

Implemententasi U-Net CNN Untuk Klasifikasi Citra Hasil Pengelasan

Muhammad Rizki Mubarrok¹, Ryan Yudha Adhitya², Mochammad Karim Al Amin³, Hendro Agus Widodo⁴,
Joko Endrasmono⁵, Didik Sukoco⁶

e-mail: rizki.mubarrok@student.ppns.ac.id, ryanyudhaadhitya@ppns.ac.id, karim@ppns.ac.id,
hendro.aw@ppns.ac.id, endrasmono@ppns.ac.id, didikskc@ppns.ac.id

^{1,4,5,6}Program Studi Teknik Otomasi, Jurusan Teknik Kelistrikan Kapal, Politeknik Perkapalan Negeri Surabaya,

²Program Studi Teknik Pengelasan, Jurusan Teknik Bangunan Kapal, Politeknik Perkapalan Negeri Surabaya,

³Program Studi Teknik Kelistrikan Kapal, Jurusan Teknik Kelistrikan Kapal, Politeknik Perkapalan Negeri Surabaya,
Kampus ITS Sukolilo Jl. Teknik Kimia, Keputih, Sukolilo, Surabaya, Indonesia

Informasi Artikel

Riwayat Artikel

Diterima 5 Januari 2020

Direvisi 20 Februari 2020

Diterbitkan 15 Maret 2020

Kata kunci:

U-Net
CNN
Pengolahan Citra
Optimizer
Pengelasan

ABSTRAK

Metode *Visual Testing* menjadi salah satu metode yang umum digunakan untuk inspeksi hasil pengelasan kategori NDT. Metode ini biasanya digunakan sebagai metode pendeteksian awal hasil pengelasan sebelum dilakukan metode pengujian lain. Penggunaan teknologi pengolahan citra diusulkan untuk membantu proses inspeksi visual hasil pengelasan. Pada penelitian ini model U-Net yang dikombinasi dengan CNN digunakan untuk proses klasifikasi hasil pengelasan. Hasil pengelasan yang coba diklasifikasi berupa hasil las normal, excessive reinforcement, porosity, dan undercut pada pipa baja karbon A106 Grade B. Model arsitektur terdiri dari arsitektur U-Net dengan kedalaman *encoder* dan *decoder* sebanyak 2 serta kombinasi layer klasifikasi CNN pada bagian akhir *decoder*. Penggunaan optimizer pada pelatihan model digunakan untuk mengoptimalkan proses pelatihan data pada model agar tingkat akurasi pelatihan dari model dapat lebih baik dan terhindar dari *overfitting* dan *underfitting*. Terdapat 3 tipe optimizer yang akan diterapkan pada model dan dicoba untuk dianalisis yaitu, Adam, SGDM, dan RMSprop. Didapatkan hasil *optimizer* SGDM pada akurasi pelatihan sebesar 98.75% dan hasil uji terhadap 40 citra baru sebesar 92.5%. Model berhasil membedakan hasil pengelasan menjadi normal, *excessive reinforcement*, *undercut*, dan *porosity*.

ABSTRACT

Visual testing is one of the most commonly used methods for welding inspection in the NDT category. This method is usually used as an initial detection method of welding results before other testing methods are carried out. The use of image processing technology is proposed to assist the visual inspection process of welding results. In this research, the U-Net model combined with CNN is used for the classification process of welding results. The welding results that are tried to be classified are normal welds, excessive reinforcement, porosity, and undercut on A106 Grade B carbon steel pipes. The model architecture consists of a U-Net architecture with 2 encoder and decoder depths and a combination of CNN classification layers at the end of the decoder. The use of optimizers in model training is used to optimize the data training process in the model so that the training accuracy of the model can be better and avoid overfitting and underfitting. There are 3 types of optimizers that will be applied to the model and tried to be analyzed, namely, Adam, SGDM, and RMSprop. SGDM optimizer results in training accuracy of 98.75% and test results on 40 new images of 92.5%. The model successfully distinguishes welding results into normal, excessive reinforcement, undercut, and porosity.

Keywords:

U-Net
CNN
Image Processing
Optimizer
Welding



Penulis Korespondensi:

Muhammad Rizki Mubarrok

Jurusan Teknik Kelistrikan Kapal Program Studi Teknik Otomasi,

Politeknik Perkapalan Negeri Surabaya,

Kampus ITS Sukolilo Jl. Teknik Kimia, Kebuptih, Sukolilo, Surabaya, Jawa Timur, Indonesia, 60111.

Email: rizki.mubarrok@student.ppons.ac.id

Nomor HP/WA aktif: +62 857-3060-0015

1. PENDAHULUAN

Dalam industri manufaktur, pengelasan merupakan salah satu proses kritis yang mempengaruhi kualitas dan kekuatan struktural dari suatu produk. Dalam beberapa dekade terakhir, penggunaan citra digital untuk memantau dan mengontrol proses pengelasan telah menjadi lebih umum. Pemanfaatan teknologi citra dalam pengelasan memberikan keunggulan dalam pemantauan secara *real-time*, evaluasi kualitas, dan otomatisasi proses. Salah satu tantangan utama dalam pengelasan berbasis citra adalah pengenalan dan klasifikasi cacat yang mungkin terjadi pada hasil pengelasan. Pada skala industri, pengenalan cacat secara manual oleh manusia membutuhkan waktu dan biaya yang besar, dan sering kali tidak efisien.

