicapai pada laju pembelajaran 10^{-3} , serta *elapsed time* 58.21.14 jam.

Dari hasil ini, terlihat bahwa 10^{-2} merupakan laju pembelajaran optimal untuk model pembelajaran mendalam, khususnya MobileNetV2. Analisis yang seksama ini menekankan interaksi antara laju pembelajaran, arsitektur model, dan metrik kinerja, yang pada akhirnya dapat menyingkap konfigurasi yang ideal untuk tugas klasifikasi rasa nyeri melalui ekspresi wajah.

Selanjutnya, pada tahap pengujian data, digunakan *dataset* baru yang berbeda dari data pelatihan. Tahap ini merupakan tahapan yang penting dalam evaluasi kinerja model klasifikasi rasa nyeri melalui ekspresi wajah. Proses evaluasi dilakukan dengan menggunakan *confusion matrix* untuk mengukur sensitivitas, presisi, dan nilai *F1-score* model.

Untuk melakukan evaluasi ini, laju pembelajaran 10^{-2} digunakan secara seragam di seluruh model DenseNet201, EfficientNetb0, dan MobileNetV2. Sebaliknya, model ResNet101 menggunakan laju pembelajaran 10^{-3} . Hal ini dilakukan dengan mempertimbangkan kemampuan model untuk mencapai akurasi tertinggi selama tahap pelatihan. Dengan menyempurnakan parameter laju pembelajaran secara cermat, penelitian ini berupaya untuk mengoptimalkan potensi penuh model dan mencapai hasil kinerja yang optimal dalam domain klasifikasi nyeri.

Hasil dari analisis *confusion matrix*, sebagaimana ditunjukkan pada Tabel IV, memberikan informasi penting tentang kinerja model DenseNet201, EfficientNetb0, MobileNetV2, dan ResNet101. Masing-masing model yang mewakili pendekatan arsitektur yang berbeda ini mengalami pengujian yang ketat dengan *dataset*, sehingga dapat menghasilkan informasi mengenai kemampuan klasifikasinya.

Hasil pada Tabel IV menunjukkan bahwa di antara model yang dianalisis, arsitektur DenseNet201 mencapai akurasi tertinggi sebesar 81,1%, sehingga menjadikannya model dengan kinerja terbaik. Selain itu, arsitektur ini menunjukkan sensitivitas, presisi, dan nilai *F1-score* yang luar biasa, masing-masing sebesar 81,06; 81,52; dan 81,29. Tampilan metrik tinggi yang komprehensif ini menekankan keunggulan DenseNet201 dalam klasifikasi rasa nyeri melalui ekspresi wajah.

Meskipun DenseNet201 memiliki kinerja terbaik, model MobileNetV2, EfficientNetb0, dan ResNet101 juga turut berkontribusi secara signifikan pada domain ini. Masing-masing model memiliki akurasi sebesar 78,2%, 79,4%, dan 78,2%. Hasil ini menekankan kompetensi dalam tugas klasifikasi nyeri. Meskipun tidak dapat melampaui arsitektur

DenseNet201, model-model ini tetap kompetitif, yang ditandai dengan kinerjanya yang hampir sama.

Wawasan bernuansa yang diperoleh dari hasil ini tidak hanya menguatkan efektivitas berbagai pilihan arsitektur, tetapi juga memberikan landasan untuk membuat keputusan pemilihan model yang tepat berdasarkan kasus penggunaan dan persyaratan tertentu. Evaluasi komprehensif dari arsitektur ini memperlihatkan kekuatan model dan area perbaikannya, yang pada akhirnya dapat mengarahkan penelitian klasifikasi nyeri yang lebih luas.

IV. KESIMPULAN

Studi ini menyajikan eksplorasi komprehensif metodologi pengenalan rasa nyeri, yang berhasil menggabungkan teknik Viola-Jones dan empat model pembelajaran mendalam tingkat lanjut, yaitu MobileNetV2, EfficientNetb0, ResNet101, dan DenseNet201. Proses ini mencakup kalibrasi yang cermat terhadap nilai laju pembelajaran yang berkisar antara 10^{-1} sampai 10^{-5} .

