



# Sistem Pengenalan Karat Pada Besi Menggunakan CNN

Risky Aswi Ramadhani<sup>1\*</sup>

<sup>1</sup>Universitas Nusantara PGRI Kediri,  
Jl. Ahmad Dahlan No.76, Kediri, Indonesia  
riskyaswiramadhani@gmail.com

\*Risky Aswi Ramadhani

## Abstrak:

Besi adalah material krusial dalam kehidupan modern, mulai dari konstruksi hingga peralatan dapur, dihargai karena kekuatan dan ketersediaannya. Namun, kelemahan mendasarnya adalah kerentanan terhadap korosi—proses yang dipicu oleh oksigen dan air—yang bisa menyebabkan kerugian besar jika tidak ditangani. Solusi yang diangkat dalam penelitian ini adalah menciptakan sebuah sistem pengenalan karat dini menggunakan Convolutional Neural Network (CNN) dengan arsitektur MobileNetV2, sebuah pendekatan yang menjanjikan akurasi tinggi dalam klasifikasi citra. Sistem ini dilatih menggunakan dataset kecil sebanyak 1279 gambar (terdiri dari 693 besi berkarat dan 586 tidak berkarat), Hasil eksperimen menunjukkan bahwa model mampu mencapai tingkat akurasi yang sangat tinggi, yakni 0.98 untuk kelas "Berkarat" dan 0.97 untuk kelas "Tidak Berkarat". Hasil ini menunjukkan bahwa model yang diusulkan efektif dalam mengenali karat pada besi, sehingga diharapkan dapat membantu dalam perawatan material besi sejak dini

## Kata Kunci:

Sistem Pengenalan Karat, Convolutional Neural Network (CNN), Korosi Besi, Deteksi Citra, Klasifikasi

## Abstract:

Iron is an essential material in modern life, from construction to kitchen utensils, valued for its strength and availability. However, its fundamental weakness is its susceptibility to corrosion—a process driven by oxygen and water—which can cause significant losses if left untreated. The solution proposed in this study is to create an early rust recognition system using a Convolutional Neural Network (CNN) with the MobileNetV2 architecture, an approach that promises high accuracy in image classification. The system was trained using a small dataset of 1,279 images (consisting of 693 rusted iron images and 586 non-rusted iron images). Experimental results show that the model is able to achieve a very high accuracy rate of 0.98 for the "Rusted" class and 0.97 for the "non-rusted" class. These results indicate that the proposed model is effective in recognizing rust on iron, thus it is expected to assist in the early treatment of iron materials.

## Keywords:

Rust Recognition System, Convolutional Neural Network (CNN), Iron Corrosion, Image Detection, Classification

## 1. Pendahuluan

Besi merupakan salah satu logam yang sering digunakan untuk berbagai keperluan manusia seperti bahan konstruksi, bahan kendaraan, dan peralatan dapur.[1], [2]Besi banyak digunakan karena memiliki sifat yang kuat, selain itu besi sangat mudah didapat[3]

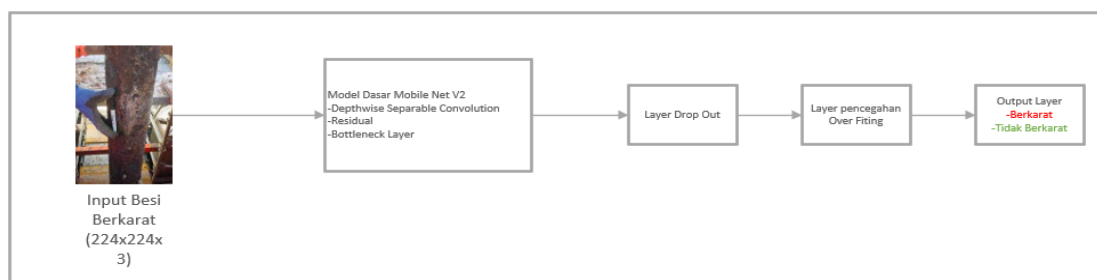
Besi memiliki banyak keistimewaan, namun besi juga memiliki beberapa kelemahan. Kelemahannya yaitu gampang korosi[4], [5], [6]. Korosi pada besi disebabkan oleh oksigen dan air[7][8]. Untuk menanggulangi korosi besi dapat di cat[9]. Yang menyebabkan besi gampang korosi bukan karena tidak di cat, karena kebiasaan orang-orang tidak mengerti jika besi tersebut korosi. Untuk menekan laju korosi pada besi perlu adanya pengelatan korosi sejak dini, sehingga korosi tidak meluas, dan perawatan besi yang terkena korosi bisa dilakukan sejak dini.

