

## Deteksi dan Klasifikasi Cacat Kemasan Kaleng Menggunakan *Convolutional Neural Network*

Rindi Kusumawardani<sup>1</sup>, Putu Dana Karningsih<sup>2</sup>

<sup>1,2</sup>Teknik Sistem dan Industri, FTIRS, Institut Teknologi Sepuluh Nopember

E-mail: [rindi@its.ac.id](mailto:rindi@its.ac.id)

### ABSTRAK

Kemasan menjadi salah satu aspek penting yang menunjukkan identitas suatu produk. Kemasan yang baik dan menarik dapat meningkatkan daya saing produk karena memberi persepsi pada pelanggan akan kualitas yang baik dari suatu produk. Untuk itu, tampilan kemasan yang baik sangat diperlukan sehingga inspeksi kualitas kemasan sangat menjadi hal yang penting. Deteksi kerusakan secara otomatis akan dapat mengurangi terjadinya human error pada proses inspeksi manual. Convolutional Neural Network (CNN) adalah salah satu pendekatan yang dapat digunakan untuk melakukan deteksi dan klasifikasi kondisi pada kemasan. Ekperimen dilakukan dengan membandingkan 5 model jaringan, yaitu ShuffleNet, GoogLeNet, ResNet18, ResNet50, dan ResNet101, dengan menggunakan parameter yang sama. Dataset yang digunakan adalah citra untuk kemasan jenis kaleng yang dibagi menjadi 3 klasifikasi yaitu, No Deffect, Minor Defect, dan Major Defect. Hasil eksperimen menunjukkan bahwa model arsitektur jaringan ResNet50 dan ResNet101 memberikan hasil pengelompokan cacat pada kemasan kaleng yang paling baik dibandingkan dengan ketiga model jaringan lainnya, dengan akurasi pengujian sebesar 95,56%. Kelima model memiliki nilai akurasi pengujian diatas 90%, sehingga dapat disimpulkan bahwa kelima model jaringan sangat ideal untuk mendeteksi cacat pada kemasan kaleng dan klasifikasi jenis cacat pada kaleng.

**Kata Kunci :** Convolutional Neural Network, Deep Learning, Machine Learning, Klasifikasi, Deteksi Cacat

### ABSTRACT

Packaging is one of the important aspects of a product's identity. The good and adorable packaging can increase product competitiveness because it gives a perception to the customers of good quality products. Therefore, a good packaging display is necessary so that packaging quality inspection is very important. Automated defect detection can help to reduce human error in the inspection process. Convolutional Neural Network (CNN) is an approach that can be used to detect and classify a packaging condition. This paper presents an experiment that compares 5 network models, i.e. ShuffleNet, GoogLeNet, ResNet18, ResNet50, and Resnet101, each network given the same parameters. The dataset is an image of cans packaging which is divided into 3 classifications, No Defect, Minor Defect, and Major Defect. The experimental result shows that network architecture models of ResNet50 and ResNet101 provided the best result for cans defect classification than the other network models, with 95,56% for testing accuracy. The five models have the testing accuracy above 90%, so it can be concluded that all network models are ideal for detecting the packaging defect and defect classification for the cans product.

**Keywords:** Convolutional Neural Network, Deep Learning, Machine Learning, Classification, Defect Detection

## PENDAHULUAN

Kemasan menjadi salah satu aspek penting pada sebuah produk, dimana kualitas pada produk maupun daya saing dan identitas suatu produk dipengaruhi oleh kemasan. Persepsi pelanggan akan kualitas suatu produk ditentukan oleh tampilan luar atau kemasannya. Tampilan kemasan atau bagian luar suatu produk menentukan keputusan seseorang untuk melakukan pembelian (Baudet, et al, 2012) [1]. Fungsi utama dari kemasan adalah sebagai tempat dan pelindung produk dari kerusakan atau proses degradasi, menjaga keamanan dan kualitas, serta memastikan kondisi produk sampai pada konsumen dalam kondisi sama ketika diproduksi dan sepanjang umur simpannya (Ramos et al., 2016) [2].

Inspeksi kemasan menjadi faktor penting dalam proses manufaktur, terutama kemasan kaleng yang banyak digunakan untuk makanan dan minuman. Kemasan kaleng akan melindungi serta mengawetkan produk dari oksigen, sinar ultraviolet, panas, kelembapan udara, serta mencegah kontaminasi mikroba yang dapat merusak produk (Bratt, 2010). Saat ini proses inspeksi visual pada kemasan masih banyak yang dilakukan secara manual. Dengan keterbatasan penglihatan manusia akibat *human error* sehingga membutuhkan lebih dari 1 operator untuk memastikan keakuratan hasil. Untuk itu, saat ini inspeksi visual secara otomatis banyak dipergunakan di perusahaan minuman untuk dapat melaksanakan proses pengendalian kualitas lebih akurat dengan waktu yang lebih singkat dan biaya yang lebih rendah (Rahman et.al, 2019) [3].

