



Pengendalian Kualitas Produksi Lembaran Baja Melalui Klasifikasi Jenis Cacat Permukaan Menggunakan CNN

Dina Indarti¹, Asep Mohamad Noor²

^{1,2} Program Studi Magister Teknik Industri dan Manajemen, Universitas Gunadarma
Jl. Margonda Raya No. 100, Depok, Jawa Barat 16424
Email: dina_indarti@staff.gunadarma.ac.id, asepmn@staff.gunadarma.ac.id

Abstract

Quality control of steel sheet production using human visual perception frequently results in errors and takes longer. The implementation of deep learning to control the quality of steel sheet production can be done with high accuracy and in real time. The classification of surface defects on steel sheet is critical for automatically controlling the quality of steel sheet production. Deep learning can quickly identify and eliminate the causes of defects in sheet steel production by classifying the type of defects. This study aims to control the quality of steel sheet production automatically by classifying the types of surface defects using the Convolutional Neural Network (CNN). The CNN model used in this study is CNN with transfer learning from 5 pre-trained models Resnet50, VGG-16, VGG-19, Inception V3, and Xception. There are 6 types of surface defects, namely crazing, inclusion, pitted, patches, rolled, and scratch. The research begins with taking image data on steel sheet that has surface defects. The number of images used in this study is 1.800 images consisting of 1.152 training data, 288 validation data, and 360 testing data. Preprocessing is carried out, namely normalization, augmentation, and one-hot encoding. After preprocessing, training and validation was carried out using transfer learning from 5 pre-trained models. The training result model is used at the testing stage. The results of the training and validation show that Xception has the best performance because of the highest training and validation accuracy values, the lowest training and validation losses, and the lowest validation and loss GAPs. The test results show that transfer learning from the pre-trained Xception model has the best performance with an accuracy of 98%.

Keywords: *classification, convolutional neural network, quality control, steel sheet, surface defects*

Abstrak

Pengendalian kualitas produksi lembaran baja dengan persepsi visual manusia sering kali terjadi kesalahan dan membutuhkan waktu yang lebih lama. Implementasi *deep learning* dalam pengendalian kualitas produksi lembaran baja dapat memiliki akurasi yang baik dan dilakukan secara *real-time*. Klasifikasi jenis cacat permukaan pada lembaran baja merupakan hal yang penting dalam pengendalian kualitas produksi lembaran baja secara otomatis. Dengan mengklasifikasikan jenis cacat menggunakan *deep learning* dapat mengidentifikasi dan menghilangkan penyebab terjadinya cacat saat produksi lembaran baja dengan cepat. Penelitian ini bertujuan untuk mengendalikan kualitas produksi lembaran baja secara otomatis melalui klasifikasi jenis cacat permukaan menggunakan *Convolutional Neural Network* (CNN). Model CNN yang digunakan pada penelitian ini yaitu CNN dengan *transfer learning* dari 5 *pre-trained model* Resnet50, VGG-16, VGG-19, Inception V3, dan Xception. Terdapat 6 jenis cacat permukaan yang diklasifikasikan yaitu *crazing*, *inclusion*, *pitted*, *patches*, *rolled*, dan *scratch*. Penelitian dimulai dengan pengambilan data citra lembaran baja yang memiliki cacat permukaan. Jumlah citra yang digunakan dalam penelitian ini yaitu 1.800 citra terdiri dari 1.152 data pelatihan, 288 data validasi, dan 360 data pengujian. Selanjutnya dilakukan *preprocessing* yaitu normalisasi, augmentasi, dan *one-hot encoding*. Setelah *preprocessing* dilakukan pelatihan dan validasi menggunakan *transfer learning* dari 5 *pre-trained model*. Model hasil pelatihan digunakan pada tahap pengujian. Hasil pelatihan dan validasi menunjukkan bahwa Xception memiliki kinerja terbaik karena nilai akurasi pelatihan dan validasi tertinggi, nilai *loss* pelatihan dan validasi

terendah, serta GAP validasi dan *loss* terendah. Hasil pengujian menunjukkan bahwa *transfer learning* dari *pre-trained* model Xception memiliki kinerja terbaik dengan akurasi sebesar 98%.

Kata kunci: cacat permukaan, *convolutional neural network*, klasifikasi, lembaran baja, pengendalian kualitas

Pendahuluan

Perusahaan manufaktur dalam memproduksi suatu produk telah memiliki standar terhadap kualitas produk tersebut. Jika produk yang dihasilkan tidak sesuai dengan standar yang telah ditetapkan oleh perusahaan maka produk tersebut dikatakan produk cacat atau gagal. Kualitas suatu produk menjadi salah satu faktor penting yang mempengaruhi konsumen dalam pemilihan suatu produk. Kualitas pada industri manufaktur selain menekankan pada produk yang dihasilkan, juga memperhatikan kualitas pada proses produksi. Jika diketahui ada cacat atau kesalahan pada proses produksi, maka produk yang dihasilkan masih dapat diperbaiki. Pengendalian kualitas merupakan strategi bisnis yang penting bagi perusahaan sehingga dapat memuaskan konsumen dan mendominasi para pesaing (Montgomery, 2009).

