

SISTEM INSPEKSI VISUAL KECACATAN PADA SEL BATERAI LITHIUM MENGUNAKAN CNN 2 DIMENSI

VISUAL INSPECTION SYSTEM OF DEFECTS ON LITHIUM BATTERY CELL USING 2 DIMENSION CNN

Fauzan Naufal Ihsan Dhuha¹, Anggunmeka Luhur Prasasti², Mas'ud Adhi Saputra³

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

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

Abstrak

Perkembangan teknologi, khususnya di bidang industri, telah membantu para pelaku industri dalam meningkatkan efisiensi produksi suatu produk. Banyak produsen-produk di bidang industri membutuhkan sumber tenaga yang dapat dibawa kemana-mana. Baterai dapat dijadikan sebuah solusi untuk menyimpan daya listrik yang dibutuhkan oleh alat-alat elektronik yang digunakan sehari-hari.

Baterai, khususnya baterai berjenis lithium, saat ini telah banyak digunakan pada berbagai aspek seperti dalam transportasi, layanan umum, sampai pada alat-alat elektronik konsumen. Dalam pembuatan baterai, seringkali terdapat kecacatan produk pada proses produksi. Hal ini dikarenakan tingkat kelalaian mesin ataupun manusia. Biasanya, untuk mengecek kecacatan produk, dibutuhkan orang yang sangat ahli dalam inspeksi visual pada produk. Tetapi, hal ini memiliki kekurangan seperti, tingkat akurasi dan keamanan yang rendah, kurang efisien dalam mengidentifikasi kecacatan, dan perbedaan persepsi antara inspektur dan pekerja lain. Oleh karena itu, penulis mengembangkan suatu metode identifikasi untuk mendeteksi produk-produk yang cacat menggunakan *Deep Learning*.

Hasil dari penelitian ini menunjukkan bahwa pada saat proses training, performansi model CNN menunjukkan peningkatan akurasi tetapi pada nilai akurasi keseluruhan model menghasilkan akurasi yang sangat rendah. Akurasi tertinggi adalah pada partisi data 70:30 dan learning rate 0.0001 sebesar 39%. Tetapi, hasil akurasi training tidak menentukan seberapa tepat sistem dalam mendeteksi suatu objek apakah rusak atau tidak.

Kata Kunci : Inspeksi Visual, Baterai Lithium, Deep Learning, CNN 2 dimensi

Abstract

Technological developments, especially in the industrial sector, have helped industry players in increasing the production efficiency of a product. Many manufacturers in the industrial sector need a power source that can be carried everywhere. Batteries can be used as a solution to store the electrical power needed by electronic devices that are used daily.

Batteries, especially lithium batteries, are currently widely used in various aspects, such as in transportation, public services, to consumer electronics. In the manufacture of batteries, there are often product defects in the production process. This is due to the level of negligence of machines or humans. Usually, to check for product defects, it takes a person who is very skilled in visual inspection of the product. However, this has drawbacks such as a low level of accuracy and safety, less efficiency in identifying defects, and differences in perception between inspectors and other workers. Therefore, the authors develop an identification method to detect defective products using Computer Vision and Deep Learning.

The results of this study indicate that during the training process, the performance of the CNN model shows an increase in accuracy, but the overall accuracy value of the model produces very low accuracy. The highest accuracy is on the 70:30 data partition and the learning rate of 0.0001 is 39%. However, the results of the training accuracy do not determine how precise the system is in detecting an object whether it is damaged or not.

Keywords: *Visual Inspection, Battery, Deep Learning, 2-Dimensional CNN.*

1. Pendahuluan

Saat ini, banyak sekali perangkat yang menggunakan baterai sebagai sumber tenaga utama. selain ringan dan mudah dibawa kemana-mana, baterai diklaim ramah lingkungan sehingga banyak sekali yang menggunakan baterai. Baterai memiliki beberapa jenis, salah satunya baterai lithium yang sudah mulai sering kita jumpai di pasaran. Terdapat kelebihan dan kekurangan dalam penggunaan lithium ion [1], seperti ramah lingkungan dan dapat bertahan lebih lama dari baterai jenis lain. Tetapi, terdapat masalah yang dihadapi oleh produsen baterai lithium, yaitu kondisi sel baterai yang seringkali sulit untuk diidentifikasi kecacatannya. Karenanya, Terjadi beberapa masalah khususnya pada para pengguna *smartphone*. pada tahun 2016, salah satu merek *smartphone* terkemuka meluncurkan model *smartphone* terbaru mereka yang diberi nama *note 7*. selang beberapa bulan setelah peluncuran, muncul beberapa masalah yang dihadapi para pengguna *smartphone* ini, yaitu baterai *smartphone* mereka tiba-tiba terasa panas dan tiba-tiba meledak. [2] Karena masalah ini, maka diperlukan sebuah sistem untuk inspeksi visual otomatis yang dapat meringankan pekerjaan *inspector*, meningkatkan keamanan bagi para karyawan dan pekerja, serta memastikan produk yang dikeluarkan lebih konsisten.