Beberapa studi telah mengarah pada sistem cerdas untuk menyelesaikan permasalahan pada inspeksi cacat pada objek tertentu, salah satunya adalah inspeksi otomatis dan metode deteksi kerusakan menggunakan *image processing* yang merupakan bagian dari *machine vision* dimana saat ini telah diadopsi banyak industri (Hajizadeh et al., 2016) [5]. Dengan pengembangan teknologi *machine learning* dan *image processing*, metode inspeksi dengan menggunakan *deep learning* dan *hough transform* telah dapat mendeteksi cacat produk pada botol wine pada studi oleh Wang et al. (2019) [6]. Studi Liang et al., (2019) terkait inspeksi kemasan untuk mendeteksi kode pada kemasan plastik dengan menggunakan *Convolutional Neural Network* (CNN) dan telah berhasil membaca kode *batch* produksi dan *expired date* secara *real time* pada desain kemasan yang cukup kompleks [7]. Metode *Deep Learning* juga dilakukan untuk mendeteksi ciri-ciri cacat pada bangunan, seperti noda, *deterioration*, maupun jamur. Penelitian dilakukan dengan membandingkan model jaringan *ResNet-50*, *VGG-16*, dan *Inception* (Perez et al., 2019) [8]. Deteksi retakan pada struktur bawah tanah dengan menggunakan kombinasi *Deep Learning* dan *Image Processing* sebagai solusi dari kekurangan pada inspeksi visual telah berhasil mendeteksi retakan-retakan pada beberapa bagian dinding. Studi ini bertujuan untuk mengurangi waktu penutupan infrastruktur karena proses inspeksi dan untuk alasan keamanan pada manusia (Panella et al., 2018) [9]. Aplikasi lain dari *Deep Learning* dalam bidang makanan segar adalah deteksi cacat luar pada sayur tomat, dengan menggunakan *computer vision* dan kamera yang terpasang pada mesin sorting. Penelitian tersebut berhasil membedakan produk tomat cacat dan tomat sehat dengan rata-rata presisi dari model jaringan *ResNet50* sebesar 94,6% (Costa et al., 2019) [10]. Studi terkait pemanfaatan CNN di dunia kesehatan juga telah digunakan untuk pendeteksian patah tulang femur, studi dilakukan dengan membandingkan 5 desain arsitektur CNN dengan parameter yang sama untuk mendapatkan hasil terbaik dalam pengenalan (rekognisi) fitur permukaan tulang dan klasifikasi patah tulang, dengan menggunakan *dataset* citra UB *B-Mode* 2D tulang femur. Dari hasil *training* dan pengujian diperoleh nilai akurasi terbaik pada arsitektur CNN 4 sebesar 95,3 % (Rokhana et al, 2019) [11].

Perkembangan CNN telah banyak diaplikasikan hampir di seluruh bidang, karena sifat dari arsitektur jaringan CNN yang fleksibel dan mampu memiliki *layer* lebih dari dua serta jaringan yang dalam dan berlapis-lapis. CNN pertama kali dikenalkan oleh Yan LeCun, et al. (1998) dengan arsitektur jaringan *LeNet-5* yang berhasil merekognisi tulisan tangan dengan menggunakan 60.000 *dataset* [12]. CNN mulai berkembang pesat ketika diadakan kompetisi *ImageNet Large-Scale Visual Recognition Challenge* yang diselenggarakan pada tahun 2010, yang kemudian bermunculan arsitektur jaringan baru, seperti jaringan *AlexNet* yang memiliki arsitektur 8 lapisan (Krizhevsky et al, 2017) [13], *GoogLeNet* dengan 22 lapisan jaringan (Simonyan et al., 2014) [14], *ShuffleNet* memiliki 50 lapisan dimana di desain special untuk *small network* dengan kapasitas komputasi yang sangat terbatas (Zhang et al., 2017) [15], *ResNet50* (*Residual Network*) yang memiliki 50 lapisan jaringan dengan karakteristik melewati *blocks* pada *convolutional layers* dengan menggunakan koneksi pintasan (Rezende et al, 2017) [16], dan beberapa jaringan lainnya.

Deteksi dan Klasifikasi Cacat Kemasan Kaleng Menggunakan *Convolutional Neural Network* / Rindi Kusumawardani, Putu Dana Kusumaningsih

Peer reviewed under responsibility of Universitas Muhammadiyah Sidoarjo.

