

SISTEM INSPEKSI VISUAL UNTUK MENDETEKSI CACAT PADA SEL BATERAI MENGUNAKAN FASTER R-CNN

VISUAL INSPECTION SYSTEM FOR DETECTING DEFECTS ON BATTERY CELLS USING FASTER R-CNN

Bernardus Ferri Sarbona¹, Anggunmeka Luhur Prasasti², Mas'ud Adhi Saputra³.

^{1,2,3} Universitas Telkom, Bandung

bernardusferri@student.telkomuniversity.ac.id¹, anggunmeka@telkomuniversity.ac.id²,
kangmasngud@telkomuniversity.ac.id³

Abstrak

Baterai *Lithium-Ion* banyak digunakan dalam banyak teknologi, dari teknologi yang sangat simple seperti senter sampai teknologi yang sudah sangat maju seperti kendaraan bertenaga listrik seperti *SLS AMG Coupe Electric Drive* yang merupakan sebuah *sport car* buatan *Mercedes-Benz* yang memiliki 4 *electric motors* yang dimana keempat motor ini yang masing masing ditenagai oleh 1 baterai. Kecacatan dalam baterai ini dapat berakibat fatal, dari berkurangnya energi yang ditampung dalam baterai, atau bahkan baterai dapat meledak. Oleh karena itu dibutuhkan sebuah *tools* yang dapat mendeteksi kecacatan pada baterai ini agar dapat dibedakan mana baterai yang bagus atau yang kurang bagus. Mendeteksi kecacatan tersebut, biasa dilakukan inspeksi visual kondisi fisik yang dapat dilakukan dengan gambar atau dengan melakukan menggunakan mata telanjang.

Sistem melakukan inspeksi visual dengan menggunakan deteksi objek dan *deep learning*. Sistem juga menggunakan algoritma *Faster R-CNN* sebagai sistem deteksi objek. Lalu gambar hasil deteksi objek tersebut akan diproses dan dikirimkan kepada komputer kecil untuk diproses lebih lanjut menggunakan *deep learning*. Sistem akan mengeluarkan output, apabila produk tidak memiliki kecacatan maka sistem akan mengeluarkan output berupa label cacat apa yang terdapat pada baterai tersebut. Hasil penelitian ini menunjukkan bahwa algoritma *Faster Region Convolutional Neural Network (Faster R-CNN)* mendapatkan hasil *training model* dengan *mean average precision (mAP)* sebesar 76,21%. Hasil ini didapatkan dengan melakukan beberapa pengujian dengan beberapa parameter yang akan dibandingkan hasilnya untuk menemukan parameter terbaik untuk digunakan pada model ini.

Kata Kunci: objek deteksi, inspeksi visual, faster R-CNN, sel baterai, baterai, lithium-ion pouch

Abstarct

Lithium-Ion batteries are widely used in many technologies, from very simple technology such as flashlights to very advanced technologies such as electric-powered vehicles such as the SLS AMG Coupe Electric Drive which is a sports car made by Mercedes-Benz which has 4 electric motors of which the fourth These motors are each powered by 1 battery. Defects in this battery can be fatal, from reduced energy stored in the battery, or even the battery may explode. Therefore, we need a tool that can detect defects in this battery so that it can be distinguished which batteries are good or not. To detect these defects, a visual inspection of the physical condition is usually carried out which can be done with pictures or by using the naked eye.

The system performs a visual inspection using object detection and deep learning. The system also uses the Faster R-CNN algorithm as an object detection system. Then the image of the object detection will be processed and sent to a small computer for further processing using deep learning. The system will issue an output, if the product does not have a defect, then the system will issue an output in the form of a label of what defects are contained in the battery. The result of this research is that the Faster Region Convolutional Neural Network (Faster R-CNN) algorithm obtains training model results with a mean average precision (mAP) of 76.21%. These results were obtained by conducting several tests with several parameters to compare the results to find the best parameters to use in this model

Keywords: detection object, visual inspection, faster R-CNN, battery cell, lithium-ion battery pouch