Solusi dari permasalahan diatas yaitu membuat sebuah system yang digunakan untuk mengenali korosi sejak dini, penelitian ini memanfaatkan CNN dengan arsitektur Mobile Net V2 untuk mengenali korosi pada besi[7]. Alasan memanfaatkan CNN dengan Arsitektur Mobile Net V2 untuk mengenali Besi karena memiliki akurasi yang tinggi[10], [11], [12]. Jika dibandingkan dengan CNN tradisional yang gemuk CNN, dengan Arsitektur Mobile Net V2 lebih efisien.

Data set yang digunakan dibagi menjadi 2 jenis yaitu besi yang berkarat berjumlah 693 dan besi yang tidak berkarat berjumlah 586, jadi total data set 1279[13], [14]. Dengan system ini diharapkan besi berkarat dapat ditangani sejak dini[15], [16].

## 2. Metode

Proses mengenali karat pada besi merupakan hal yang rumit. Proses lebih detailnya dapat dilihat pada arsitekturdengan mobile net dibawah ini :



**Gambar 1. Arsitektur Pengenalan karat dengan MobileNetV2**

Berikut ini keterangan dari Gambar 2: Arsitektur Pengenalan karat dengan MobileNetV2 :

- a. Input Layer: pada tahapan ini system mendapatkan input data berupa besik yang "berkarat/tidak berkarat". dimensi yang digunakan 225x224x3(angka ini menunjukan bahwa resolusi gambar 224x224 piksel dengan 3 kanal warna).
- b. Model Dasar MobileNetV2: Pada tahapan ini citra diproses oleh arsitektur MobileNetV2 yang lebih efisien. Adapun rincian komponen-kompone yang ada didalamnya dapat dilihat pada penjealan dibawah ini
  - Depthwise Separable Convolution: Teknik konvolusi yang meringankan kinerja komputer.
  - Residual: Jalur pintas (skip connection) untuk menjaga aliran informasi pada layer yang dalam.
  - Bottleneck Layer: Lapisan penyempitan untuk mengekstraksi fitur paling penting secara efisien.
- c. Layer Dropout: Berfungsi untuk memutuskan koneksi saraf secara acak selama pelatihan guna mencegah ketergantungan berlebih pada satu saraf tertentu.
- d. Layer Pencegahan Overfitting: Langkah tambahan (seperti *Global Average Pooling* atau augmentasi) untuk memastikan model tetap akurat saat menghadapi data baru di luar dataset latihan.

e. Output Layer: Pada Tahap akhir citra sudah diklasifikasi sehingga dapat dikenali besi itu berkarat atau tidak.

### 2.1 Deskripsi Parameter Pelatihan

Selama penelitian ini dilakukan, proses pelatihan model dikonfigurasi menggunakan pengaturan teknis (hyperparameter) tertentu untuk mengoptimalkan performa klasifikasi. Pengaturan tersebut meliputi penetapan jumlah Epochs sebanyak 50 kali untuk memastikan model belajar secara mendalam dari seluruh dataset, serta penggunaan Batch Size sebesar 16 untuk menyeimbangkan beban memori dan stabilitas gradien. Selain itu, diterapkan Learning Rate sebesar 0,001 sebagai standar kecepatan penyesuaian bobot agar model dapat mencapai titik konvergensi dengan akurat selama fase pelatihan.

## 3. Hasil dan Pembahasan

### 3.1. Hasil

#### a. Data Training

Pada penelitian ini system deteksi karat dibangun dengan menggunakan Tecnable machine dan menggunakan Convolutional *Neural Network* CNN, hal yang pertama kali dilakukan yaitu membuat data training, berikut ini proses pembuatan data training.



Sumber: <https://www.kaggle.com/datasets/benpepperpots/rust-iron-dataset>

**Gambar 2. Data Training besi berkarat dan besi tidak berkarat**

Gambar3: Data Training berkarat dan tidak berkarat merupakan data training yang akan digunakan. Data tersebut berisi besi yang berkarat dan tidak berkarat. Adapun jumlah data latih 1279 gambar.

#### b. Proses pembentukan Model.

Bagian ini merupakan bagian dasar setelah data terkumpul, proses ini disebut dengan trainmodel. Pada penelitian ini model diubah menjadi model tensor flow Js. Model dapat dilihat pada Gambar 4 Tensor Flow dibawah ini

```
let model, webcam, labelContainer, maxPredictions;

// Load the image model and setup the webcam
async function init() {
  const modelURL = URL + "model.json";
  const metadataURL = URL + "metadata.json";
  model = await tmImage.load(modelURL, metadataURL);
  maxPredictions = model.getTotalClasses();
  const flip = true; // whether to flip the webcam
  webcam = new tmImage.Webcam(200, 200, flip); // width, height, flip
  await webcam.setup(); // request access to the webcam
  await webcam.play();
  window.requestAnimationFrame(loop)
  document.getElementById("webcam-container").appendChild(webcam.canvas);
  labelContainer = document.getElementById("label-container");
  for (let i = 0; i < maxPredictions; i++) { // and class labels
    labelContainer.appendChild(document.createElement("div"));
  }
}
```

**Gambar 3 . Tensor Flow. Js**

c. Interface Website

Setelah Model terbentuk model Tensor Flow. Js dipindah ke website negan memanfaatkan PHP dan HTML, tampilan website inilah yang nantinya yang dioperasikan oleh user yang merawat besi.