© 2020 Universitas Muhammadiyah Sidoarjo. All Right reserved. This is an open access article under the CC BY licence (<http://creativecommons.org/licenses/by/4.0/>)

Studi ini mengimplementasikan algoritma jaringan CNN pada struktur data 2 dimensi berupa citra, CNN digunakan untuk melakukan deteksi dan klasifikasi kondisi pada kemasan kaleng. Hal ini mengarah pada sistem manufaktur cerdas dengan keseluruhan system terhubung dengan jaringan, dimonitor dengan sensor, dan dikendalikan dengan komputasi cerdas yang handal untuk memperbaiki kualitas produk, produktivitas system dan *sustainability* (Wang et al., 2018) [17]. Metode yang digunakan dengan membandingkan 5 model jaringan dengan *dataset* dan *setting* parameter yang sama. Eksperimen dilakukan dengan menjalankan pelatihan masing-masing jaringan, dan dilakukan pengujian dengan data validasi. Proses selanjutnya, jaringan yang telah melalui proses *training* dan validasi, di uji menggunakan data tes yang bukan bagian dari data *training*, untuk menentukan seberapa akurat hasil *training* jaringan dengan data tes. Hasil studi ini diharapkan dapat bermanfaat terutama untuk perkembangan sistem manufaktur cerdas yang dapat digunakan pada proses *quality control* maupun proses sorting produk.

### Studi Literatur

*Convolutional Neural Network* (CNN) merupakan bagian dari *Deep Learning* yang memiliki tujuan utama untuk menyelesaikan permasalahan pada *Computer Vision* seperti klasifikasi gambar, deteksi objek, dan segmentasi. Struktur dasar jaringan CNN setidaknya memiliki tiga lapisan utama, yaitu *convolution*, *pooling*, dan *fully connected layer*, seperti terlihat pada **Gambar 1**. Pada bagian *convolutional layer* terdiri dari lapisan *convolution*, fungsi aktivasi *rectified linear unit (ReLU)*, dan *pooling*. Lapisan *convolution* bertugas untuk mengekstraksi fitur dari citra *input* dan menghasilkan beberapa *feature maps*, operasi *convolution* dapat dinyatakan dalam (1)

$$S(t) = (x * w)(t) \tag{1}$$

Dari persamaan diatas  $x$  merupakan *input* dan  $w$  adalah filter, jika  $x$  merupakan citra dua dimensi maka  $t$  merupakan pixel. Sehingga operasi *convolutional* lebih dari satu dimensi dapat ditulis dalam (2)

$$S(i,j) = (K * I)(i,j) = \sum \sum I(i-m, j-n)K(m,n) \tag{2}$$

Proses selanjutnya adalah fungsi aktivasi *ReLU* untuk meningkatkan representasi dari model. Lapisan *ReLU* berkerja sebagai *threshold* untuk setiap elemen dan tidak merubah ukuran pada input. Nilai *output* dari *neuron* dapat dinyatakan 0, dan jika *input* positif maka nilai *output* dari *neuron* adalah nilai pada input aktivasi itu sendiri, sehingga dapat dinyatakan dalam (3)

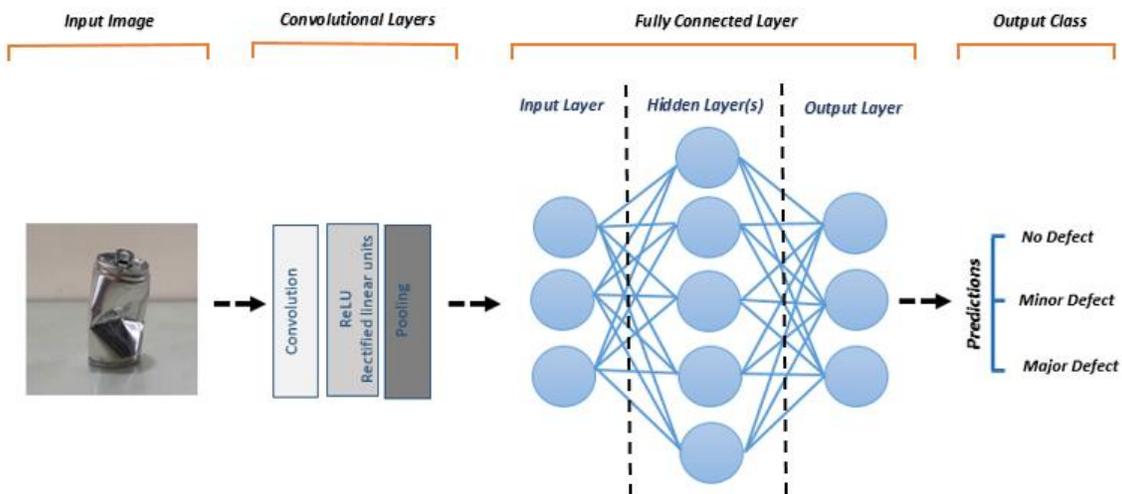
$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \tag{3}$$

*Pooling* atau *subsampling layer* berfungsi untuk mereduksi ukuran citra. Terdapat dua jenis *pooling* yang dapat digunakan, yaitu *max pooling* dan *average pooling*. Sebagian besar arsitektur CNN menggunakan *max pooling*, dimana *max pooling* akan membagi *output* dalam beberapa *grid*, dan setiap pergeseran *filter* akan mengambil nilai terbesar dari setiap *grid*, sedangkan *average pooling* akan mengambil nilai rata-rata. Pada bagian *fully connected layer* proses transformasi data dilakukan untuk diklasifikasikan secara linear, dan akan ditampilkan pada *output* berupa hasil klasifikasi.