Pada penelitian sebelumnya, Metode CNN digunakan untuk mengidentifikasi wajah seseorang [3] dan mengenali huruf-huruf arab yang selanjutnya ditranslasi ke Bahasa Indonesia [4]. Pada penelitian Tugas Akhir ini, Metode CNN akan digunakan untuk mengidentifikasi kerusakan pada baterai secara fisik. Tentunya, baterai yang diidentifikasi hanya berbentuk *pouch*. Sistem ini akan diimplementasikan di desktop dan hasil keluaran dari sistem ini berupa data klasifikasi kerusakan baterai yang dapat bermanfaat untuk mengidentifikasi kerusakan baterai pada pabrik.

2. Dasar Teori

2.1. Inspeksi Visual

Inspeksi Visual adalah suatu metode yang digunakan untuk pengendalian kualitas, analisis data, dan lain sebagainya. Biasanya, metode ini diterapkan pada lingkungan proses-proses pada industri. Inspeksi visual dilakukan untuk menghasilkan suatu produk yang konsisten dan memiliki kualitas yang bagus.

2.2. Baterai Lithium Polymer Pouch

Baterai Lithium Polimer atau biasa disebut dengan LiPO adalah Baterai lithium-ion yang berbahan dasar polimer elektrolit berbentuk gel. Perbedaan mendasar dengan baterai lithium ion biasa adalah dari bentuk fisik dan bahan pembuatannya. Bentuk fisik dari baterai LiPo berbentuk kotak atau *pouch* [5]. Penggunaan baterai ini biasanya digunakan pada alat-alat yang memiliki kebutuhan tenaga listrik yang tinggi seperti baterai *smartphone*, mainan *remote control*, dan lain sebagainya.

2.3. Pengolahan Gambar (Image Processing)

Image Processing atau dalam Bahasa Indonesia disebut dengan pemrosesan citra adalah suatu metode dalam *Machine Learning* yang berfungsi untuk memproses suatu citra gambar menjadi data-data yang dapat diolah oleh *Machine Learning*. [6] Metode ini dapat membantu manusia dalam pengenalan objek dan membuat pekerjaan menjadi lebih efisien. Pemrosesan citra biasanya digunakan pada sistem kamera digital.

Image Processing membantu manusia dalam mengidentifikasi objek sehingga membuat pekerjaan manusia menjadi lebih cepat dan efisien. Beberapa algoritma yang dipakai untuk mengklasifikasi gambar seperti *Naïve-Bayes*, *Support Vector Machine*, dan *Neural Network*, tetapi yang seringkali digunakan adalah *Neural Network*.

2.4. Kecerdasan Buatan (Artificial Intelligence)

Artificial Intelligence atau Kecerdasan buatan adalah suatu sistem yang memiliki kecerdasan layaknya manusia. Kecerdasan Buatan terdiri dari beberapa set instruksi yang disebut dengan Agen. Meskipun memiliki kemiripan dengan program, namun tujuan utama dari Kecerdasan Buatan yaitu membuat program yang dapat memprogram

sendiri. Secara mendasar, Kecerdasan Buatan terbagi menjadi 2 konsep, yaitu Kecerdasan Buatan Konvensional dan Kecerdasan Buatan Komputasional (*Computational Intelligence / CI*) [7]. Kecerdasan Konvensional saat ini dikenal dengan sebutan Pembelajaran Mesin atau *Machine Learning*.

2.5. Machine Learning

Machine Learning atau Pembelajaran Mesin adalah suatu cabang ilmu dari kecerdasan buatan yang memungkinkan suatu mesin atau sistem untuk belajar. [8] Menurut Arthur Samuel, seorang pionir kecerdasan buatan mendefinisikan machine learning sebagai "suatu ilmu yang memberikan komputer kemampuan untuk belajar tanpa diprogram secara eksplisit".