Lembaran baja merupakan bahan yang sangat diperlukan untuk industri otomotif, industri pertahanan nasional, manufaktur mesin, industri kimia, dan industri lainnya. Proses produksi lembaran baja merupakan proses yang kompleks di mana lembaran baja bersentuhan dengan mesin mulai dari pemanasan, pengecoran, pengeringan, dan pemotongan (Sharifzadeh et al., 2008). Selama proses produksi beberapa cacat permukaan yang mungkin terjadi pada lembaran baja (Luo et al., 2020). Cacat permukaan pada lembaran baja menyebabkan penurunan kualitasnya. Dengan pengklasifikasian jenis cacat tersebut memungkinkan untuk dengan cepat mengidentifikasi dan menghilangkan penyebab terjadinya cacat (Mazur & Koinov, 2016). Oleh karena itu, efisiensi dan akurasi klasifikasi cacat merupakan hal yang penting dalam pengendalian kualitas produk logam.

Pengendalian kualitas produk dengan persepsi visual manusia sering kali terjadi kesalahan dan membutuhkan waktu produksi yang lebih lama. Solusi yang dapat digunakan yaitu penggunaan komputer dan peralatan lain

seperti kamera dan sensor sehingga dapat melakukan pengendalian otomatis kualitas produk secara *real-time*. Pemeriksaan, pengenalan, dan klasifikasi objek untuk menjamin kualitas suatu produk menjadi tugas penting dalam otomasi kualitas produk (Vergara-Villegas et al., 2014).

Penelitian mengenai pengendalian kualitas produk secara otomatis melalui klasifikasi objek telah dilakukan oleh beberapa peneliti. Pengendalian kualitas melalui klasifikasi lima jenis cacat pada bahan dilakukan menggunakan filter Gabor dan *Principal Component Analysis* (PCA). Akurasi klasifikasi mencapai 98,8%. Dengan metode klasifikasi yang digunakan maka pengendalian kualitas produksi bahan dapat dilakukan secara otomatis dengan tingkat kesalahan yang lebih kecil dibandingkan pengendalian kualitas menggunakan persepsi visual manusia (Bissi et al., 2013). Penelitian mengenai klasifikasi tiga jenis cacat pada kayu untuk pengendalian kualitas kayu secara otomatis telah dilakukan oleh Qayyum et al. (2016). Metode yang digunakan untuk klasifikasi yaitu *Gray Level Co-occurrence Matrix* (GLCM) dan *Particle Swarm Optimization* (PSO). Akurasi klasifikasi hanya mencapai 78,26%. Akurasi yang diperoleh kurang baik karena GLCM merupakan deskriptor spasial sehingga tidak dapat menangkap komponen dengan frekuensi tinggi atau rendah dari cacat multi-arah pada permukaan kayu. Dalam industri tekstil, klasifikasi jenis cacat pada bahan sangat penting dalam mengontrol kualitas produksi bahan (Bissi et al., 2013). Klasifikasi jenis cacat pada kayu juga merupakan hal yang penting dalam pengendalian kualitas kayu. Oleh karena itu, pada penelitian ini dilakukan pengendalian kualitas lembaran baja melalui klasifikasi jenis cacat pada permukaan lembaran baja.

Saat ini model yang populer untuk memecahkan masalah klasifikasi citra adalah *deep learning*. Model ini memberikan hasil yang bagus terkait pengenalan objek secara visual, seperti klasifikasi citra, deteksi dan

alokasi objek, dan segmentasi citra. *Deep learning* merupakan salah satu bidang dari *machine learning* yang memanfaatkan jaringan syaraf tiruan untuk menyimulasikan bagaimana cara kerja otak manusia (Russell & Norvig, 2021). Salah satu arsitektur model *deep learning* yang memiliki performa terbaik dalam klasifikasi citra yaitu *Convolutional Neural Network* (CNN) (Krizhevsky et al., 2017). CNN mampu melakukan proses pembelajaran mandiri untuk pengenalan objek, ekstraksi objek, dan klasifikasi citra (Zhang et al., 2018). Pada CNN setiap neuron dipresentasikan dalam bentuk dua dimensi, sehingga metode ini cocok untuk pemrosesan dengan *input* berupa citra (Russell & Norvig, 2021).