## METODE

### A. Akuisisi Data

Pada studi ini data yang digunakan merupakan *dataset* citra kaleng dengan jenis yang sama dan dengan kondisi yang berbeda. Citra diambil dari sudut dan posisi kaleng yang berbeda-beda dengan tujuan agar jaringan mampu mempelajari kondisi kaleng pada beragam posisi dan sudut, seperti pada **Gambar 2**. *Dataset* sebanyak 600 kaleng dibagi dalam 3 kategori dan diberi label *No Defect* (tidak ada cacat), *Minor Defect* (kerusakan kecil yang tidak mempengaruhi kualitas produk), dan *Major Defect* (kerusakan pada kaleng yang dapat mempengaruhi kualitas dan desain produk). Sebanyak 80% dari data citra digunakan sebagai data training dan 20% sebagai data validasi. Sebelum dilakukan proses klasifikasi menggunakan CNN, citra terlebih dahulu melalui praproses dengan melakukan proses *wrapping* dan *cropping* pada seluruh citra agar objek pada citra tetap utuh dan kondisi citra kaleng mudah teridentifikasi. Proses selanjutnya yaitu merubah ukuran *pixel* citra agar dapat diproses oleh jaringan menjadi 224 x 224 *pixel*. Pada praproses citra tidak dilakukan perubahan menjadi *gray scale* karena tidak banyak warna pada citra.



Gambar 1. Arsitektur Dasar CNN



Gambar 2. Sampel Dataset Kemasan Kaleng

## B. Metodologi

Identifikasi citra kaleng sebagai kemasan kaleng dalam kondisi baik dan kaleng yang memiliki cacat dilakukan dengan menggunakan algoritma CNN, dengan membandingkan 5 model jaringan CNN yaitu *ShuffleNet*, *GoogLeNet*, *ResNet18*, *ResNet50*, dan *ResNet101*. Penggunaan variasi 5 model jaringan CNN bertujuan untuk mendapatkan arsitektur yang paling tepat dalam mendeteksi dan mengklasifikasi data citra kemasan kaleng. Setiap model jaringan memiliki karakteristik masing-masing, seperti yang ditunjukkan pada **Tabel 1**. Model jaringan *ShuffleNet* secara spesial di desain untuk *small network* dengan prinsip desain *bottleneck*, diaplikasikan untuk *mobile device* dengan daya komputasi yang terbatas, akan tetapi jaringan ini memiliki arsitektur yang efisien dengan menambahkan fitur *map channels* untuk menyajikan lebih banyak data dimana dapat bekerja pada jaringan yang sangat kecil (Xhang et al., 2018). Pada jaringan *GoogLeNet* didesain dengan komputasi yang efisien dan mudah dijalankan, jaringan ini dapat dijalankan pada perangkat komputasi yang cenderung rendah sehingga mempermudah siapapun dalam menggunakannya. Karakteristik *GoogLeNet* menggunakan jaringan *Inception* lebih dari satu dan lebih luas, yang berfungsi untuk meningkatkan akurasi (Szegedy et al., 2015) [18]. Model jaringan *ResNet* merupakan model jaringan yang memanfaatkan efisiensi dari struktur *bottleneck* untuk mencapai kinerja yang maksimal, dimana model jaringan ini mudah di *optimize* dan dapat menaikkan akurasi dari peningkatan *depth* (He et al., 2016) [19].

Tabel 1. Karakteristik Model CNN pada Eksperimen

Model	Depth	Layers	Connections
<i>ShuffleNet</i>	50	172	187
<i>GoogLeNet</i>	22	144	170
<i>ResNet18</i>	18	71	78
<i>ResNet50</i>	50	177	192
<i>ResNet101</i>	101	347	379

Tahap awal yang dilakukan pada eksperimen adalah adalah merubah parameter pada masing-masing model jaringan yang disesuaikan dengan jumlah *dataset* citra, merubah *weight*, dan *bias* dimana penentuan parameter yang ideal akan berpengaruh terhadap kemampuan pelatihan jaringan. *Weight* bertugas untuk mengubah data *input* pada *hidden layer*, dan *bias* merupakan parameter yang digunakan untuk menyesuaikan *output* bersama dengan jumlah *weight*. Tahapan selanjutnya yaitu cek model jaringan dengan *deep learning network analyzer* untuk mengetahui apakah terdapat *error* pada jaringan. Pada tahap pelatihan, *setting* parameter pada masing-masing jaringan sama, dengan *learning rate* sebesar 0,0001 untuk mengendalikan perubahan pada *weight* dan *bias* selama proses pelatihan, *mini batch size* 38, dan *epoch* 100, sehingga maksimum iterasi pada masing-masing model jaringan sebanyak 1200. Komputasi dilakukan dengan menggunakan perangkat Intel Core i7-3520M CPU 2.90GHz RAM 8 GB, sehingga membutuhkan waktu kompilasi yang lebih lama jika dibandingkan dengan menggunakan *Graphics Processor Unit* (GPU). Perangkat lunak yang digunakan dalam eksperimen adalah Matlab versi 2020a dengan menggunakan *Deep Network Designer* dan *Pretrained Network* yang tersedia. Pada tahap pengujian data tes, digunakan sejumlah 90 data citra yang bukan merupakan data *training* dan validasi. Data tes kemudian di uji ke dalam masing-masing model jaringan CNN, hal tersebut dilakukan untuk menghitung nilai akurasi yang dihasilkan dari masing-masing jaringan.