Pola signifikan diperoleh dari analisis data pelatihan. Laju pembelajaran sebesar 10^{-2} berfungsi sebagai katalisator untuk validasi akurasi yang lebih tinggi di seluruh model DenseNet201, EfficientNetb0, dan MobileNetV2, dengan masing-masing model mencapai tingkat akurasi yang mengesankan sebesar 99,60%. Model-model ini mencapai kinerja yang luar biasa tanpa mengorbankan *elapsed time*. Waktu pemrosesan masing-masing model adalah 33.20.52 jam, 09.38.25 jam, dan 05.12.28 jam

Sementara itu, ResNet101 menghasilkan akurasi tertinggi sebesar 99,60%, yang dicapai pada laju pembelajaran 10^{-3} . Namun, pencapaian ini memerlukan waktu yang lama, yaitu 58.21.14 jam. Hal ini menunjukkan adanya pengorbanan efisiensi pemrosesan terhadap akurasi.

Investigasi selanjutnya terhadap hasil pengujian pada *dataset* yang berbeda menjelaskan implikasi praktis dari kinerja model. Dalam kerangka evaluasi ini, model DenseNet201 menunjukkan kinerja yang unggul, dengan akurasi sebesar 81,1%. Hasil dari *confusion matrix* memperkuat pencapaian ini. Hal ini ditunjukkan dengan nilai sensitivitas, presisi, dan *F1-score* yang mengesankan, masing-masing sebesar 81,06; 81,52; dan 81,29. Model MobileNetV2, EfficientNetb0, dan ResNet101 juga turut memberikan kontribusi signifikan, dengan akurasi masing-masing sebesar 78,2%, 79,4%, dan 78,2%.

Sebagai kesimpulan, investigasi multifaset ini menggarisbawahi pentingnya memilih laju pembelajaran yang optimal untuk model pembelajaran mendalam. Temuan ini menekankan bahwa perpaduan yang harmonis antara akurasi dan efisiensi operasional dicapai ketika model MobileNetV2 menggunakan laju pembelajaran sebesar 10^{-2} . Dengan memanfaatkan penggabungan strategis antara metodologi dan model, penelitian ini mendorong bidang pengenalan rasa nyeri melalui ekspresi wajah, membuka jalan menuju metodologi yang semakin efektif dan efisien.

KONFLIK KEPENTINGAN

Penulis menyatakan bahwa tidak ada konflik kepentingan dalam penelitian dan penyusunan makalah ini.

KONTRIBUSI PENULIS

Konseptualisasi, Raihan Islamadina, Khairun Saddami, Fitri Arnia, Taufik Fuadi Abidin, dan Rusdha Muharar; metodologi, Raihan Islamadina, Khairun Saddami, Fitri Arnia, Taufik Fuadi Abidin, dan Rusdha Muharar; perangkat lunak,

Raihan Islamadina, Khairun Saddami, dan Muhammad Irwandi; penulisan—penyusunan draf asli, Raihan Islamadina; penulisan—penelaahan dan penyuntingan, Raihan Islamadina, Khairun Saddami, Fitri Arnia, Taufik Fuadi Abidin, Rusdha Muharar, dan Aulia Syarif Aziz.

UCAPAN TERIMA KASIH

Penelitian ini didanai oleh DIPA UIN Ar-Raniry Banda Aceh tahun 2023. Terima kasih kepada para pembimbing dari Universitas Syiah Kuala Banda Aceh dan tim peneliti dari UIN Ar-Raniry Banda Aceh yang telah berkontribusi dalam pelaksanaan penelitian dan penulisan artikel ini.