Penggunaan CNN dalam permasalahan klasifikasi citra dengan jumlah data yang banyak dapat mencapai kinerja yang optimal, tetapi jika jumlah data sedikit dapat menggunakan pendekatan *transfer learning* dari *pre-trained model* CNN yang telah ada. *Transfer learning* adalah pendekatan CNN dengan memindahkan model yang telah terlatih pada suatu *dataset* yang sangat besar, biasanya menggunakan Imagenet, untuk menyelesaikan masalah pada *dataset* lainnya (Torrey & Shavlik, 2010). *Pre-trained model* CNN yang memiliki akurasi yang baik dan banyak digunakan antara lain VGG (Simonyan & Zisserman, 2014), ResNet (He et al., 2016), Inception V3 (Szegedy et al., 2016), dan Xception (Chollet, 2017).

Beberapa penelitian telah membahas mengenai klasifikasi jenis cacat pada logam. Penelitian yang dilakukan oleh Zhou et al. (2017) membahas mengenai pengembangan arsitektur CNN dalam mengklasifikasikan cacat permukaan pada lembaran baja. Kernel yang digunakan pada penelitian tersebut diinisialisasi dengan kernel filter yang telah dipelajari sehingga vektor fitur dan softmax dapat dipelajari secara simultan. Hasil pelatihan menunjukkan akurasi antara 77% sampai 99,9%. Akurasi klasifikasi antara 78% sampai 99%. Penelitian lain membahas mengenai klasifikasi tiga jenis cacat pada permukaan logam menggunakan model ResNet. Kinerja klasifikasi terbaik menggunakan model ResNet50 dengan akurasi mencapai 96,91% (Konovalenko et al., 2020). Penelitian yang dilakukan oleh Bansal (2020) membahas mengenai model Xception, U-Net, Mask RCNN, dan UNet++ yang

digunakan untuk mengklasifikasikan 4 jenis cacat pada lembaran baja. Hasil penelitian menunjukkan bahwa model Xception memiliki performa klasifikasi yang terbaik.

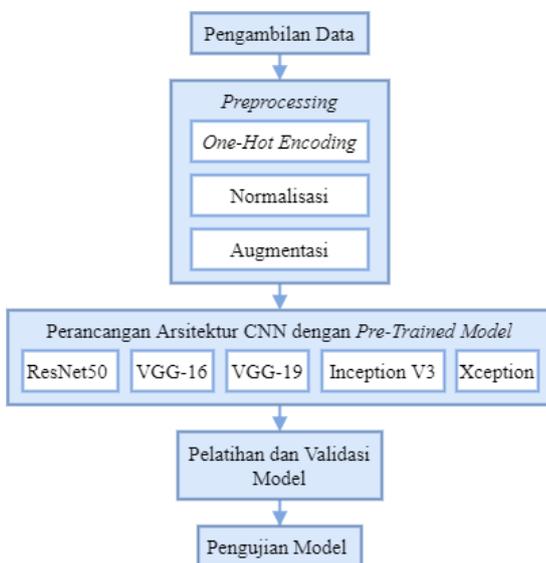
Pada proses produksi lembaran baja, data citra jenis cacat permukaan yang dikumpulkan jumlahnya terbatas sehingga penggunaan CNN dapat tidak optimal. Pengembangan arsitektur CNN telah dilakukan pada penelitian yang dilakukan oleh Zhou et al. (2017) tetapi akurasi pelatihan dan klasifikasi dapat kurang baik jika menggunakan jumlah parameter model yang kecil. Oleh karena itu, klasifikasi jenis cacat permukaan lembaran baja pada penelitian ini menggunakan *transfer learning* dari beberapa *pre-trained model* CNN yang telah memiliki kinerja baik pada *dataset* Imagenet yaitu VGG, ResNet, Inception V3, dan Xception. Penelitian yang dilakukan oleh Konovalenko et al. (2020) dan Bansal (2020) telah memiliki kinerja yang baik dalam mengklasifikasikan jenis cacat pada permukaan logam tetapi kedua penelitian terbatas hanya mengklasifikasi maksimal empat jenis cacat pada permukaan logam. Pada penelitian ini dilakukan klasifikasi enam jenis cacat pada permukaan lembaran baja.

Tujuan penelitian ini adalah melakukan pengendalian kualitas produksi lembaran baja secara otomatis melalui klasifikasi jenis cacat permukaan pada lembaran baja menggunakan CNN dengan *transfer learning*. Adanya keterbatasan jumlah data citra jenis cacat permukaan lembaran baja yang dikumpulkan sehingga penelitian ini menggunakan CNN dengan *transfer learning*. Penelitian ini menggunakan arsitektur *pre-trained model* CNN yaitu ResNet50, VGG-16, VGG-19, Inception V3, dan Xception pada lapisan ekstraksi fitur lalu mengubah bagian lapisan klasifikasi menggunakan *dense layer* dengan fungsi aktivasi ReLU dan softmax. Jenis cacat permukaan pada lembaran baja yang diklasifikasikan pada penelitian ini terdiri dari 6 yaitu *rolled-in scale*, *patches*, *crazing*, *pitted surface*, *inclusion*, dan *scratches*.