1. Pendahuluan

Perkembangan teknologi saat ini telah menimbulkan berbagai minat dalam beberapa aspek dalam bidang teknologi, khususnya pada interaksi manusia dengan komputer. *Computer Vision* merupakan pengembangan teknologi komputer terbaru. *Computer Vision* memungkinkan sebuah komputer untuk mengolah data visual seperti gambar atau video yang nantinya akan diolah menjadi sebuah nilai biner ataupun data tertentu. *Computer Vision* juga bekerja bersama dengan *Deep Learning*. Dengan *Deep Learning* komputer dapat mengolah nilai biner ataupun data tertentu yang dihasilkan oleh *Computer Vision*. Inputan ini dapat berupa sebuah gambar.

Baterai adalah salah satu bagian terpenting pada hidup. Banyak dari teknologi yang digunakan pada kehidupan sehari-hari menggunakan baterai sebagai sumber daya dari teknologi tersebut. Baterai sangat mudah digunakan juga sangat praktis untuk digunakan karena ukurannya yang relatif kecil. Salah satu tipe baterai yang sering digunakan pada teknologi sehari-hari adalah baterai *lithium-ion pouch*. Baterai *lithium-ion* sering ditemukan pada *handphone*, laptop dan banyak teknologi lainnya. Baterai ini sering digunakan karena ukurannya yang kecil dan tipis juga karena baterai ini dapat menampung banyak daya.

Baterai *lithium-ion pouch* memiliki beberapa kelemahan fatal yang diantaranya adalah kurangnya toleransi terhadap suhu yang sangat panas, isi ulang baterai yang berlebihan dapat memperpendek usia baterai dan baterai rentan meledak. Sebuah buletin melaporkan 2 kasus baterai dari sebuah telepon seluler mengalami korsleting dan menyebabkan kebakaran. Dilaporkan juga 2 peneliti terluka dikarenakan ledakan baterai *lithium-ion pouch* pada 11 November 2004 Shanghai. Serta berbagai kasus yang dilaporkan sebelumnya [1]

Penelitian ini membuat sebuah sistem yang dapat digunakan untuk melakukan inspeksi pada baterai setelah diproduksi. Sistem akan mendeteksi kecacatan pada baterai. Hal ini dilakukan agar *quality control* pada baterai yang telah diproduksi menjadi lebih efektif serta lebih konsisten. Keamanan juga merupakan masalah besar pada produksi baterai. Sistem ini akan meningkatkan keamanan inspektor karena inspektor tidak perlu mendekati baterai untuk melakukan *quality control*.

Pada penelitian sebelumnya, CNN telah digunakan untuk mengenali huruf-huruf Arab yang akan ditranslasi ke bahasa Indonesia [2], mendeteksi kecepatan kendaraan menggunakan webcam [3] dan melakukan klasifikasi pada ekspresi wajah seseorang [4]. Pada penelitian Tugas Akhir ini CNN akan digunakan untuk melakukan deteksi kecacatan pada baterai secara fisik. Baterai yang akan dideteksi adalah baterai berbentuk pouch.

2. Dasar Teori

2.1 Baterai Lithium-Ion Pouch

Baterai *lithium ion* merupakan salah satu jenis baterai yang paling populer untuk peralatan elektronik *portable* seperti *handphone*, laptop dan masih banyak lagi karena memiliki kepadatan energi terbaik, mengalami kehilangan daya yang lambat pada saat digunakan dan ramah lingkungan. Akan tetapi baterai *lithium-ion* juga memiliki banyak kelemahan juga, diantaranya adalah biaya, keamanan dan daya tahan baterai [5]. Beberapa penyebabnya adalah bahan pelindung baterai yang tipis, sehingga panas dari baterai dapat membakar lapisan pelindung tersebut dan meledak

2.2 Machine Learning

Machine Learning merupakan salah satu teknologi yang paling banyak digunakan pada kehidupan sehari-hari. *Machine Learning* merupakan cabang dari *Artificial Intelligence*. *Machine learning* memiliki kemampuan, untuk mengakses berbagai data tanpa perintah dari pengguna. *Machine learning* mampu melakukan ini dengan mempelajari algoritma dan model statistik yang ada. *Machine learning* bertujuan untuk mendesain algoritma yang efisien dan memiliki prediksi akurat yang tinggi [6].