2.6. Deep Learning

Deep Learning merupakan proses pembelajaran mesin dengan cara kerja seperti jaringan syaraf otak manusia. [6] *Deep Learning* berfungsi untuk membuat prediksi sesuai dengan input yang masuk ke dalam sistem. Cara kerja *Deep Learning* mirip sekali dengan cara kerja otak manusia. Terdapat *hidden layer* yang berfungsi seperti hubungan antar syaraf otak. Lapisan ini berguna untuk pembelajaran pada mesin. *Deep learning* memiliki dua jenis algoritma seperti algoritma ANN (Artificial Neural Network) dan algoritma DNN (Deep Neural Network). *Deep learning* dapat diimplementasikan pada beberapa bidang, contohnya pada kamera pengawas lalu lintas yang mendeteksi plat nomor kendaraan yang kemudian data tersebut dicocokkan untuk membuat surat tilang kendaraan elektronik.

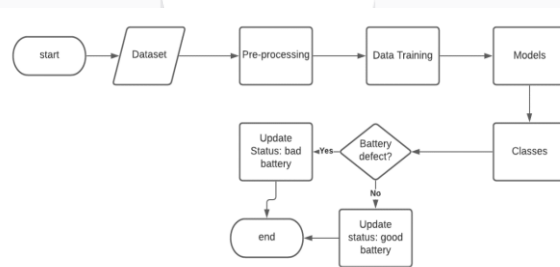
2.7. Convolutional Neural Network

CNN atau *Convolutional Neural Network* adalah suatu metode pengembangan dari *Multilayer Perception* (MLP) yang dibuat untuk memproses data dua dimensi [7]. Metode ini termasuk ke dalam *Deep Neural Network*. CNN berfungsi untuk memproses citra gambar dan membuat klasifikasinya berdasarkan persamaan [9]. Contoh dari pengimplementasian CNN yaitu pada sistem pengenalan wajah, pengenalan objek dan lain sebagainya. Untuk metode CNN dibagi menjadi 3 metode, yaitu 1 dimensional CNN, 2 dimensional CNN, dan 3 dimensional CNN. Untuk penelitian ini hanya menggunakan 2D CNN. [3] [4] [10]

3. Perancangan Sistem

3.1. Gambaran Umum Sistem

Gambaran umum sistem dapat dilihat pada gambar berikut ini.



Gambar 1. Flowchart sistem deteksi kerusakan baterai

Adapun penjelasan dari gambar diatas dapat dijelaskan sebagai berikut.

1. Dataset gambar akan melalui prapemrosesan untuk persiapan *training* gambar.
2. Setelah proses tersebut, data gambar akan ditraining dengan CNN.
3. Hasil dari *training* akan menghasilkan model CNN yang digunakan untuk klasifikasi baterai.
4. Baterai akan diklasifikasi dengan model CNN dan menghasilkan status baterai rusak atau tidak.

3.2. Dataset

Dataset gambar yang digunakan dalam penelitian ini adalah hasil pengumpulan data yang diperoleh dari *learning factory* yang berada di daerah dago, bandung. Pengambilan data dilakukan dengan cara pengambilan

gambar menggunakan kamera DSLR dan kamera *smartphone*. Jumlah data yang diperoleh 1191 gambar dengan resolusi 3000 x 4000 px berwarna. Label gambar diurutkan ke dalam 4 kategori, cacat welding, cacat kembang, cacat bocor, dan normal. Untuk lebih jelasnya dapat dilihat pada tabel berikut.

Tabel 1. Dataset gambar

| Kelas | Nama | Jumlah gambar |
|------------|---------------|---------------|
| 0 | cacat_bocor | 238 |
| 1 | cacat_kembang | 571 |
| 2 | cacat_welding | 295 |
| 3 | normal | 141 |
| Total Data | | 1191 |

3.3. Perancangan Sistem

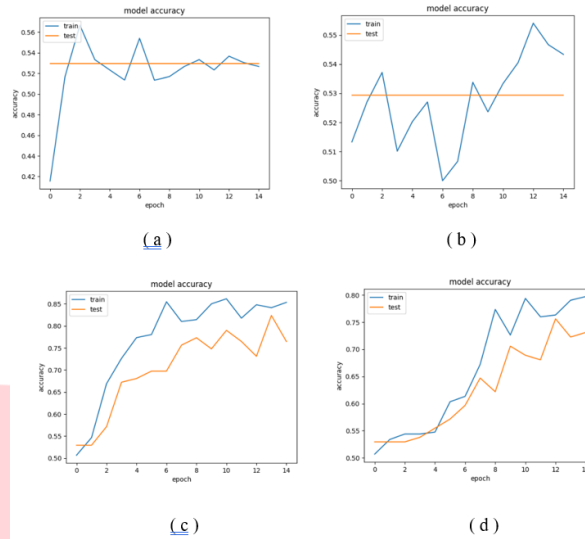
Proses perancangan sistem dimulai dengan menentukan gambar masukan, yaitu penentuan kategori kerusakan yang akan diklasifikasi. Selanjutnya melakukan prapemrosesan untuk menyiapkan data gambar yang akan diproses dan diklasifikasi. Selanjutnya, data gambar akan melalui proses klasifikasi menggunakan metode CNN dan hasil dari proses ini menghasilkan model klasifikasi kerusakan baterai yang dapat digunakan untuk mengidentifikasi kerusakan baterai.