Metodologi

Adapun tahapan pada penelitian ini ditunjukkan oleh Gambar 1. Berdasarkan Gambar 1, tahapan penelitian dimulai dengan pengambilan data, yaitu tahap untuk mendapatkan data citra yang akan digunakan

pada proses pelatihan, validasi, dan pengujian model. Tahap selanjutnya dilakukan *preprocessing* citra yang terdiri dari *one-hot encoding*, augmentasi (Russell & Norvig, 2021), dan normalisasi (Tammina, 2019). Setelah *preprocessing*, tahap selanjutnya adalah merancang arsitektur model CNN dengan *pre-trained model* ResNet50, VGG-16, VGG-19, Inception V3, dan Xception. Pada penelitian ini digunakan arsitektur lima *pre-trained model* CNN tersebut pada lapisan ekstraksi fitur lalu mengubah bagian lapisan klasifikasi menggunakan *dense layer* dengan fungsi aktivasi ReLU dan softmax. Setiap model tersebut selanjutnya digunakan dalam proses pelatihan dan validasi. Selanjutnya setiap model hasil pelatihan digunakan dalam proses pengujian untuk mengklasifikasikan jenis cacat permukaan pada lembaran baja. Model klasifikasi dengan akurasi terbaik selanjutnya dapat disimpan dalam komputer dan peralatan lain seperti kamera atau sensor yang terdapat dalam proses manufaktur lembaran baja sehingga dapat melakukan pengendalian otomatis kualitas produk lembaran baja secara *real-time*.



Gambar 1. Tahapan penelitian

Pengambilan Data

Data citra yang digunakan pada penelitian ini merupakan data sekunder yang diperoleh dari Kaggle (Kaggle, 2020). Data ini berasal dari Northeastern University (NEU) *Metal Surface Defects Database* yang berisi 6 jenis cacat permukaan pada lembaran baja yaitu, *rolled-in scale (RS)*, *patches (Pa)*, *crazing (Cr)*, *pitted surface (PS)*, *inclusion (In)*, dan

scratches (Sc). Data terdiri dari 1.800 citra *grayscale* dengan format *.bmp* berukuran 200×200 piksel dimana pada setiap jenis cacat permukaan pada lembaran baja terdapat 300 citra.

Preprocessing Data

Pada tahap *preprocessing* dilakukan *one-hot encoding*, normalisasi, dan augmentasi data citra. *One-hot encoding* digunakan karena jenis cacat permukaan pada lembaran baja terdiri dari 6 kategori yang tidak dapat dibedakan kedudukannya, sehingga diperlukan pelabelan pada tiap kategori. Bentuk *one-hot encoding* pada setiap jenis cacat permukaan pada lembaran baja dapat dilihat pada Tabel 1. Normalisasi dilakukan pada semua data pelatihan, validasi, dan pengujian. Augmentasi data yang dilakukan pada data pelatihan sebagai berikut:

1. *Width Shift Range* sebesar 0,2, artinya citra ditranslasi secara horizontal (sepanjang sumbu *x*) dengan jarak 20%.
2. *Height Shift Range* sebesar 0,2, artinya citra ditranslasi secara vertikal (sepanjang sumbu *y*) dengan jarak 20%.
3. *Shear Range* sebesar 0,2, artinya citra diubah sudut pandangnya dengan jarak 20% pada sumbu *x* atau sumbu *y*.
4. *Zoom Range* sebanyak 0,2, artinya citra diubah secara *zoom-in* atau *zoom-out* sebesar 20%.
5. *Horizontal Flip*, artinya citra dibalik secara horizontal.
6. *Vertical Flip*, artinya citra dibalik secara vertikal.

Tabel 1. Bentuk *one-hot encoding* jenis cacat permukaan pada lembaran baja

Citra ke-	Cr	In	Pa	PS	RS	Sc
1	1	0	0	0	0	0
2	0	1	0	0	0	0
3	0	0	1	0	0	0
4	0	0	0	1	0	0
5	0	0	0	0	1	0
6	0	0	0	0	0	1

Perancangan Arsitektur Model CNN

Model yang digunakan pada perancangan ini yaitu CNN dengan arsitektur ResNet50, VGG-16, VGG-19, Inception V3, dan Xception sebagai *pre-trained model*. *Pre-trained model* terdiri dari *base model (feature extraction layer)* dan *custom head network (classification*

layer). Pada penelitian ini digunakan *transfer learning* dengan mempertahankan fitur pada *base model*, lalu mengubah bagian *custom head network* sesuai dengan kebutuhan klasifikasi jenis cacat permukaan pada lembaran baja. *Custom head network* yang digunakan pada penelitian ini yaitu *dense layer* dengan fungsi aktivasi ReLU, dan *dense layer* dengan fungsi aktivasi softmax. Arsitektur CNN dengan *transfer learning* dari *pre-trained model* ResNet50, VGG-16, VGG-19, Inception V3, dan Xception yang digunakan pada penelitian dapat dilihat pada Gambar 2.