## HASIL DAN PEMBAHASAN

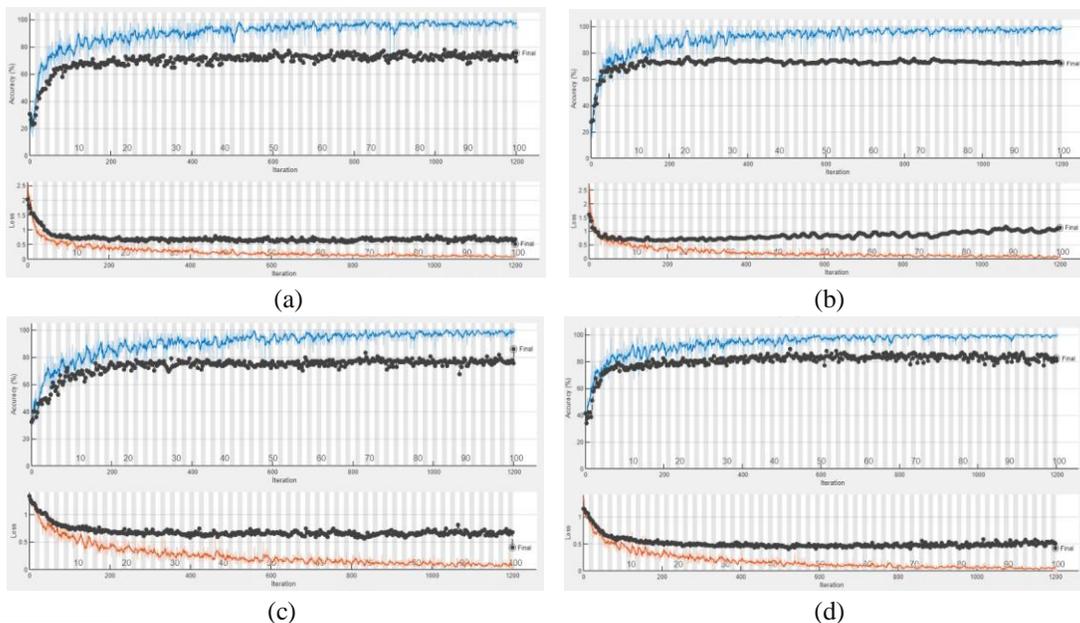
Dari hasil eksperimen dengan menggunakan *dataset* citra serta *learning* parameter yang sama pada 5 model jaringan, masing-masing model jaringan menghasilkan proses *learning* dan waktu komputasi yang berbeda-beda, yang ditampilkan pada **Gambar 3**. Model jaringan yang memiliki *gap* terkecil antara akurasi data *training* dan validasi yaitu *ResNet50* dimana menghasilkan nilai akurasi pelatihan sebesar 93,81%, akurasi validasi sebesar 82,46% dan akurasi data tes sebesar 95,56% . Sedangkan model jaringan yang memiliki *gap* terbesar antara akurasi data pelatihan dengan validasi adalah jaringan *GoogLeNet* yang menghasilkan akurasi pelatihan 90,24%, akurasi

validasi 71,95%, dan akurasi data tes 91,11%. **Tabel 2** menampilkan perbandingan hasil pelatihan dan waktu komputasi kelima model jaringan, terlihat bahwa model jaringan yang menghasilkan nilai akurasi pengujian adalah *ResNet50* dan *ResNet101* yaitu 95,56% yang diuji menggunakan 90 *dataset*. Waktu pelatihan jaringan tercepat adalah jaringan *ShuffleNet* dengan waktu 191 menit 33 detik, karena sifat dasar dari jaringan ini sendiri yang didesain untuk *small network*, sehingga proses komputasi cenderung ringan dijalankan pada perangkat dengan kemampuan rendah sekalipun. Pada model jaringan *ResNet101* membutuhkan waktu pelatihan yang cukup lama dibandingkan dengan jaringan lain, yaitu 1172 menit 39 detik, dengan waktu hampir 2 kali dari waktu yang pelatihan jaringan *ResNet50*. Model jaringan *ResNet101* memiliki rata-rata akurasi yang paling tinggi diantara keempat jaringan lainnya, karena jaringan ini memiliki 101 *layer* yang mampu melakukan lebih dari 1000 klasifikasi dengan jutaan citra.