Machine learning dapat dibagi menjadi beberapa bagian lagi menjadi banyak cabang, salah satunya adalah *deep learning*. *Deep Learning* merupakan bagian dari kecerdasan buatan dan *machine learning*. *Deep learning* memungkinkan model komputasi yang terdiri dari beberapa lapisan pemrosesan untuk mempelajari representasi data dengan berbagai tingkat abstraksi [7]

Machine learning telah berkembang beberapa tahun terakhir ini. *Machine learning* telah menjadi alat yang umum pada setiap tugas yang membutuhkan ekstraksi informasi dari kumpulan data besar. *Machine learning* dapat membantu pekerjaan dan masalah yang dihadapi manusia dengan lebih efisien dan cepat. Proses pelatihan diperlukan oleh mesin ini untuk mencapai tujuan tersebut. Proses pelatihan tersebut menggunakan sekumpulan data yang disebut dengan data latih.

2.3 Convolutional Neural Network (CNN)

Convolutional Neural Networks adalah salah satu algoritma *Deep Learning* yang dibuat untuk memproses data dua dimensi. CNN memanfaatkan *feature learning* untuk mengekstrak suatu masukan gambar menjadi sebuah *feature map* yang berbentuk angka-angka dalam *array*. CNN terdiri dari 3 lapisan besar yang diantaranya adalah lapisan konvolusi, lapisan *pooling* dan lapisan *fully connected* [8].

Lapisan konvolusi merupakan lapisan pertama yang mendasari struktur dari CNN. Layer ini akan melakukan proses konvolusi dengan matriks kernel atau biasa disebut dengan matriks *filte*, digunakan untuk mengekstraksi fitur-fitur dari citra yang diinputkan, beberapa contoh nilai yang diambil adalah *edge detection* dan *corner detection* [6]. Lapisan *pooling* merupakan lapisan kedua pada CNN. Nilai yang telah didapatkan dari lapisan konvolusi akan digunakan untuk melakukan sebuah proses yang bernama *downsampling*. *Downsampling* adalah proses pengecilan area pada *feature map* untuk mempercepat proses komputasi dan mengurangi resiko terjadinya *overfitting*. Lapisan *fully connected* adalah lapisan yang berupa *array multidimensional*. Lapisan ini akan mengolah data yang telah diolah pada lapisan *pooling* agar data dapat diklasifikasi.

2.4 Faster Regional Convolutional Neural Network (Faster R-CNN)

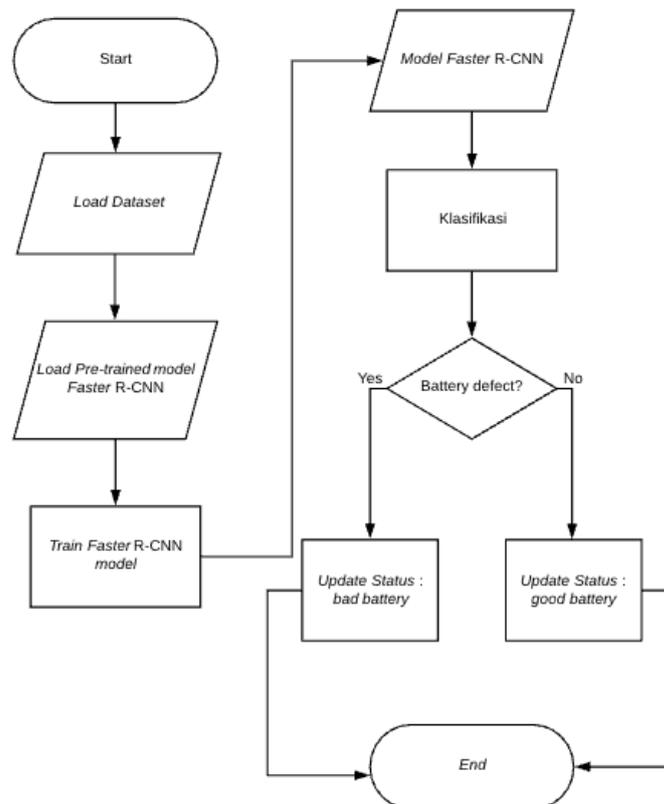
Faster Regional Convolutional Neural Network (Faster R-CNN) adalah sebuah algoritma *deep learning* yang banyak digunakan dalam *object detection*. *Faster R-CNN* menggunakan kedua versi algoritma sebelumnya yaitu R-CNN dan *Fast R-CNN* dengan *Regional Proposal Network*. *Faster R-CNN* memiliki waktu mendeteksi yang lebih cepat serta lebih akurat dibandingkan 2 versi sebelumnya [10].