Pengujian hasil pengelasan yang ideal yaitu dilakukan dengan metode tanpa merusak spesimen las atau *Non Destructive Test* (NDT) dan juga pengujian dengan merusak spesimen las atau *Destructive Test* (DT)[1]. Metode *Visual Testing* menjadi salah satu metode yang umum digunakan untuk inspeksi hasil pengelasan kategori NDT. Metode ini biasanya digunakan sebagai metode pendeteksian awal hasil pengelasan sebelum dilakukan metode pengujian lain. Dalam melakukan pengujian visual membutuhkan seorang ahli inspeksi las atau *welding inspector* untuk mengamati spesimen hasil pengelasan. Namun dalam proses pengamatan terkadang terjadi permasalahan tingkat ketelitian dan petugas yang melakukan inspeksi visual harus mempunyai pengalaman atau kompetensi dibidang ini. Hal tersebut dipengaruhi oleh tingkat konsentrasi dan lamanya jam terbang seorang ahli inspeksi las dalam melakukan pengamatan.

Berdasarkan permasalahan tersebut perlulah dibuat suatu alat yang dapat membantu proses inspeksi visual hasil pengelasan agar proses inspeksi tersebut dapat berjalan dengan lebih baik dan tingkat ketelitian lebih tinggi. Penggunaan teknologi pengolahan citra dirasa menjadi teknologi yang sesuai untuk mengatasi permasalahan tersebut. Penggunaan pengolahan citra sebagai alat untuk pengecekan hasil pengelasan sudah banyak dilakukan sebelumnya[2][3]. Penelitian sejenis sebelumnya juga pernah dilakukan menggunakan metode *Convolutional Neural Network* (CNN) dengan optimizer Adam. Hasilnya metode tersebut berhasil melakukan identifikasi cacat las pada pipa karbon dengan baik dan cepat[4]. Meskipun dalam penggunaan CNN dengan optimizer adam sudah mendapatkan hasil yang baik dan cepat, terdapat tantangan untuk membuat model pengolahan citra yang lebih baik menggunakan model arsitektur yang lain.

Pada penelitian kali ini digunakan kombinasi U-Net dan CNN sebagai metode dalam klasifikasi cacat hasil pengelasan. Kombinasi antara U-Net dan CNN nantinya akan dianalisis keandalannya dalam sistem klasifikasi cacat hasil pengelasan. Penggunaan kombinasi arsitektur U-Net dan CNN sebelumnya berhasil mendapatkan nilai akurasi tertinggi untuk klasifikasi sebesar 98.7% pada citra hasil MRI tumor otak[5][3]. Pada penelitian tersebut citra dilakukan segmentasi menggunakan U-Net kemudian dilanjutkan dengan proses klasifikasi menggunakan CNN. Model CNN yang digunakan terdiri dari 39 *layer* dan 2 blok diantara *input* dan *output layer*. Arsitektur U-Net digunakan untuk mengatasi masalah segmentasi gambar, yaitu memisahkan objek dalam suatu gambar dari latar belakang. Selain itu arsitektur ini dipilih karena memiliki tingkat pelatihan yang cepat dan cenderung membutuhkan jumlah parameter yang sedikit[6]. Metode CNN dikenal karena kemampuannya dalam mengenali pola spasial dalam data, membuatnya sangat efektif untuk tugas-tugas pengenalan gambar dan pengolahan citra[7].

Penelitian ini dirancang dengan total dataset sebanyak 400 data dimana data tersebut dibagi menjadi 360 data *training* dan 40 data *testing*. Terdapat 4 kelas jenis pengelasan yaitu normal, *undercut*, *porosity*, dan *excessive reinforcement*. Dari keempat jenis kelas tersebut terdapat masing-masing 80 data *training* dan 20 data *testing*. Dengan penelitian ini Dengan adanya penelitian ini, diharapkan dapat terciptanya akurasi model yang unggul dengan




modifikasi arsitektur UNet-CNN dalam klasifikasi cacat hasil pengelasan. Hasil dari penelitian ini berpotensi terciptanya inovasi baru yang mampu diimplementasikan dalam dunia nyata, seperti sistem inspeksi hasil pengelasan.

2. METODE PENELITIAN

2.1 Arsitektur U-Net

U-Net merupakan salah satu arsitektur *convolutional neural network* yang sangat populer untuk segmentasi citra medis dan tugas pemrosesan citra lainnya. Arsitektur ini bertujuan untuk mengatasi masalah segmentasi gambar, yaitu untuk memisahkan objek dalam suatu gambar dari latar belakang[6]. Pada arsitektur ini memiliki ciri khas yaitu struktur yang berbentuk "U". Visualisasi dari arsitektur U-Net dapat dilihat pada Gambar 1.