4. Hasil Pengujian dan Analisis

Pengujian pada penelitian tugas akhir ini menggunakan partisi data dan learning rate sebagai parameter pengujian. Untuk learning rate menggunakan 0.1, 0.01, 0.001, dan 0.0001. sedangkan untuk partisi data menggunakan rasio 80:20, 70:30, dan 60:40.

Hasil dari pengujian ini adalah sebagai berikut.

1. Hasil akurasi tertinggi pada partisi data 80:20 adalah sebesar 38% dengan learning rate 0.0001. Grafik performansi dan tabel classification report dari model klasifikasi ini dapat dilihat pada gambar 2 dan tabel 2 dibawah ini.



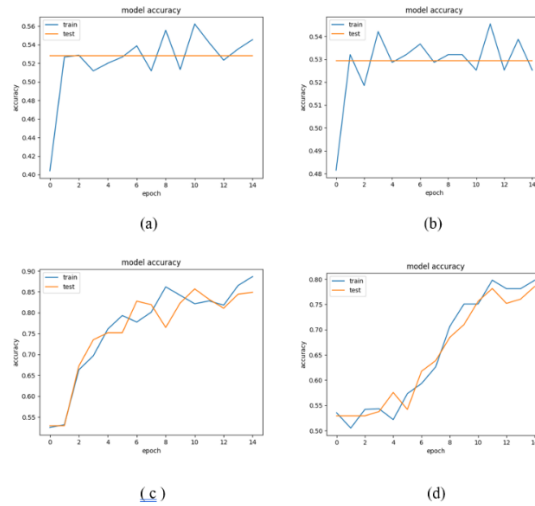
Gambar 2. Grafik performansi pada partisi data 80:20

Learning rate (a) 0.1 (b) 0.01 (c) 0.001 (d) 0.0001

Tabel 2. Classification report dengan learning rate 0.0001 (80:20)

| id | Precision | Recall | F1-Score |
|----------|-----------|--------|----------|
| 0 | 0.23 | 0.27 | 0.25 |
| 2 | 0.23 | 0.20 | 0.21 |
| 3 | 0.51 | 0.52 | 0.51 |
| Accuracy | | | 0.38 |

- Hasil akurasi tertinggi pada partisi data 70:30 adalah sebesar 39% dengan learning rate 0.0001. Grafik performansi dan tabel classification report dari model klasifikasi ini dapat dilihat pada gambar 3 dan tabel 3 berikut.

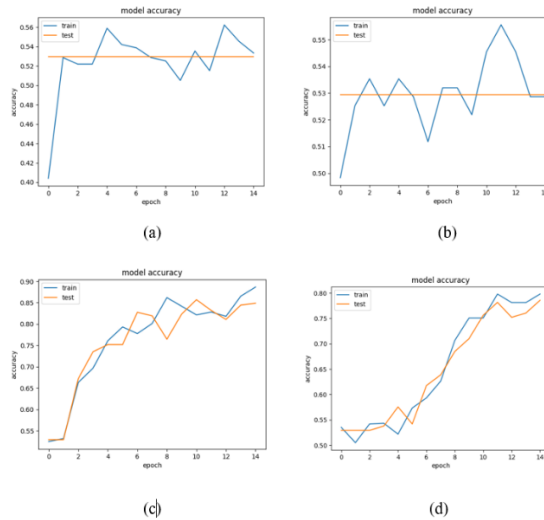


Gambar 3. Grafik performansi pada partisi data 70:30
 Learning rate (a) 0.1 (b) 0.01 (c) 0.001 (d) 0.0001

Tabel 3. Classification report dengan learning rate 0.0001 (70:30)

| id | Precision | Recall | F1-Score |
|----------|-----------|--------|----------|
| 0 | 0.21 | 0.29 | 0.24 |
| 2 | 0.29 | 0.29 | 0.29 |
| 3 | 0.56 | 0.48 | 0.52 |
| Accuracy | | | 0.39 |

- Hasil akurasi tertinggi pada partisi data 60:40 adalah sebesar 38%. Grafik performansi dan classification report dari model klasifikasi ini dapat dilihat pada gambar 4 dan tabel 4 dibawah ini.