R-CNN menggunakan algoritma *Region of Interest (ROI)* untuk memperkuat akurasi sistem dalam mendeteksi objek [11]. *Fast R-CNN* merupakan pengembangan dari model R-CNN. *Fast R-CNN* mampu melakukan komputasi 25 kali lebih cepat dibandingkan dengan R-CNN. Hal ini dikarenakan perbedaan letak dari *region of interest* [9].

Faster R-CNN menggunakan *Fast R-CNN* sebagai *detector* dan RPN sebagai *region proposer*. RPN merupakan sebuah *neural network* yang menggantikan peran *selective search*, RPN akan menghasilkan beberapa *bounding box*, disetiap *box* akan memiliki 2 skor probabilitas, apakah pada lokasi tersebut terdeteksi objek atau tidak. *Faster R-CNN* juga dibantu oleh beberapa library salah satu contohnya adalah *Tensorflow* [13].

3. Perancangan Sistem

Secara umum sistem inspeksi visual untuk mendeteksi kecacatan pada baterai *lithium-ion pouch* dirancang untuk mengambil suatu gambar baterai *lithium-ion pouch*. Pada penelitian ini terdapat 2 proses utama, yaitu proses pelatihan dan proses uji coba. Gambaran umum sistem dapat dilihat dari *flowchart* dibawah ini.



Gambar 1. Flowchart Sistem Inspeksi Visual untuk Mendeteksi Kecacatan pada Baterai

Pada gambar diatas dijelaskan proses dari keseluruhan sistem mulai dari awal pengambilan citra kemudian citra wajah tersebut akan di-load dan dilanjutkan dengan proses pelatihan model dengan menggunakan

dataset yang telah di-load. Setelah model dilatih maka akan dilakukan proses klasifikasi untuk menguji model dengan menggunakan dataset yang tidak digunakan dalam proses pelatihan. Sistem akan mengklasifikasikan data ini dengan memberikan label pada gambar baterai kecacatan apa yang terdapat pada baterai tersebut.

3.1 Pengujian Sistem

Pengujian sistem dilakukan untuk mencari nilai partisi data latih dan data uji, *learning rate* dan *step* yang mendapatkan performansi yang paling bagus. Untuk partisi data latih dan data uji digunakan perbandingan 50:50, 60:40, 70:30, 80:20 dan 90:10. Untuk *learning rate* digunakan nilai *learning rate* 0,003; 0,0003; 0,00003 dan 0,000003. Untuk *step* digunakan nilai 1000, 2000, 3000 dan 4000. Seluruh hasil pengujian dapat dilihat dari tabel dibawah ini. Dataset yang digunakan berjumlah 1007 dengan resolusi 100x100 piksel yang dibagi menjadi 3 kelas yaitu kelas cacat *overcharged*, cacat *welding* dan normal. Setiap pengujian akan dilakukan sebanyak 4 kali dan nilai terbaik yang didapat pada pengujian akan digunakan pada pengujian selanjutnya. Pengujian partisi data dengan nilai rasio yang sudah disebut sebelumnya dapat dilihat dari tabel dibawah ini.