Kelima jaringan pada eksperimen ini menghasilkan nilai rata-rata akurasi pelatihan diatas 90%, rata-rata akurasi validasi berkisar 75%-80%, dan rata-rata akurasi tes diatas 90%, sehingga dapat disimpulkan bahwa kelima model jaringan sangat ideal untuk mendeteksi cacat pada kemasan kaleng dan klasifikasi jenis cacat pada kaleng. Model jaringan yang paling ideal untuk *dataset* citra pada eksperimen ini adalah *ResNet101* dan *ResNet50* dengan nilai akurasi pengujian data tes 95,56%, tetapi model jaringan *ResNet101* memiliki kekurangan pada waktu pelatihan yang cenderung lebih lama. Hal tersebut juga dipengaruhi oleh kapasitas perangkat yang terbatas, jika komputasi dijalankan dengan GPU waktu pelatihan dapat menjadi lebih singkat. Pada eksperimen ini lebih ideal jika menggunakan model jaringan *ResNet50* dengan jumlah *dataset* yang terbatas, karena sudah menghasilkan akurasi pengujian yang cukup tinggi. Hasil pembelajaran dan validasi akan lebih maksimal jika *dataset* yang digunakan lebih banyak dari *dataset* yang digunakan pada eksperimen ini.

Tabel 2 Hasil Akurasi dan Waktu Pelatihan

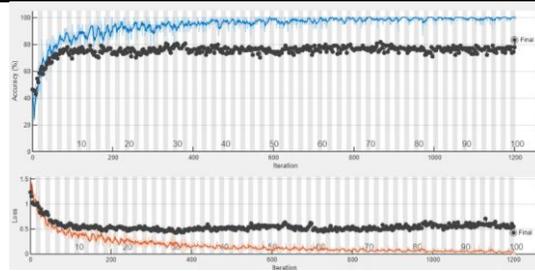
Model	Akurasi %			Waktu Pelatihan
	Pelatihan	Validasi	Tes	
<i>ShuffleNet</i>	90,31	75,44	90,00	191 menit 33 detik
<i>GoogLeNet</i>	90,24	71,95	91,11	335 menit 20 detik
<i>ResNet18</i>	90,34	85,96	92,22	278 menit 21 detik
<i>ResNet50</i>	93,81	82,46	95,56	675 menit 16 detik
<i>ResNet101</i>	94,04	83,33	95,56	1172 menit 39 detik



Deteksi dan Klasifikasi Cacat Kemasan Kaleng Menggunakan *Convolutional Neural Network* / Rindi Kusumawardani, Putu Dana Kusumaningsih

Peer reviewed under responsibility of Universitas Muhammadiyah Sidoarjo.

© 2020 Universitas Muhammadiyah Sidoarjo. All Right reserved. This is an open access article under the CC BY licence (<http://creativecommons.org/licenses/by/4.0/>)