Gambar 4. Grafik performansi dengan partisi data 60:40

Learning rate (a) 0.1 (b) 0.01 (c) 0.001 (d) 0.0001

Tabel 4. Classification report dengan learning rate 0.0001 (60:40)

| id | Precision | Recall | F1-Score |
|----------|-----------|--------|----------|
| 0 | 0.23 | 0.27 | 0.25 |
| 2 | 0.23 | 0.20 | 0.21 |
| 3 | 0.51 | 0.52 | 0.51 |
| Accuracy | | | 0.38 |

5. Simpulan dan Saran

5.1. Simpulan

Berdasarkan penelitian dan pengujian yang telah dilakukan, dapat disimpulkan bahwa:

1. metode klasifikasi CNN cocok untuk mengidentifikasi kerusakan baterai, tetapi dikarenakan data yang kurang bagus membuat hasilnya menjadi kurang maksimal.
2. dari pengujian yang dilakukan, terdapat peningkatan dalam hal performansi pada proses *training*. Dalam beberapa kali pengujian didapatkan hasil akurasi yang meningkat seiring dengan meningkatnya Learning Rate. Akurasi tertinggi dalam pengujian yang penulis lakukan adalah pada partisi data 70:30 dan learning rate 0.0001 sebesar 39%.
3. Data yang bagus menurut kriteria adalah data yang memiliki keseragaman dalam hal latar dan konsistensi posisi objek sehingga pemrosesan gambar menjadi lebih cepat dan tepat.

5.2. Saran

Dalam penelitian setelah ini, penulis ingin memberikan saran untuk pengembangan selanjutnya dari sistem ini sebagai berikut.

1. Data yang digunakan untuk penelitian diharapkan untuk menggunakan data yang lebih banyak dan bervariasi lagi.
2. Data gambar asli sebaiknya diproses terlebih dahulu sebelum memasuki tahapan prapemrosesan seperti labelling gambar dan lain sebagainya.

3. Untuk pengambilan data, diharapkan menggunakan background foto yang seragam agar memudahkan proses ekstraksi ciri pada gambar.
4. Untuk pengembangan selanjutnya, diharapkan untuk menambah beberapa parameter seperti bau dan sebagainya sebagai parameter pertimbangan kerusakan pada baterai.

Referensi

- [1] F. A. Permana, "Baterai Lithium," *INKUIRI: Jurnal Pendidikan IPA*, vol. 9, no. 2, pp. 113-118, 2020.
- [2] A. Newcomb, "NBC News," 23 January 2017. [Online]. Available: <https://www.nbcnews.com/tech/tech-news/samsung-finally-explains-galaxy-note-7-exploding-battery-mess-n710581>.
- [3] F. A. Isman, A. L. Prasasti and R. A. Nugrahaeni, "Expression Classification for User Experience Testing using Convolutional Neural Network," in *International Conference on Artificial Intelligence and Mechatronics Systems (AIMS)*, 2021.
- [4] 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.
- [5] I. A. P. P. Muhammad Thowil Afif, "Analisis Perbandingan Baterai Lithium-Ion, Lithium-Polymer, Lead Acid, dan Nickel-Metal Hydride Pada Penggunaan Mobil Listrik," *Jurnal Rekayasa Mesin*, vol. 1, 2015.
- [6] F. F. Maulana and N. Rochmawati, "Klasifikasi Citra Buah Menggunakan Convolutional Neural Network," *JINACS (Journal Of Informatics and Computer Science)*, 2019.
- [7] I. W. S. E. Putra, "Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) Pada Caltech 101," *Jurnal Teknik ITS*, vol. 1, no. 1, pp. 65-68, 2016.
- [8] J. Hurwitz and D. Kirsch, *Machine Learning for Dummies - IBM Edition*, IBM, 2018.
- [9] Agarap and A. F. M., "An Architecture Combining Convolutional Neural Network (CNN) and Support Vector Machine (SVM) for Image Classification," *arXiv:1712.03541v2*, 2019.
- [10] J. Chang and J. Sha, "An Efficient Implementation of 2D convolution in CNN," *IEICE Electronics Express*, 2017.