Parameter lain yang digunakan pada model ini yaitu *categorical cross-entropy* yang digunakan untuk mengevaluasi penggunaan model pada data yang digunakan. Parameter lain yang digunakan adalah *optimizer* Adam sebagai pengoptimal bobot model saat proses pelatihan dengan mengurangi nilai jarak dari hasil *categorical cross-entropy*.

Pelatihan

Jumlah citra yang digunakan pada penelitian ini adalah 1.800 citra lalu dibagi menjadi data latih, data validasi, dan data uji. Data latih dan validasi menggunakan 80% dari keseluruhan citra, sehingga jumlahnya sebanyak 1.440 citra. Lalu 1.440 citra tersebut dibagi lagi menjadi data pelatihan sebanyak 1.152 citra dan data validasi sebanyak 288 citra.

Model yang telah dirancang kemudian disiapkan dengan mengatur konfigurasi *loss*, *optimizer*, dan *metrics* yang digunakan pada proses pelatihan. Penelitian ini menggunakan *optimizer* Adam (Kingma & Ba, 2014) dengan *learning rate* 0,0001 dan *loss* menggunakan *categorical* menyesuaikan dengan jenis data

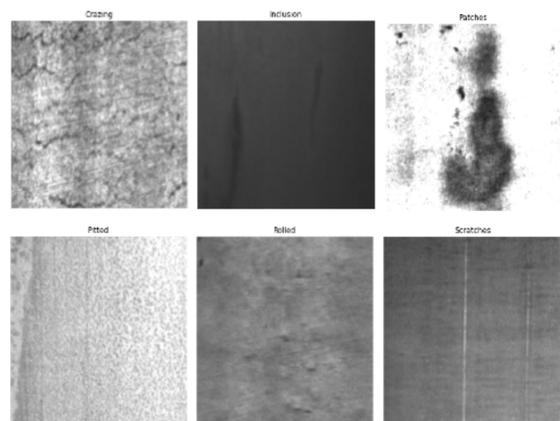
pada tahap *preprocessing*, lalu *metrics* yang digunakan adalah *accuracy*. Pada tahap pelatihan juga dilakukan konfigurasi berupa aturan jumlah *epoch*. Pada penelitian ini digunakan 4 inialisasi *epoch* yaitu 10, 25, 50, dan 100.

Pengujian

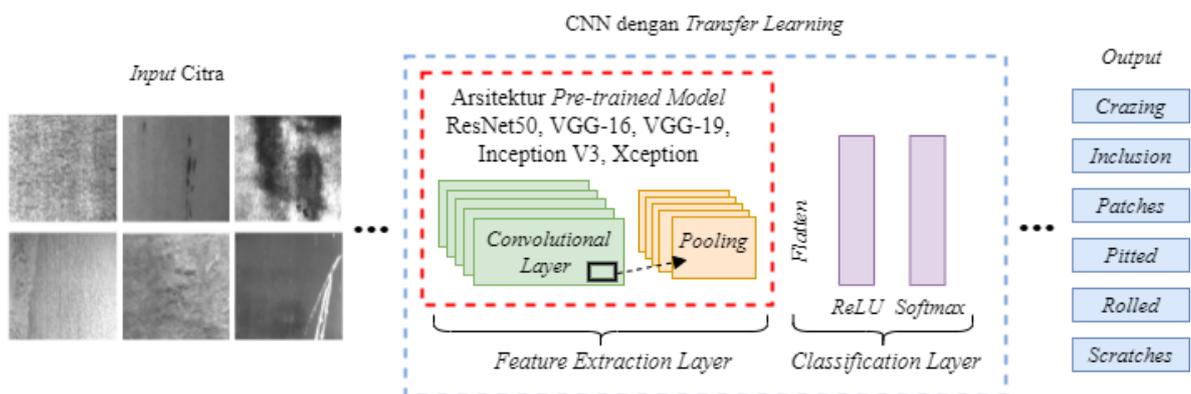
Data uji menggunakan 20% dari keseluruhan citra, sehingga jumlahnya sebanyak 360 citra. Pengujian dilakukan untuk menguji model yang telah melakukan pelatihan dan validasi, sehingga dapat mengenali data baru yang berbeda dari saat pelatihan dan validasi. Hasil pengujian setiap model direpresentasikan menggunakan *confusion matrix* (Han et al., 2011) untuk memperoleh nilai akurasi, presisi, *recall*, dan F1.