**Gambar 4. Pengujian Besi Berkarat**

Gambar 5: Pengujian besi berkarat Bagian ini merupakan sebuah bagian untuk menguji besi tersebut berkarat atau tidak, pada percobaan tersebut besi yang di cek Adalah anak kunci. Hasil dari percobaan tersebut anak kunci terbut dikenali berkarat, dengan nilai 40%. Hal ini benar karena pada anak kuci tersebut terdapat bercak-bercak yang berkarat.

### 3.2. Pembahasan

#### a. Hasil Akurasi Per Kelas

Analisis dilakukan per kelas untuk memastikan model memiliki kemampuan generalisasi yang seimbang. Hasil menunjukkan akurasi 0.98 untuk kelas Berkarat dan 0.97 untuk kelas Tidak Berkarat, yang mengindikasikan bahwa model mampu mengenali fitur tekstur korosi secara spesifik tanpa dipengaruhi oleh perbedaan jumlah sampel antar kelas. Hasil bisadilihat pada table 1: Hasil Evaluasi akurasi dibawah ini:

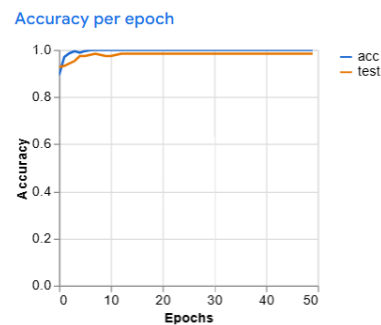
**Tabel 1: Hasil Evaluasi Akurasi**

Klas	Akurasi	Sampel
Berkarat	0.98	88
Tidak Berkarat	0.97	88

#### b. Analisis Kurva Pembelajaran (Accuracy & Loss per Epoch)

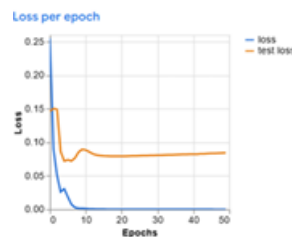
Berdasarkan hasil pelatihan, grafik *Accuracy per Epoch* menunjukkan bahwa akurasi model meningkat secara signifikan dan stabil mendekati angka 1.0 (100%) seiring bertambahnya iterasi, baik pada data *training* maupun data *test*. Penurunan nilai *Loss per Epoch* yang drastis hingga mendekati 0.00 pada data *training* mengonfirmasi bahwa model berhasil mempelajari pola visual karat dengan sangat baik. Meskipun

terdapat sedikit fluktuasi pada nilai *loss* data *test* di awal *epoch*, grafik tersebut kemudian mendatar (*plateau*), yang membuktikan bahwa model tidak mengalami *overfitting* dan mampu menggeneralisasi data baru dengan stabil. Berikut ini grafiknya



**Gambar 6 Akurasi Per Epoch**

Grafik *loss* pada data pelatihan menunjukkan penurunan drastis hingga mendekati nilai 0.00. Meskipun terdapat sedikit fluktuasi pada *test loss* di bawah angka 0.10 pada awal pelatihan, nilai tersebut kemudian mendatar (*plateau*), yang mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami *overfitting* yang signifikan. Grafik dapat dilihat pada gambar dibawah ini



**Gambar 7. Loss per Epoch**

#### 4. Kesimpulan

Penelitian ini berhasil mengembangkan sistem deteksi karat pada besi berbasis MobileNetV2 yang diintegrasikan ke dalam platform web menggunakan TensorFlow.js. Melalui pelatihan dengan 1.279 citra dan konfigurasi hyperparameter yang optimal, model mencapai performa yang sangat baik dengan tingkat akurasi 98% untuk kategori berkarat dan 97% untuk kategori tidak berkarat. Grafik pembelajaran yang stabil dengan tingkat *loss* mendekati nol mengonfirmasi bahwa model mampu melakukan generalisasi dengan efektif tanpa mengalami *overfitting*, sehingga sistem ini terbukti akurat dan siap diimplementasikan sebagai alat pendukung keputusan yang efisien bagi pengguna untuk mendeteksi kondisi besi secara real-time.