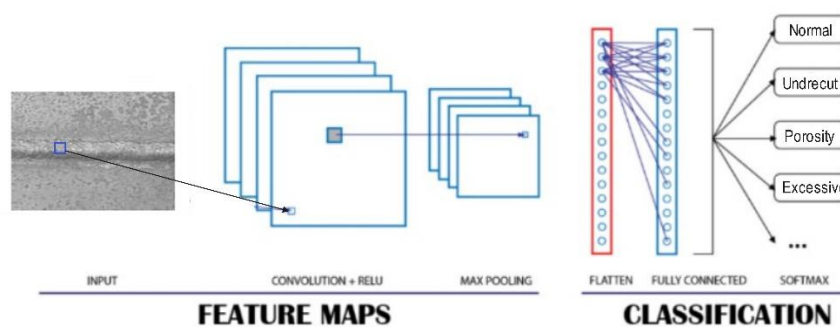


Gambar 1: Arsitektur U-Net

Berdasarkan Gambar 1, arsitektur ini terdiri dari jalur berbentuk "U" yang berkontraksi dan meluas. Setiap langkah dari jalur kontraksi terdiri dari dua konvolusi 3x3, ReLU dan 2x2 max-pooling. Sebaliknya, jalur ekspansif terdiri dari 2x2 *upconvolution*, konvolusi 3x3, dan ReLU. Di antara *upconvolution* dan konvolusi di jalur ekspansif, peta fitur digabungkan dengan dengan peta fitur yang dipotong dari jalur kontraksi dari lapisan yang sesuai[8].

2.2 Arsitektur Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah jenis arsitektur jaringan saraf tiruan yang dirancang khusus untuk memproses data grid, seperti gambar dan video. CNN terdiri dari beberapa lapisan yang mencakup *input layer*, *convolution layer*, *non-linear layer*, *pooling layer*, dan *fully connected layer*. Setiap lapisan ini berperan dalam proses pengenalan objek pada citra [9][10]. Gambar arsitektur CNN dapat dilihat pada Gambar 2.

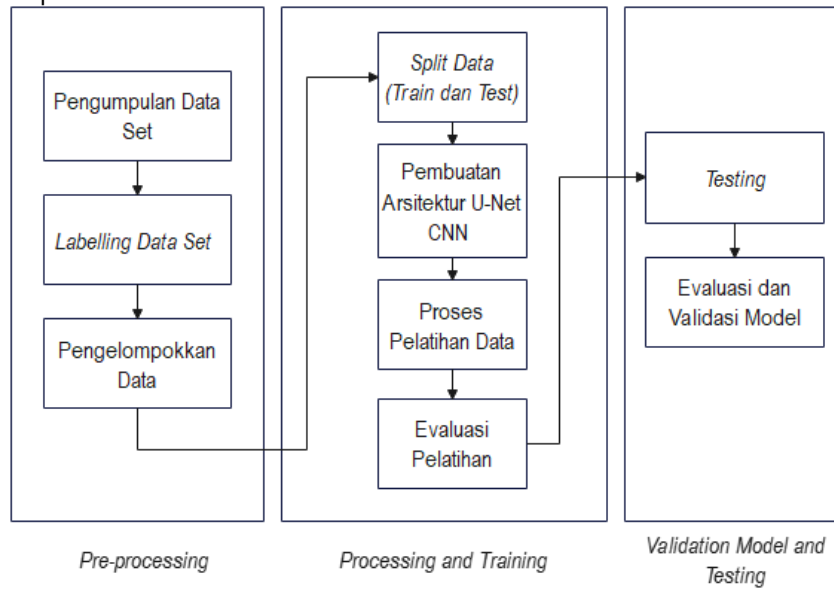


Gambar 2: Arsitektur CNN



2.3 Perancangan Eksperimen Penelitian

Pada bagian ini akan dijelaskan bagaimana rancangan dan langkah eksperimen dari penelitian ini, Alur eksperimen dapat dilihat pada Gambar 3.




Gambar 3: Perancangan Eksperimen Penelitian

Tahap penelitian dimulai dengan pengumpulan dataset pada setiap kelas, setelah dataset sudah terkumpul kemudian gambar akan dikelompokkan pada setiap kelas. Dataset yang sudah terkumpul pada setiap kelas akan dibagi lagi menjadi 2 yaitu data *train* dan data *validation* dengan presentase data *train* 80% dan data *validation* 20%. Tahap berikutnya adalah pembuatan model dan arsitektur kemudian data yang sudah ada dilakukan pelatihan dengan model dan arsitektur yang telah dibuat. Setelah melakukan pelatihan, data hasil pelatihan akan di analisis dan dievaluasi serta dilakukan pengujian dengan citra yang belum pernah dilihat sebelumnya. Hasil dari pengujian tersebut kemudian akan dilakukan analisis kembali.

2.4 Objek dan Area Deteksi

Penelitian ini menggunakan hasil pengelasan pada pipa baja karbon A106 Grade B dengan jenis pengelasan SMAW, GTAW, dan GMAW. Hasil pengelasan menjadi fokus deteksi dengan jenis klasifikasi hasil pengelasan normal, *porosity*, *undercut*, dan *excessive reinforcement*. Pada gambar 4 merupakan contoh citra yang akan dilakukan proses deteksi. Pada input gambar akan diubah ukurannya menjadi 200x200 guna mempercepat proses komputasi dari model. Gambar 4 merupakan visualisasi dari contoh hasil pengelasan yang akan dideteksi dan diproses.