Tabel 1. Hasil Pengujian Partisi Data 50:50

Pengujian Ke-	Data Train (%)	Data Test (%)	mAP
1	50	50	49,20%
2	50	50	48,70%
3	50	50	52,55%
4	50	50	48,60%

Tabel 2. Hasil Pengujian Partisi Data 60:40

Pengujian Ke-	Data Train (%)	Data Test (%)	mAP
1	60	40	52,11%
2	60	40	57,77%
3	60	40	52,90%
4	60	40	56,11%

Tabel 3. Hasil Pengujian Partisi Data 70:30

Pengujian Ke-	Data Train (%)	Data Test (%)	mAP
1	70	30	51,20%
2	70	30	54,22%
3	70	30	54,12%
4	70	30	53,70%

Tabel 4. Hasil Pengujian Partisi Data 80:20

Pengujian Ke-	Data <i>Train</i> (%)	Data <i>Test</i> (%)	mAP
1	80	20	62,55%
2	80	20	61,20%
3	80	20	63,55%
4	80	20	62,40%

Tabel 5. Hasil Pengujian Partisi Data 90:10

Pengujian Ke-	Data <i>Train</i> (%)	Data <i>Test</i> (%)	mAP
1	90	10	68,70%
2	90	10	66,00%
3	90	10	67,80%
4	90	10	69,88%

Pengujian ini memberikan mAP terbaik sebesar 69,88% dengan menggunakan partisi data latih dan data uji dengan rasio 90:10 pada pengujian ke-4. Pengujian selanjutnya akan menggunakan partisi data dengan rasio 90:10. Hasil pengujian *learning rate* dapat dilihat pada tabel dibawah.

Tabel 6. Hasil Pengujian *Learning Rate* 0,003

Pengujian ke-	<i>Learning Rate</i>	mAP
1	0,003	53,20%
2	0,003	53,44%
3	0,003	50,60%
4	0,003	54,50%

Tabel 7. Hasil Pengujian *Learning Rate* 0,0003

Pengujian ke-	<i>Learning Rate</i>	mAP
1	0,0003	57,77%
2	0,0003	61,40%
3	0,0003	58,00%
4	0,0003	57,77%

Tabel 8. Hasil Pengujian *Learning Rate* 0,00003

Pengujian ke-	<i>Learning Rate</i>	mAP
1	0,00003	40,00%
2	0,00003	38,80%
3	0,00003	35,90%
4	0,00003	35,60%

Tabel 9. Hasil Pengujian *Learning Rate* 0,000003

Pengujian ke-	<i>Learning Rate</i>	mAP
1	0,000003	7,10%
2	0,000003	7,20%
3	0,000003	8,00%
4	0,000003	8,40%

Pengujian menunjukkan nilai mAP terbaik yang didapatkan adalah 61,40% dengan menggunakan nilai *learning rate* 0,0003 yang didapatkan pada pengujian ke-2. Pengujian selanjutnya akan menggunakan nilai *learning rate* 0,0003. Hasil dari pengujian *step* dapat dilihat pada tabel dibawah ini.

Tabel 10. Hasil Pengujian *Step* 1000

Pengujian ke-	<i>Step</i>	mAP
1	1000	54,80%
2	1000	54,69%
3	1000	54,31%
4	1000	55,21%

Tabel 11. Hasil Pengujian *Step* 2000

Pengujian ke-	<i>Step</i>	mAP
1	2000	70,00%
2	2000	62,26%
3	2000	65,20%
4	2000	73,33%

Tabel 12. Hasil Pengujian *Step* 3000

Pengujian ke-	<i>Step</i>	mAP
1	3000	73,40%
2	3000	76,21%
3	3000	74,55%
4	3000	75,66%

Tabel 11. Hasil Pengujian *Step* 4000

Pengujian ke-	<i>Step</i>	mAP
1	4000	70,00%
2	4000	73,90%
3	4000	72,88%
4	4000	74,70%

Berdasarkan hasil akurasi dari seluruh pengujian didapatkan hasil akurasi tertinggi yaitu 76,21%. Pada pengujian ini dapat dilihat bahwa partisi data, nilai *learning rate* dan jumlah *step* pada proses pelatihan dapat mempengaruhi tingkat keakuratan pada klasifikasi terbukti dari setiap pengujiannya jumlah mAP yang diberikan berbeda-beda pada setiap pengujiannya.