REFERENSI

- [1] K.D. Craig, "The facial expression of pain better than a thousand words?," *APS J.*, vol. 1, no. 3, hal. 153–162, 1992, doi: 10.1016/1058-9139(92)90001-S.
- [2] M.A. Lazarini, R. Rossi, dan K. Hirma, "A systematic literature review on the accuracy of face recognition algorithms," *EAI Endorsed Trans. IoT*, vol. 8, no. 30, hal. 1–11, Sep. 2022, doi: 10.4108/eetiot.v8i30.2346.
- [3] P. Viola dan M. Jones, "Rapid object detection using a boosted cascade of simple features," *Proc. 2001 IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2001, hal. I-511–I-518, doi: 10.1109/CVPR.2001.990517.
- [4] P. Viola dan M. Jones, "Robust real-time face detection," *Int. J. Comput. Vis.*, vol. 57, no. 2, hal. 137–154, Mei 2004, doi: 10.1023/B:VISI.0000013087.49260.fb.
- [5] M.F. Hirzi, S. Efendi, dan R.W. Sembiring, "Literature study of face recognition using the Viola-Jones algorithm," *2021 Int. Conf. Artif. Intell. Mechatronics Syst. (AIMS)*, 2021, hal. 1–6, doi: 10.1109/AIMS52415.2021.9466010.
- [6] F. Elgendy, M. Alshewimy, dan A. Sarhan, "Pain detection/classification framework including face recognition based on the analysis of facial expressions for e-health systems," *Int. Arab J. Inf. Technol.*, vol. 18, no. 1, hal. 125–132, Jan. 2021, doi: 10.34028/iajit/18/1/14.
- [7] R.M. Al-Eidan, H. Al-Khalifa, dan A. Al-Salman, "Deep learning-based models for pain recognition: A systematic review," *Appl. Sci.*, vol. 10, no. 17, hal. 1–15, Agu. 2020, doi: 10.3390/app10175984.
- [8] M.N. Chaudhari, M. Deshmukh, G. Ramrakhiani, dan R. Parvatikar, "Face detection using Viola Jones algorithm and neural networks," *2018 4th Int. Conf. Comput. Commun. Control Autom. (ICCUBEA)*, 2018, hal. 1–6, doi: 10.1109/ICCUBEA.2018.8697768.
- [9] P. Rodriguez dkk., "Deep pain: Exploiting long short-term memory networks for facial expression classification," *IEEE Trans. Cybern.*, vol. 52, no. 5, hal. 3314–3324, Mei 2022, doi: 10.1109/TCYB.2017.2662199.
- [10] D.L. Martinez, O. Rudovic, dan R. Picard, "Personalized automatic estimation of self-reported pain intensity from facial expressions," *2017 IEEE Conf. Comput. Vis. Pattern Recognit. Workshops (CVPRW)*, 2017, hal. 2318–2327, doi: 10.1109/CVPRW.2017.286.
- [11] G. Bargshady dkk., "Ensemble neural network approach detecting pain intensity from facial expressions," *Artif. Intell. Med.*, vol. 109, hal. 1–12, Sep. 2020, doi: 10.1016/j.artmed.2020.101954.
- [12] G. Bargshady dkk., "The modeling of human facial pain intensity based on temporal convolutional networks trained with video frames in HSV color space," *Appl. Soft Comput.*, vol. 97, hal. 1–14, Des. 2020, doi: 10.1016/j.asoc.2020.106805.
- [13] R. Islamadina dkk., "Performance of deep learning benchmark models on thermal imagery of pain through facial expressions," *2022 IEEE Int. Conf. Commun. Netw. Satell. (COMNETSAT)*, 2022, hal. 374–379, doi: 10.1109/COMNETSAT56033.2022.9994546.
- [14] G. Huang, Z. Liu, L.V.D. Maaten, dan K.Q. Weinberger, "Densely connected convolutional networks," *2017 IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2017, hal. 2261–2269, doi: 10.1109/CVPR.2017.243.
- [15] M. Sandler dkk., "MobileNetV2: Inverted residuals and linear bottlenecks," *2018 IEEE/CVF Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2018, hal. 4510–4520, doi: 10.1109/CVPR.2018.00474.
- [16] K. He, X. Zhang, S. Ren, dan J. Sun, "Deep residual learning for image recognition," *2016 IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2016, hal. 770–778, doi: 10.1109/CVPR.2016.90.
- [17] M. Tan dan Q.V. Le, "EfficientNet: Rethinking model scaling for convolution neural networks," 2019, *arXiv:1905.11946*.
- [18] J. Brownlee (2020) "Understand the Impact of Learning Rate on Neural Network Performance," [Online], <https://machinelearningmastery.com/understand-the-dynamics-of-learning-rate-on-deep-learning-neural-networks/>, tanggal akses: 22-Jun-2023.
- [19] M.A. Haque dkk., "Deep multimodal pain recognition: A database and comparison of spatio-temporal visual modalities," *2018 13th IEEE Int. Conf. Autom. Face Gesture Recognit. (FG 2018)*, 2018, hal. 250–257, doi: 10.1109/FG.2018.00044.
- [20] M.H. Beale, M.T. Hagan, dan H.B. Demuth, *Deep Learning Toolbox™ User's Guide*. (2020). Tanggal akses: 19-Agu-2023. [Online]. Tersedia: <https://www.mathworks.com/help/deeplearning/index.html>
- [21] A. Schoenauer-Sebag, M. Schoenauer, dan M. Sebag, "Stochastic gradient descent: Going as fast as possible but not faster," 2017, *arXiv:1709.01427*.
- [22] A.G. Lalkhen dan A. McCluskey, "Clinical tests: Sensitivity and specificity," *Contin. Educ. Anaesth. Crit. Care Pain*, vol. 8, no. 6, hal. 221–223, Des. 2008, doi: 10.1093/bjaceaccp/mkn041.