Gambar 4: Contoh Dataset Deteksi



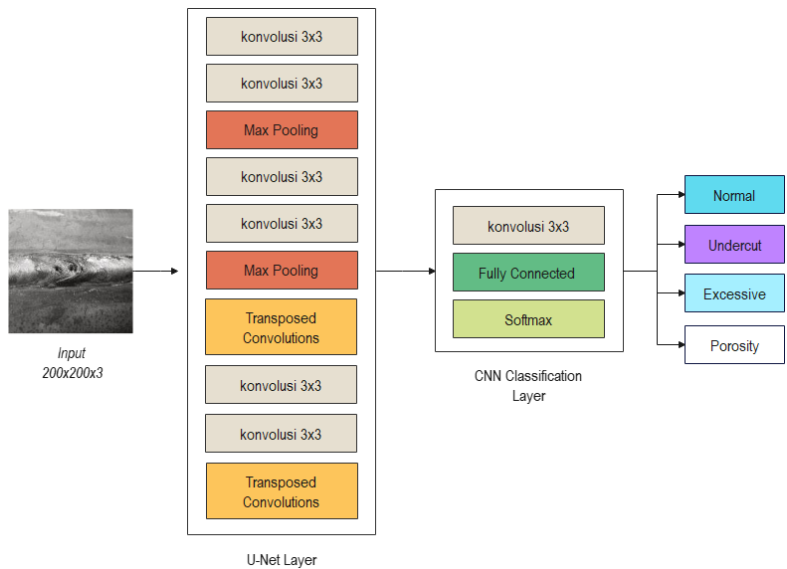
2.5 Pengembangan Arsitektur

Metode dan arsitektur yang dipilih menjadi fokus utama pada penelitian ini. Keberhasilan dari sistem deteksi bergantung pada penggunaan metode dan arsitektur yang tepat. Pada dasarnya model arsitektur U-Net sudah berisikan model CNN pada setiap bagian *layer* terutama pada bagian *encoder*, hanya saja pada arsitektur U-Net terdapat bagian *skip connection* yang berfungsi untuk mengatasi masalah hilangnya informasi spasial selama proses pengembalian, dilakukan koneksi langsung antara lapisan encoder dan decoder. Pada penelitian ini model U-Net akan dilakukan modifikasi pada bagian encoder berupa penambahan layer *dense layer* dan *fully connected layer* sehingga dapat melakukan proses klasifikasi citra. Arsitektur dari U-Net tetap dipakai karena memiliki bagian *skip connection* yang dapat membantu mengatasi masalah informasi yang hilang selama proses *max pooling*. Visualisasi dari arsitektur U-Net-CNN yang dikembangkan oleh peneliti dapat dilihat pada gambar 5.

	NAME	TYPE	ACTIVATIONS	LEARNABLES
1	input 200x200x3 images with 'zerocenter' normalization	Image Input	200x200x3	-
2	conv1_1 16 3x3x3 convolutions with stride [1 1] and padding 'same'	Convolution	200x200x16	Weights 3x3x3x16 Bias 1x1x16
3	relu1_1 ReLU	ReLU	200x200x16	-
4	conv1_2 16 3x3x16 convolutions with stride [1 1] and padding 'same'	Convolution	200x200x16	Weights 3x3x16x16 Bias 1x1x16
5	bn1 Batch normalization with 16 channels	Batch Normalization	200x200x16	Offset 1x1x16 Scale 1x1x16
6	relu1_2 ReLU	ReLU	200x200x16	-
7	pool1 2x2 max pooling with stride [2 2] and padding [0 0 0 0]	Max Pooling	100x100x16	-
8	conv2_1 32 3x3x16 convolutions with stride [1 1] and padding 'same'	Convolution	100x100x32	Weights 3x3x16x32 Bias 1x1x32
9	relu2_1 ReLU	ReLU	100x100x32	-
10	conv2_2 32 3x3x32 convolutions with stride [1 1] and padding 'same'	Convolution	100x100x32	Weights 3x3x32x32 Bias 1x1x32
11	bn2 Batch normalization with 32 channels	Batch Normalization	100x100x32	Offset 1x1x32 Scale 1x1x32
12	relu2_2 ReLU	ReLU	100x100x32	-
13	pool2 2x2 max pooling with stride [2 2] and padding [0 0 0 0]	Max Pooling	50x50x32	-
14	conv5_1 64 3x3x32 convolutions with stride [1 1] and padding 'same'	Convolution	50x50x64	Weights 3x3x32x64 Bias 1x1x64
15	relu5_1 ReLU	ReLU	50x50x64	-
16	conv5_2 64 3x3x64 convolutions with stride [1 1] and padding 'same'	Convolution	50x50x64	Weights 3x3x64x64 Bias 1x1x64
17	bn5 Batch normalization with 64 channels	Batch Normalization	50x50x64	Offset 1x1x64 Scale 1x1x64
18	relu5_2 ReLU	ReLU	50x50x64	-
19	upconv6 64 2x2x64 transposed convolutions with stride [2 2] and output cropping [0 0]	Transposed Convolution	100x100x64	Weights 2x2x64x64 Bias 1x1x64
20	concat6 Depth concatenation of 2 inputs	Depth concatenation	100x100x96	-
21	conv6_1 32 3x3x96 convolutions with stride [1 1] and padding 'same'	Convolution	100x100x32	Weights 3x3x96x32 Bias 1x1x32
22	relu6_1 ReLU	ReLU	100x100x32	-
23	conv6_2 32 3x3x32 convolutions with stride [1 1] and padding 'same'	Convolution	100x100x32	Weights 3x3x32x32 Bias 1x1x32
24	bn6 Batch normalization with 32 channels	Batch Normalization	100x100x32	Offset 1x1x32 Scale 1x1x32
25	relu6_2 ReLU	ReLU	100x100x32	-
26	upconv7 32 2x2x32 transposed convolutions with stride [2 2] and output cropping [0 0]	Transposed Convolution	200x200x32	Weights 2x2x32x32 Bias 1x1x32
27	concat7 Depth concatenation of 2 inputs	Depth concatenation	200x200x48	-
28	conv7_1 16 3x3x48 convolutions with stride [1 1] and padding 'same'	Convolution	200x200x16	Weights 3x3x48x16 Bias 1x1x16
29	bn7 Batch normalization with 16 channels	Batch Normalization	200x200x16	Offset 1x1x16 Scale 1x1x16
30	relu7_1 ReLU	ReLU	200x200x16	-
31	fullyConnectedLayer 4 fully connected layer	Fully Connected	1x1x4	Weights 4x64000 Bias 4x1
32	DO 40% dropout	Dropout	1x1x4	-
33	softmax softmax	Softmax	1x1x4	-
34	classificationLayer crossentropyex	Classification Output	-	-