Hasil dan Pembahasan

Contoh data citra pada penelitian ini dapat dilihat pada Gambar 3.



Gambar 3. Contoh Data Citra



Gambar 2. Arsitektur *pre-trained model* CNN dengan *transfer learning*

Hasil Pelatihan

Sebagian data citra yang telah melalui tahap *pre-processing* selanjutnya digunakan pada tahap pelatihan. Nilai akurasi dan *loss* pelatihan dengan *transfer learning* dari *pre-trained model* ResNet50, VGG-16, VGG-19, Inception V3, dan Xception menggunakan 4 nilai *epoch* yaitu 10, 25, 50, dan 100 dapat dilihat pada Tabel 2.

Tabel 2. Nilai akurasi dan *loss* pelatihan menggunakan *transfer learning* dari 5 *pre-trained model*

Model	Epoch	Pelatihan		Validasi	
		Acc.	Loss	Acc.	Loss
ResNet50	10	49,57	1,45	49,31	1,43
	25	51,74	1,39	46,88	1,38
	50	67,8	1,11	63,89	1,13
	100	77,69	0,83	68,75	0,94
VGG-16	10	92,88	0,34	90,62	0,4
	25	97,05	0,15	93,06	0,22
	50	97,05	0,09	91,67	0,2
	100	98,61	0,05	92,71	0,2
VGG-19	10	87,85	0,52	84,72	0,56
	25	91,49	0,28	90,62	0,32
	50	96,01	0,16	94,10	0,18
	100	97,04	0,1	95,83	0,13
Inception V3	10	98,7	0,04	96,88	0,12
	25	99,2	0,03	95,83	0,12
	50	98,7	0,04	95,83	0,12
	100	99,74	0,01	95,49	0,19
Xception	10	99,39	0,03	97,92	0,11
	25	99,31	0,03	98,26	0,08
	50	99,57	0,02	97,92	0,06
	100	99,74	0,01	98,96	0,04

Berdasarkan Tabel 2, nilai akurasi tertinggi dan *loss* terendah pada saat pelatihan menggunakan *transfer learning* ResNet50, VGG-16, VGG-19, Inception V3, dan Xception dengan *epoch* 100. Nilai akurasi pelatihan secara berurutan dengan *epoch* 100 tertinggi dan *loss* terendah dicapai oleh Xception, Inception V3, VGG-16, VGG-19, dan ResNet50. Kinerja validasi tertinggi dan *loss* terendah juga dicapai oleh Xception, kemudian diikuti oleh VGG-19, Inception V3, VGG-16, dan ResNet50. Jika dibandingkan hanya pada nilai akurasi pelatihan dan validasi, sebenarnya ada dua kelompok kinerja yaitu kelompok tinggi dicapai oleh Xception, Inception V3, VGG-16, dan VGG-19, dan kelompok rendah dicapai oleh ResNet50. Kelompok tinggi disebabkan akurasi lebih dari 90% sedangkan kelompok rendah mencapai akurasi kurang dari 90%.

Berdasarkan Tabel 3, jika dilihat berdasarkan GAP atau selisih akurasi antara

pelatihan dan validasi, maka GAP akurasi terendah secara berurutan dicapai oleh Xception, VGG-19, Inception V3, VGG-16, dan ResNet50. Jika dilihat berdasarkan GAP atau selisih *loss* antara pelatihan dan validasi, maka GAP *loss* terendah secara berurutan dicapai oleh Xception, VGG-19, ResNet50, VGG-16, dan Inception V3. Secara keseluruhan, kinerja Xception yang terbaik karena memiliki nilai akurasi pelatihan dan validasi tertinggi, nilai *loss* pelatihan dan validasi terendah, serta GAP validasi dan *loss* terendah.

Tabel 3. Nilai GAP pelatihan menggunakan *transfer learning* dari 5 *pre-trained model*

Model	GAP	
	Acc.	Loss
ResNet50	8,94%	0,12
VGG-16	5,9%	0,15
VGG-19	1,21%	0,03
Inception V3	4,25%	0,18
Xception	0,78%	0,03

Hasil Pengujian

Nilai akurasi, presisi, *recall*, dan F1-score dan *loss* pengujian dengan *transfer learning* dari 5 *pre-trained model* ResNet50, VGG-16, VGG-19, Inception V3, dan Xception menggunakan *epoch* 100 dapat dilihat pada Tabel 4.