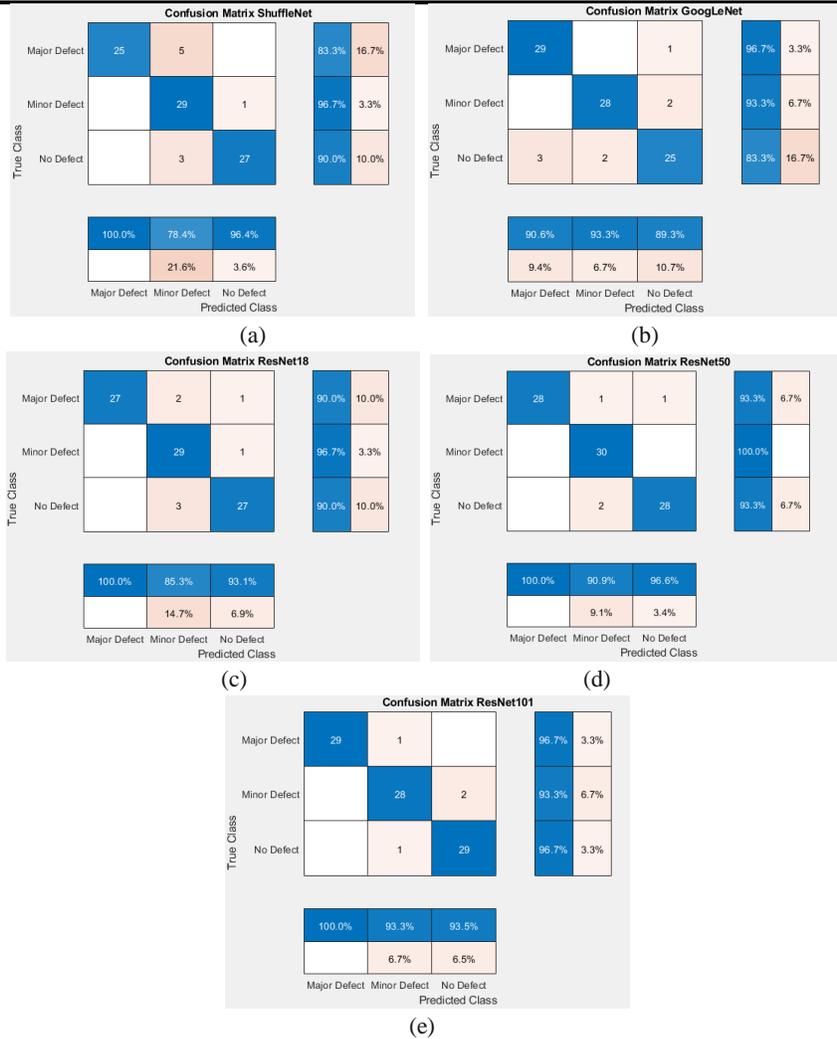


(e)

Gambar 3. Proses Pelatihan Jaringan

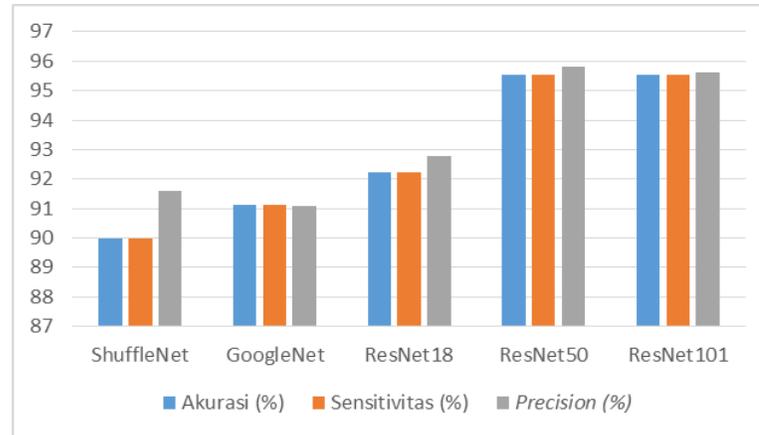
(a) *ShuffleNet*, (b) *GoogLeNet*, (c) *ResNet18*, (d) *ResNet50*, (e) *ResNet101*

Berdasarkan hasil pengujian pada 90 dataset dengan 30 dataset pada masing-masing kelas, dapat dibuat *confusion matrix* yang merupakan hasil prediksi data pengujian pada masing-masing kelas, seperti disajikan pada **Gambar 4**. Pada *confusion matrix* terlihat bahwa jaringan mampu memprediksi klasifikasi dengan baik, model jaringan *ShuffleNet* menghasilkan kesalahan klasifikasi terbanyak dan model jaringan yang menghasilkan kesalahan paling sedikit adalah *ResNet50* dan *ResNet101*. Hasil pengukuran akurasi, sensitivitas dan *precision* pada masing-masing model jaringan disajikan dalam bentuk grafik perbandingan pada **Gambar 5**, dimana dapat disimpulkan bahwa model jaringan *ResNet50* dan *ResNet101* memberikan akurasi, sensitivitas, dan *precision* yang terbaik, dengan nilai *precision* pada jaringan *ResNet50* lebih tinggi dibandingkan dengan model jaringan *ResNet101*.



Gambar 4. Confusion Matrix Model Jaringan

(a) ShuffleNet, (b) GoogLeNet, (c) ResNet18, (d) ResNet50, (e) ResNet101



Gambar 5. Perbandingan Akurasi, Sensitivitas dan Precision pada Setiap Model Jaringan

## SIMPULAN

Dari hasil pengujian dan analisa yang telah dilakukan, dapat disimpulkan bahwa algoritma CNN dapat membedakan jenis klasifikasi kerusakan pada kemasan kaleng, baik dengan menggunakan *dataset* citra untuk pengujian yang sudah disiapkan, maupun pengujian tiap citra. Hasil akurasi validasi dan tes pada kelima model jaringan memiliki akurasi pengujian diatas 90%, sehingga kelima model jaringan dapat dikatakan sangat ideal untuk mendeteksi cacat pada kemasan kaleng dan klasifikasi jenis cacat pada citra kemasan kaleng. Masing-masing jaringan memiliki karakteristik, kelebihan, serta kekurangan masing-masing. Pada eksperimen ini, model jaringan terbaik yang dapat melakukan deteksi dan klasifikasi dengan *dataset* citra kemasan kaleng adalah model jaringan *ResNet50* dan *ResNet101*. Namun model jaringan *ResNet101* membutuhkan waktu *training* yang cukup lama dibandingkan dengan model jaringan *ResNet50*, sehingga untuk eksperimen ini model jaringan yang paling ideal yaitu *ResNet50* dengan nilai akurasi 95,56%, sensitivitas 95,56%, dan *precision* 95,82%. Kedepannya penelitian ini akan dikembangkan untuk melakukan klasifikasi dengan menggunakan data di industri, dengan *dataset* yang lebih banyak agar proses pembelajaran semakin lebih baik. Selain itu diperlukan variasi parameter *epoch* serta *mini batch size* untuk menghasilkan perbandingan yang lebih optimal diantara masing-masing model jaringan.