Gambar 5 : Hasil Parameter Model





U-Net Layer
 Gambar 6 : Model Arsitektur

Pada gambar 6 merupakan alur pengolahan citra pada model arsitektur U-Net CNN yang telah dibuat. Langkah awal adalah citra hasil pengelasan dengan ukuran 200x200 dengan jenis RGB sebagai input gambar akan melalalui lapisan U-Net dengan kedalaman 2 encoder dan decoder terlebih dahulu. Kemudian dilanjutkan dengan lapisan klasifikasi CNN dengan keluaran hasil klasifikasi berupa *normal*, *undercut*, *excessive*, atau *porosity*.

2.6 Penerapan Optimizer pada Model

Penggunaan optimizer pada pelatihan model digunakan untuk mengoptimalkan proses pelatihan data pada model. Tujuannya adalah agar tingkat akurasi pelatihan dari model dapat lebih baik dan terhindar dari *overfitting* dan *underfitting*. Terdapat 3 tipe optimizer yang akan diterapkan pada model dan dicoba untuk dianalisis yaitu, Adam, SGDM, dan RMSprop.

a) Adam (*Adaptive Moment Estimation*)

Merupakan optimizer yang dikembangkan dari algoritma SGD (*Stochastic Gradient Descent*) dengan nilai bobot jaringan yang telah diperbarui[11]. Pada algoritma ini pengaturan *learning rate* harus dilakukan pengaturan terlebih dahulu. Perhitungan dari algoritma Adam dapat dilihat pada persamaan (1).

$$\theta_t = \theta_t - 1 - \frac{\alpha}{\sqrt{V_t + \epsilon}} \cdot m_t \tag{1}$$

Keterangan :

- θ_t : Parameter yang diperbarui saat iterasi
- α : Nilai *learning rate*
- V_t : Rata-rata gradien
- ϵ : Faktor terkecil pembagian dengan 0
- m_t : Momen gradient pada iterasi

b) SGDM (*Stochastic Gradient Descent with Momentum*)

Merupakan variasi dari algoritma Stochastic Gradient Descent (SGD) yang menambahkan konsep momentum untuk memperbaiki konvergensi dan stabilitas saat melatih model machine learning, terutama dalam deep learning. SGD adalah metode optimasi yang memperbarui parameter model secara iteratif berdasarkan sampel acak dari dataset[12]. Perhitungan dari algoritma SGDM dapat dilihat pada persamaan (2).

$$\theta_t = \theta_t - 1 - V_t \tag{2}$$



Keterangan :

θ_t : Parameter yang diperbarui saat iterasi

V_t : Rata-rata gradien

c) RMSProp (*Root Mean Square Propagation*)

Merupakan algoritma optimasi yang bekerja dengan mempertahankan rata-rata eksponensial dari kuadrat gradien dan menggunakan informasi ini untuk menyesuaikan learning rate dari setiap parameter secara individual[13]. Perhitungan dari algoritma RMSProp dapat dilihat pada persamaan (3).

$$\theta_t = \theta_{t-1} - \frac{\alpha}{\sqrt{V_t + \epsilon}} \cdot g_t \tag{3}$$

Keterangan :