Tabel 4. Nilai akurasi, presisi, *recall*, dan F1-score pengujian menggunakan *transfer learning* dari 5 *pre-trained model*

Model	Akurasi	Presisi	Recall	F1-score
ResNet50	69%	76%	69%	66%
VGG-16	97%	97%	97%	97%
VGG-19	95%	95%	95%	95%
Inception V3	95%	95%	95%	95%
Xception	98%	98%	98%	98%

Berdasarkan Tabel 4, secara berurutan akurasi, presisi, *recall*, dan F1-score pengujian tertinggi dicapai oleh Xception, VGG-16, Inception V3 dan VGG-19, dan ResNet50. Kinerja pengujian dengan akurasi, presisi, *recall*, dan F1-score lebih dari 90% dicapai Xception, VGG-16, Inception V3 dan VGG-19, sedangkan ResNet50 memiliki kinerja pengujian dengan akurasi, presisi, *recall*, dan F1-score kurang dari 90%.

Secara keseluruhan, kinerja terbaik dalam mengklasifikasikan enam jenis cacat permukaan pada lembaran baja yaitu menggunakan *transfer learning* dari *pre-trained*

model Xception. Pada penelitian yang dilakukan oleh Zhou et al. (2017), akurasi pelatihan hanya mencapai 78% jika menggunakan jumlah *epoch* 50 karena arsitektur CNN yang digunakan tidak optimal jika data yang digunakan dalam pelatihan terbatas. Akurasi pelatihan pada penelitian ini yang menggunakan *transfer learning* dari *pre-trained model* Xception dengan beberapa jumlah *epoch* 10, 25, 50, dan 100 mencapai lebih dari 99%. Hasil klasifikasi jenis cacat permukaan pada lembaran baja selanjutnya digunakan untuk mengetahui penyebab terjadinya cacat saat produksi lembaran baja sehingga perbaikan kualitas lembaran baja dapat dilakukan dengan cepat. Model klasifikasi dapat disimpan dalam komputer dan peralatan lain seperti kamera atau sensor yang terdapat dalam proses manufaktur lembaran baja sehingga dapat melakukan pengendalian otomatis kualitas produk lembaran baja secara *real-time*.

Kesimpulan

Pada penelitian ini telah dilakukan pengklasifikasian enam jenis cacat permukaan dengan jumlah data citra yang terbatas menggunakan *transfer learning* dari *pre-trained model* CNN. CNN dengan *transfer learning* dari 5 *pre-trained model* ResNet50, VGG-16, VGG-19, Inception V3, dan Xception dapat mengklasifikasi enam jenis cacat permukaan pada lembaran baja dengan baik. Arsitektur model CNN yang digunakan pada penelitian ini yaitu *feature extraction layer* menggunakan arsitektur dari *pre-trained model* lalu mengubah *classification layer* menggunakan *flatten layer* dan 2 *dense layer* dengan fungsi aktivasi ReLU dan softmax. Akurasi klasifikasi enam jenis cacat permukaan pada lembaran baja menggunakan CNN dengan *transfer learning* dari 5 *pre-trained model* yaitu ResNet50 sebesar 69%, VGG-16 sebesar 97%, VGG-19 sebesar 95%, Inception V3 sebesar 95%, dan Xception sebesar 98%. Secara keseluruhan, kinerja Xception terbaik dalam mengklasifikasikan jenis cacat permukaan pada lembaran baja karena memiliki nilai akurasi pelatihan dan validasi tertinggi, nilai *loss* pelatihan dan validasi terendah, GAP validasi dan *loss* terendah, dan akurasi, presisi, *recall*, dan F1-score pengujian tertinggi. Hasil klasifikasi jenis cacat

permukaan pada lembaran baja selanjutnya digunakan untuk mengetahui penyebab terjadinya cacat saat produksi lembaran baja sehingga perbaikan kualitas lembaran baja dapat dilakukan dengan cepat.

Pada penelitian lebih lanjut, model klasifikasi dapat disimpan dalam komputer dan peralatan lain seperti kamera atau sensor yang terdapat dalam proses manufaktur lembaran baja sehingga dapat melakukan pengendalian otomatis kualitas produk lembaran baja secara *real-time*. Klasifikasi dapat dikembangkan dengan penambahan jumlah jenis cacat permukaan dan jumlah citra pada *dataset*. Model *deep learning* dapat dikembangkan lebih lanjut sehingga dapat mendeteksi lebih dari satu jenis cacat permukaan pada suatu lembaran baja. Klasifikasi jenis cacat pada lembaran baja juga dapat diterapkan lebih lanjut dalam perawatan bangunan dengan konstruksi baja. Model klasifikasi jenis cacat tersebut dapat diimplementasikan dalam bentuk aplikasi *mobile* sehingga pengguna aplikasi (pengawas bangunan) dapat mengambil foto bagian bangunan yang terdapat cacat atau kerusakan. Berdasarkan foto tersebut dapat diketahui jenis cacat sehingga dapat dilakukan penanganan yang diperlukan untuk memperbaiki cacat tersebut.