4. Simpulan dan Saran

Kesimpulan yang dapat diambil dari pembahasan yang telah diuraikan adalah:

- Metode klasifikasi *Faster R-CNN* cocok untuk mengidentifikasi kerusakan pada baterai, akan tetapi model dari hasil penelitian ini masih kurang memaksimalkan kinerja dari metode *Faster R-CNN*. Hal ini dikarenakan kurangnya variasi dataset, kurang maksimalnya proses *preprocessing* juga kurang banyaknya parameter parameter yang dapat digunakan untuk mengoptimalkan kinerja dari metode *Faster R-CNN*.
- Pada hasil pengujian performansi sistem klasifikasi parameter mAP. Memberikan hasil terbaik dengan menggunakan partisi data *train* sebesar 90% dan data *test* sebesar 10% menghasilkan nilai *mean average precision* sebesar 74.31%.

Saran yang dapat diberikan untuk penelitian lebih lanjut adalah sebagai berikut:

- Mengembangkan data set pelatihan, agar memiliki lebih banyak varian baterai. Memiliki perbandingan label yang seimbang juga mendapatkan validasi dari pakar bidang terkait
- Data set sebaiknya di proses terlebih dahulu sebelum memasuki tahap prapemrosesan
- Pengambilan data set disarankan menggunakan *background* foto yang seragam untuk mempermudah proses ekstraksi ciri dari gambar

REFERENSI

- [1] Q. Wang, J. Sun and G. Chu, "Lithium Ion Battery Fire and Explosion," *Journal of hazardous materials*, vol. 344, pp. 734-741, 2005.
- [2] S. S. Rosyda, B. Irawan and A. L. Prasasti, "Design of Arabic Recognition Application using Convolutional Neural Network," *Journal of Engineering and Applied Sciences*, 2019.
- [3] N. H. Tsani, B. Dirgantoro and A. L. Prasasti, "Impelemntasi Deteksi Kecepatan Kendaraan Menggunakan Kamera Webcam dengan Metode Frame Difference," in *e-Proceeding of Engineering*, 2017.
- [4] F. A. Isman, A. L. Prasasti and R. A. Nugrahaeni, "Expression Classification For User Experience Testing Using Convolutional Neural Network," *International Conference on Artificial Intelligence*, 2021.
- [5] L. Lu, "A review on the key issues for lithium-ion battery management in electric vehicles," *Journal of power sources*, vol. 226, pp. 272-288, 2013.

- [6] M. Mohri, A. Rostamizadeh and A. Talwalkar, *Foundations of machine learning*, MIT press, 2018.
- [7] Y. LeCun, Y. Bengio and G. Hinton., "Deep learning," in *Deep learning*, nature 521, no. 7553, 2015, pp. 436-444..
- [8] F. A. Isman, A. L. Prasasti and R. A. Nugraheni, "Expression Classification For User Experience Testing Using Convolutional Nural Network," in *International Conference on Artificial Intelligence and Mechatronics Systems (AIMS)*, Bandung, 2021.
- [9] Zhao, Zhong-Qiu and e. al, "Object detection with deep learning: A review," in *IEEE transactions on neural networks and learning systems*, 2019.
- [10] M. Z. Alom, "A state-of-the-art survey on deep learning theory and architectures," in *Electronics*, 2019, 2019.
- [11] S. Ren, ""Faster r-cnn: Towards real-time object detection with region proposal networks," in *Advances in neural information processing systems*, 2015.
- [12] R. Girshick, "Fast r-cnn.," in *Proceedings of the IEEE international conference on computer vision*, 2015.
- [13] M. abadi, "TensorFlow: learning functions at scale," in *Proceedings of the 21st ACM SIGPLAN International Conference on Functional Programming*, 2016.