θ_t : Parameter yang diperbarui saat iterasi

α : Nilai *learning rate*

V_t : Rata-rata gradien

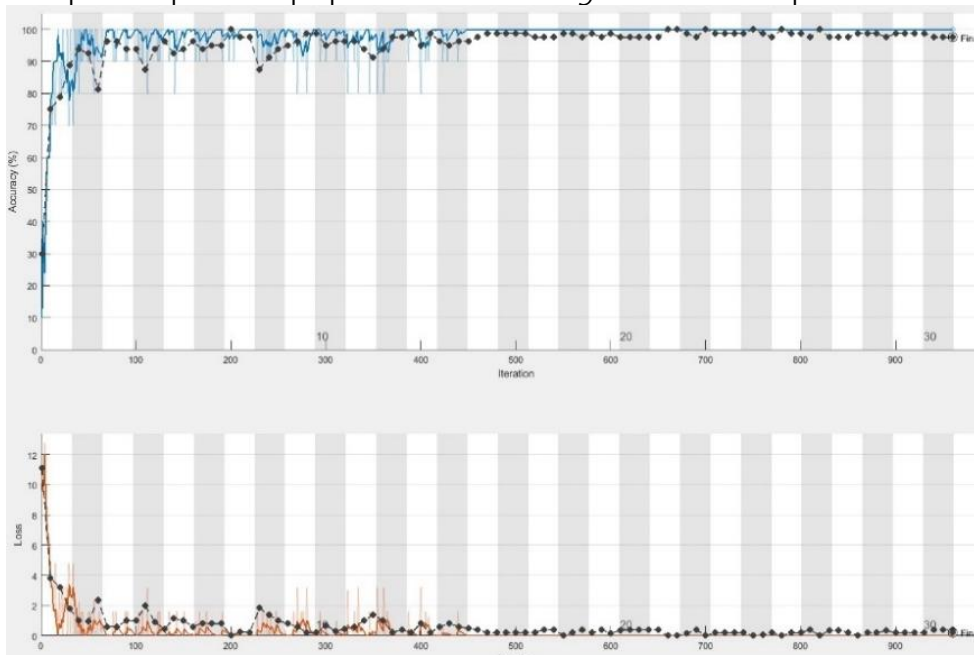
ϵ : Faktor terkecil pembagian dengan 0

g_t : Gradient terhadap iterasi

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pelatihan Berdasarkan Optimizer

Proses pelatihan model dilakukan dengan membandingkan beberapa optimizer. Proses pelatihan dilakukan dengan total jumlah epoch 30 pada setiap optimizer. Nilai *learning rate* awal diatur pada nilai 0.001.




Gambar 7 : Hasil Akurasi dan Loss pada Optimizer Adam

Grafik dari hasil pelatihan dengan optimizer Adam pada Gambar 7 menunjukkan pola yang positif dan konsisten pada nilai akurasi dan loss. Grafik akurasi untuk data pelatihan dan data validasi menunjukkan peningkatan yang cepat pada awal pelatihan, dan kemudian mencapai stabilitas mendekati 100% pada data pelatihan dan sekitar 97,5% pada data validasi setelah sekitar 450 iterasi. Hal ini memperlihatkan kemampuan model untuk belajar dari data pelatihan dan tetap mempertahankan kinerjanya pada suatu data validasi. Sementara itu pada grafik *Loss*



menunjukkan penurunan yang sangat cepat, yang pada data pelatihan dan validasi menjadi sangat kecil dan stabil setelah kurang lebih 450 iterasi.




Gambar 8 : Hasil Akurasi dan Loss pada Optimizer SGDM

Grafik dari hasil pelatihan dengan optimizer SGDM pada Gambar 8 menunjukkan pola yang positif dan konsisten pada nilai akurasi dan loss. Grafik akurasi untuk data pelatihan dan data validasi menunjukkan peningkatan yang cepat pada awal pelatihan, dan kemudian mencapai stabilitas mendekati 100% pada data pelatihan dan sekitar 98,75% pada data validasi setelah sekitar 110 iterasi. Hal ini memperlihatkan kemampuan model untuk belajar dari data pelatihan dan tetap mempertahankan kinerjanya pada suatu data validasi. Sementara itu pada grafik *Loss* menunjukkan penurunan yang sangat cepat, yang pada data pelatihan dan validasi menjadi sangat kecil dan stabil setelah kurang lebih 100 iterasi.

Grafik proses pelatihan pada Gambar 9 menunjukkan konsistensi relatif dalam pola akurasi dan kerugian. Plot akurasi (atas) menunjukkan bahwa pelatihan benar-benar tajam dan mencapai akurasi sekitar 100% setelah kurang lebih 150 epoch. Akurasi validasi tidak meningkat terlalu banyak, dengan level yang cukup stabil dan tinggi mendekati sekitar 98,75% pada epoch terakhir. Terdapat sedikit gangguan dalam akurasi validasi, namun tetap tinggi, menunjukkan bahwa model mungkin memiliki performa yang baik pada data validasi. Sementara itu nilai *Loss* menurun tajam pada awal pelatihan dan hampir mendatar serta berkurang sangat lambat setelah sekitar 150 iterasi. Meskipun terdapat beberapa peningkatan nilai kerugian pada data validasi, tren kehilangan data yang dilatih tetap datar. Pola ini menunjukkan bahwa model memang telah mempelajari pola tersebut dari data yang dilatih dan melakukan generalisasi ke data validasi yang sebelumnya tidak terlihat.





Gambar 9 : Hasil Akurasi dan Loss pada Optimizer RMSProp

Detail hasil pelatihan model dari masing-masing penggunaan optimizer dapat dilihat pada Tabel I.