Daftar Pustaka

- Bansal, A. (2020). *Identification and Classification of Defects in Steel Sheets using Deep Learning Models* [National College of Ireland]. <http://norma.ncirl.ie/4432/1/akanshabansal.pdf>
- Bissi, L., Baruffa, G., Placidi, P., Ricci, E., Scorzoni, A., & Valigi, P. (2013). Automated defect detection in uniform and structured fabrics using Gabor filters and PCA. *Journal of Visual Communication and Image Representation*, 24(7), 838–845. <https://doi.org/10.1016/j.jvcir.2013.05.011>
- Chollet, F. (2017). Xception: Deep Learning with Depthwise Separable Convolutions. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1800–1807. <https://doi.org/10.1109/CVPR.2017.195>
- Han, J., Kamber, M., & Pei, J. (2011). *Data Mining Concepts and Techniques* (3rd ed.). Elsevier.

- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Kaggle. (2020). *Metal Surface Defects Dataset*. <https://www.kaggle.com/fantacher/neu-metal-surface-defects-data>
- Kingma, D. P., & Ba, J. (2014). *Adam: A Method for Stochastic Optimization*. <http://arxiv.org/abs/1412.6980>
- Konovalenko, I., Maruschak, P., Brezinová, J., Viňáš, J., & Brezina, J. (2020). Steel surface defect classification using deep residual neural network. *Metals*, 10(6), 1–15. <https://doi.org/10.3390/met10060846>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. <https://doi.org/10.1145/3065386>
- Luo, Q., Fang, X., Liu, L., Yang, C., & Sun, Y. (2020). Automated Visual Defect Detection for Flat Steel Surface: A Survey. *IEEE Transactions on Instrumentation and Measurement*, 69(3), 626–644. <https://doi.org/10.1109/TIM.2019.2963555>
- Mazur, I., & Koinov, T. (2016). Quality Control system for a hot-rolled metal surface. *Frattura Ed Integrità Strutturale*, 10(37), 287–296. <https://doi.org/10.3221/IGF-ESIS.37.38>
- Montgomery, D. C. (2009). *Introduction to Statistical Quality Control* (6th ed.). John Wiley & Son.
- Qayyum, R., Kamal, K., Zafar, T., & Mathavan, S. (2016). Wood Defects Classification Using GLCM Based Features And PSO Trained Neural Network. *22nd International Conference on Automation and Computing (ICAC)*, 273–277. <https://doi.org/https://doi.org/10.1109/IConA C.2016.7604931>
- Russell, S., & Norvig, P. (2021). *Artificial Intelligence A Modern Approach*. Pearson.
- Sharifzadeh, M., Alirezaee, S., Amirfattahi, R., & Sadri, S. (2008). Detection of steel defect using the image processing algorithms. *2008 IEEE International Multitopic Conference*, 125–127. <https://doi.org/10.1109/INMIC.2008.4777721>
- Simonyan, K., & Zisserman, A. (2014). *Very Deep Convolutional Networks for Large-Scale Image Recognition*. <http://arxiv.org/abs/1409.1556>
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the Inception Architecture for Computer Vision. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2818–2826. <https://doi.org/10.1109/CVPR.2016.308>
- Tammina, S. (2019). Transfer learning using VGG-16 with Deep Convolutional Neural Network for Classifying Images. *International Journal of Scientific and Research Publications (IJSRP)*, 9(10), 143–150. <https://doi.org/10.29322/IJSRP.9.10.2019.p9420>
- Torrey, L., & Shavlik, J. (2010). Transfer Learning. In *Handbook of Research on Machine Learning Applications and Trends: Algorithms, Methods, and Techniques* (pp. 242–264). IGI Global.
- Vergara-Villegas, O. O., Cruz-Sánchez, V. G., de Jesús Ochoa-Domínguez, H., de Jesús Nandayapa-Alfaro, M., & Flores-Abad, Á. (2014). Automatic Product Quality Inspection Using Computer Vision Systems. In *Lean Manufacturing in the Developing World* (pp. 135–156). Springer International Publishing. https://doi.org/10.1007/978-3-319-04951-9_7
- Zhang, C., Sargent, I., Pan, X., Gardiner, A., Hare, J., & Atkinson, P. M. (2018). VPRS-Based Regional Decision Fusion of CNN and MRF Classifications for Very Fine Resolution Remotely Sensed Images. *IEEE Transactions on Geoscience and Remote Sensing*, 56(8), 4507–4521. <https://doi.org/10.1109/TGRS.2018.2822783>
- Zhou, S., Chen, Y., Zhang, D., Xie, J., & Zhou, Y. (2017). Classification of surface defects on steel sheet using convolutional neural networks. *Materiali in Tehnologije*, 51(1), 123–131. <https://doi.org/10.17222/mit.2015.335>

Ucapan Terima Kasih

Terima kasih kepada Universitas Gunadarma yang telah mendukung terlaksananya penelitian ini.