## DAFTAR PUSTAKA

- [1] Baudet, N., Maire, J.C., and Pillet, M., 2012. The Visual Inspection of Product Surface. Food Quality and Preference.
- [2] Ramos, M., Valdes, A., and Garrigos, M.A., 2016. Packaging for Drinks. Reference Modul in Food Science: Analytical Chemistry, Nutrition & Food Science. University of Alicante, Spain.
- [3] Rahman, N., Saad, N., Abdullah, A., and Ahmad, N., 2019. A Review of Vision Based Defect Detection using Image Processing Techniques for Beverages Manufacturing Industry. Journal of Technology.
- [ ] Bratt, L., 2010. Fish Canning Handbook. Blackwell Publishing Ltd. United Kingdom.
- [5] Hajizadeh, S., Nunez, A., and Tax, D.M., 2016. Semi-Supervised Rail Defect Detection from Imbalanced Image Data. IFAC-Papers online, 49 (3), 78-83

Deteksi dan Klasifikasi Cacat Kemasan Kaleng Menggunakan *Convolutional Neural Network* / Rindi Kusumawardani, Putu Dana Kusumaningsih

Peer reviewed under responsibility of Universitas Muhammadiyah Sidoarjo.

© 2020 Universitas Muhammadiyah Sidoarjo. All Right reserved. This is an open access article under the CC BY licence (<http://creativecommons.org/licenses/by/4.0/>)

- 
- [6] Wang, J., Fu, P., and Gao, R.X., 2019. Machine Vision Intelligence for Product Defect Inspection Based on Deep Learning and Hough Transform, *Journal of Manufacturing System*, 51: 52-60.
- [7] Liang, Q., Zhu, W., Sun, W., Yu, Z., Wang, Y., and Zhang, D., 2019. In Line Inspection Solution for Codes on Complex Background for The Plastic Container Industry, *Journal of Measurement*, 148, 106965.
- [8] Perez, H., Joseph, H., Tah, M. and Mosavi, A., 2019. Deep Learning for Detecting Building Defects Using Convolutional Neural Network, *MDPI Journal*.
- [9] Panella, F., Boehm, J., Loo, Y., Kaushik, A., and Gonzales, D., 2018. Deep Learning and Image Processing for Automated Crack Detection and Defect Measurement in Underground Structures, *Journal of Remote Sensing and Spatial Information Sciences*, Volume: XLII-2.
- [10] Costa, A.Z., Hugo, E.H.F., and Fracarolli, J.A., 2020. Computer Vision Based Detection of External Defects on Tomatoes using Deep Learning, *Journal of Biosystem Engineering*, 190: 131-144.
- [11] Rokhana, R., Priambodo, J., Karlita, T., Sunarya, I.M.G., Yuniarto, E.M., Purnama, I.K.E., dan Purnomo, M.H., 2019. Convolutional Neural Network untuk Pendekteksian Patah Tulang Femur pada Citra Ultrasonik B-Mode, *JNTETI*, Volume 8, No.1.
- [12] LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P., 1998. Gradient-Based Learning Applied to Document Recognition, *Proceeding of the IEEE*, Vol.86, No.11, 2278-2324.
- [13] Krizhevsky, A., Sutskever, I., and Hinton, G.E., 2017. ImageNet Classification with Deep Convolutional Neural Network, *Commun. ACM*, Vol. 60, No.6, 84-90.
- [14] Simonyan, K., and Zisserman, A., 2014. Very Deep Convolutional Neural Network for Large-Scale Image Recognition, *ArXiv140091556Cs*.
- [15] Zhang, X., Zhou, X., Lin, M, and Sun, J., 2018. ShuffleNet: An Extremely Efficient Convolutional Neural Network for Mobile Devices, *CVF Conference on Computer Vision and Pattern Recognition*, IEEE.

- 
- [16] Rezende, E., Ruppert, G., Carvalho, T., Ramos, F., and Geus, P.D., 2017. Malicious Software Classification using Transfer Learning of ResNet-50 Deep Neural Network, Conference on Machine Learning & Applications, 16<sup>th</sup>.
- [17] Wang, J., May, Y., Zhang, I., Gao, R.X., and Wu, D., 2018. Deep Learning for Smart Manufacturing: Methods and Applications, Journal of Manufacturing System, 48: 144-16.
- [18] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A., 2015. Going Deeper with Convolutional, IEEE, 978-1-4673-6964-0/15.
- [19] He, K., Zhang, X., Ren, S., and Sun, J. Deep Residual Learning for Image Recognition. Conference on Computer Vision and Pattern Recognition, IEEE.