TABEL I : Hasil Akumulasi Pelatihan Model Berdasarkan *Optimizer*

	Training Accuracy	Validation Accuracy	Training Loss	Validation Loss	Training Time
Adam	100%	97.5%	0%	0%	65 menit 11 detik
SGDM	100%	98.75%	0%	0%	37 menit 1 detik
RMSProp	91.87%	98.75%	4%	4%	58 menit 2 detik

Pada Tabel I data hasil pelatihan model menunjukkan bahwa *optimizer* SGDM memiliki hasil yang lebih baik dari *optimizer* lain pada proses pelatihan data. Nilai akurasi menunjukkan nilai yang paling tinggi 98.75% dan nilai *loss* menunjukkan nilai yang paling rendah 0% dengan waktu pelatihan paling cepat diantara lainnya 37 menit 1 detik. Sedangkan untuk *optimizer* Adam memiliki akurasi validasi 97.5% dan nilai *loss* 0% dengan waktu pelatihan 65 menit 11 detik. *Optimizer* RMSProp dianggap memiliki hasil yang paling buruk dengan nilai akurasi sebesar 91,87% dan nilai *loss* 4% dengan waktu pelatihan 58 menit 2 detik.

3.2 Tahap Pengetesan dan Validasi

Pada tahap ini model dengan setiap *optimizer* akan dilakukan pengetesan dengan citra yang belum pernah dilihat pada proses pelatihan sebelumnya. Digunakan total 40 citra pada saat pengetesan dengan rincian 10 citra pada setiap kelas. Hasil pengetesan dengan masing-masing *optimizer* dapat dilihat pada Tabel II.



TABEL II : Hasil Pengetesan Model Berdasarkan Optimizer

Optimizer	Benar				Salah				Accuracy
	Normal	Excessive Reinforcement	Undercut	Porosity	Normal	Excessive Reinforcement	Undercut	Porosity	
Adam	9	10	8	9	1	0	2	1	90%
SGDM	9	10	9	9	1	0	1	1	92.5%
RMSProp	9	10	8	9	1	0	2	1	90%

Pada Tabel II diperoleh hasil *optimizer* SGDM memiliki tingkat akurasi paling tinggi pada saat pengetesan dibanding dengan yang lain. Pada *optimizer* SGDM diperoleh nilai akurasi sebesar 92.5% sedangkan adam dan RMSProp sebesar 90%. Perhitungan nilai akurasi didapatkan dari perhitungan jumlah total prediksi benar data dibagi dengan jumlah total data pengetesan seperti pada persamaan 4.

$$X_{kesalahan} = \frac{\text{Total Prediksi benar}}{\text{Total data uji}} \times 100\% \quad (4)$$

3.3 Evaluasi Hasil

Pada penelitian ini model U-Net CNN dibuat untuk mendeteksi cacat hasil pengelasan. Dari hasil Analisa hasil pelatihan berdasarkan Tabel 1 didapatkan hasil akurasi, pelatihan nilai *loss* dan waktu pelatihan pada setiap *optimizer*. *Optimizer* Adam memperoleh nilai akurasi sebesar 97.5% dan nilai *loss* sebesar 0% dengan waktu pelatihan 65 menit 11 detik. *Optimizer* SGDM memperoleh nilai akurasi sebesar 98,75% dan nilai *loss* sebesar 0% dengan waktu pelatihan 37 menit 1 detik. *Optimizer* RMSProp memperoleh nilai akurasi sebesar 98,75% dan nilai *loss* sebesar 4% dengan waktu pelatihan 58 menit 2 detik. *Optimizer* terbaik adalah *optimizer* dengan nilai akurasi tinggi dan *loss* rendah serta waktu pelatihan yang cepat, oleh karena itu pada model penelitian kali ini SDGM dipilih sebagai *optimizer* yang digunakan pada sistem pelatihan data. *optimizer* SGDM lebih unggul dibanding yang lain dengan memperoleh nilai akurasi *training* dan *testing* yang lebih tinggi serta waktu yang lebih cepat dibanding yang lain. Pada proses uji diperoleh akurasi sebesar 92.5%. Penurunan akurasi data uji diakibatkan oleh kurang beragamnya dataset *training* sehingga terdapat beberapa citra yang salah dalam proses prediksi. Faktor *hyperparameter* pelatihan yang digunakan pada dapat mempengaruhi kinerja setiap *optimizer* dalam melakukan proses pelatihan model. Penetapan *learning rate* awal dapat menentukan hasil pada proses pelatihan. Pada pelatihan model penelitian ini menggunakan *learning rate* awal sebesar 0.001 disetiap *optimizer* yang digunakan. Penetapan nilai momentum pada *optimizer* SGDM dan *decay rate* pada *optimizer* RMSProp juga dapat membantu meningkatkan hasil pelatihan pada model. Berdasarkan hasil pengetesan yang diperoleh, untuk pengoptimalan model lebih lanjut sebaiknya dilakukan eksperimen dengan variasi *hyperparameter* pada setiap *optimizer*. Selain itu, melakukan validasi silang (*cross-validation*) dapat membantu memastikan bahwa hasil yang diperoleh konsisten dan tidak hanya hasil kebetulan dari satu set data validasi tertentu.

4. KESIMPULAN

Berdasarkan hasil penelitian yang sudah dilakukan diperoleh kesimpulan bahwa model U-Net CNN yang telah dibuat berhasil digunakan untuk mengklasifikasi citra hasil pengelasan. Dengan menggunakan *optimizer* SGDM didapatkan hasil akurasi pelatihan sebesar 98.75% dan hasil uji terhadap 40 citra baru sebesar 92.5%. Model berhasil membedakan hasil pengelasan menjadi normal, *excessive reinforcement*, *undercut*, dan *porosity*. Proses pelatihan dilakukan dengan total jumlah epoch 30 pada setiap *optimizer*. Nilai *learning rate* awal diatur pada nilai 0.001. Jumlah dataset yang digunakan pada penelitian ini berjumlah 400 citra dan sebaiknya dilakukan penambahan citra agar akurasi prediksi yang dilakukan dapat lebih baik serta melakukan validasi silang pada proses pelatihan untuk memastikan hasil yang diperoleh konsisten dan tidak hanya hasil kebetulan dari satu set data validasi tertentu.

DAFTAR PUSTAKA

- [1] M. Junaedy and R. Hasrun, "Assesmen Bangunan Gedung Dengan Metode Non Destructive Test (Ndt) Dan Destructive Test (Dt)," 2023, [Online]. Available: <https://journal.unm.ac.id/index.php/Semnasdies62/index>
- [2] A. Khumaidi and R. L. Pradana, "Identifikasi Penyebab Cacat Pada Hasil Pengelasan Dengan Image Processing Menggunakan Metode Yolo," *J. Tek. Elektro dan Komput. TRIAC*, vol. 9, no. 3, pp. 107–112, 2022, [Online]. Available: <https://journal.trunojoyo.ac.id/triac/article/view/15997>



- [3] R. Andiana, R. Adhitya, A. M. Amri, and P. Perkapalan Negeri Surabaya, "Penerapan Metode LSB Untuk Perbaikan Kualitas Citra Pada Proses Inspeksi Visual Pengelasan," vol. 1, no. 2, pp. 151–156, 2022, [Online]. Available: <http://melatijournal.com/index.php/Metta>
- [4] M. Karim *et al.*, "Rancang Bangun Aplikasi Intelligent Visual Scanner berbasis CNN untuk identifikasi cacat pada hasil pengelasan," vol. 4, no. 2, pp. 1–11, 2023.
- [5] A. Akter *et al.*, "Robust clinical applicable CNN and U-Net based algorithm for MRI classification and segmentation for brain tumor," *Expert Syst. Appl.*, vol. 238, no. PF, p. 122347, 2024, doi: 10.1016/j.eswa.2023.122347.
- [6] S. Tommy, N. Siti, M. T. Roseno, and H. Syaputra, "Segmentasi Ruang Jantung Dalam Kondisi Kardiomegali Menggunakan Metode CNN Dengan," vol. 12, pp. 455–461, 2023.
- [7] Y. A. Suwitono and F. J. Kaunang, "Implementasi Algoritma Convolutional Neural Network (CNN) Untuk Klasifikasi Daun Dengan Metode Data Mining SEMMA Menggunakan Keras," *J. Komtika (Komputasi dan Inform.)*, vol. 6, no. 2, pp. 109–121, 2022, doi: 10.31603/komtika.v6i2.8054.
- [8] H. Miao, Z. Zhao, C. Sun, B. Li, and R. Yan, "A U-Net-Based Approach for Tool Wear Area Detection and Identification," *IEEE Trans. Instrum. Meas.*, vol. 70, 2021, doi: 10.1109/TIM.2020.3033457.
- [9] A. Ghosh, A. Sufian, F. Sultana, A. Chakrabarti, and D. De, *Fundamental concepts of convolutional neural network*, vol. 172, no. June, 2019. doi: 10.1007/978-3-030-32644-9_36.
- [10] I. Nihatul Husna, M. Ulum, A. Kurniawan Saputro, D. Tri Laksono, and D. Neipa Purnamasari, "Rancang Bangun Sistem Deteksi Dan Perhitungan Jumlah Orang Menggunakan Metode Convolutional Neural Network (CNN)," *Semin. Nas. Fortei Reg.*, vol. 7, p. 2, 2022.
- [11] R. Kurniawan, P. B. Wintoro, Y. Mulyani, and M. Komarudin, "Implementasi Arsitektur Xception Pada Model Machine Learning Klasifikasi Sampah Anorganik," *J. Inform. dan Tek. Elektro Terap.*, vol. 11, no. 2, pp. 233–236, 2023, doi: 10.23960/jitet.v11i2.3034.
- [12] M. K. Al Amin *et al.*, "Analysis of Optimizer Effects on CNN Model for Defect Identification in Welding Results of A 106 Grade B Carbon Steel Pipe," in *2023 International Conference on Electrical Engineering and Informatics (ICEEI)*, 2023, pp. 1–6. doi: 10.1109/ICEEI59426.2023.10346872.
- [13] I. Gusmanda, J. Raharjo, and E. Suhartono, "Deteksi Penyakit Pneumonia Berbasis Citra X-," *Telkom Univ.*, vol. 10, no. 6, pp. 5178–5181, 2023.