#### Pustaka

- [1] D. M. Clatterbuck, D. C. Chrzan, and J. W. Morris, "The ideal strength of iron in tension and shear," *Acta Mater.*, vol. 51, no. 8, pp. 2271–2283, May 2003, doi: 10.1016/S1359-6454(03)00033-8.
- [2] D. M. Clatterbuck, D. C. Chrzan, and J. W. Morris, "THE IDEAL STRENGTH OF IRON," *Nano Microstruct. Des. Adv. Mater. A Commem. Vol. Profr. G. Thomas' Seventieth Birthd.*, pp. 173–190, Jan. 2003, doi: 10.1016/B978-008044373-7/50043-7.
- [3] M. Ghasempour-Mouziraji, J. Lagarinhos, D. Afonso, and R. Alves de Sousa, "A review study on metal powder materials and processing parameters in Laser Metal Deposition," *Opt. Laser Technol.*, vol. 170, no. 7, p. 110226, Mar. 2024, doi: 10.1016/j.optlastec.2023.110226.
- [4] D. Banerjee and A. Gopalan, "Towards Reliable Alignment: Uncertainty-aware RLHF," Oct. 2024,

Accessed: Jan. 21, 2026. [Online]. Available: <http://arxiv.org/abs/2410.23726>

- [5] T. Soga, "Advances in capillary electrophoresis mass spectrometry for metabolomics," *TrAC - Trends Anal. Chem.*, vol. 158, Jan. 2023, doi: 10.1016/j.trac.2022.116883.
- [6] D. Dowson and A. Neville, "Tribology and corrosion in hip joint replacements: Materials and engineering," *Jt. Replace. Technol.*, pp. 401–442, Jan. 2014, doi: 10.1533/9780857098474.3.401.
- [7] J. G. Speight, "Corrosion," *Subsea Deep. Oil Gas Sci. Technol.*, pp. 213–256, 2015, doi: 10.1016/B978-1-85617-558-6.00008-8.
- [8] M. Wojtkowska *et al.*, "The Influence of Water Quality Change on the Corrosion Process in Galvanized Pipes of Fire Protection Installations," *Sustain. 2022, Vol. 14*, vol. 14, no. 13, Jun. 2022, doi: 10.3390/su14137708.
- [9] "Mengenal Karakteristik dan Jenis Tanah-Tanah Pertanian di Indonesia - Jejak ... - Haidar Fari Aditya, Fitri Wijayanti - Google Books." Accessed: Feb. 27, 2026. [Online]. Available: [https://books.google.co.id/books?hl=en&lr=&id=smffEAAAQBAJ&oi=fnd&pg=PA1&dq=Jenis+Tanah:+Proses+Pembentukan+hingga+Persebarannya+di+Indonesia&ots=ER11m5ixs0&sig=eLBAmgPJY-jidKxe918luYyYNMg&redir\\_esc=y&safe=strict#v=onepage&q&f=false](https://books.google.co.id/books?hl=en&lr=&id=smffEAAAQBAJ&oi=fnd&pg=PA1&dq=Jenis+Tanah:+Proses+Pembentukan+hingga+Persebarannya+di+Indonesia&ots=ER11m5ixs0&sig=eLBAmgPJY-jidKxe918luYyYNMg&redir_esc=y&safe=strict#v=onepage&q&f=false)
- [10] K. L. Guntu *et al.*, "CheckKuko: Non-Invasive Early Detection of Iron Deficiency Nail Symptoms through Image Processing Using Faster R-CNN," *2022 IEEE Glob. Conf. Artif. Intell. Internet Things, GCAIoT 2022*, pp. 82–87, 2022, doi: 10.1109/GCAIoT57150.2022.10019199.
- [11] Y. Dong, Y. Pan, D. Wang, and T. Cheng, "Corrosion detection and evaluation for steel wires based on a multi-vision scanning system," *Constr. Build. Mater.*, vol. 322, p. 125877, Mar. 2022, doi: 10.1016/j.conbuildmat.2021.125877.
- [12] R. P. De Figueiredo and S. Bogh, "Vision-Based Corrosion Identification Using Data-Driven Semantic Segmentation Techniques," *IST 2023 - IEEE Int. Conf. Imaging Syst. Tech. Proc.*, 2023, doi: 10.1109/IST59124.2023.10355698.
- [13] "Rust-Iron-Dataset." Accessed: Mar. 06, 2026. [Online]. Available: <https://www.kaggle.com/datasets/benpepperpots/rust-iron-dataset>
- [14] W. T. Nash, C. J. Powell, T. Drummond, and N. Birbilis, "Automated Corrosion Detection Using Crowd Sourced Training for Deep Learning," *Corrosion*, vol. 76, no. 2, pp. 135–141, Aug. 2019, Accessed: Mar. 06, 2026. [Online]. Available: <http://arxiv.org/abs/1908.02548>
- [15] S. S. Aljameel *et al.*, "A Deep Learning Approach to Industrial Corrosion Detection," *Comput. Mater. Contin.*, vol. 81, no. 2, pp. 2587–2605, Nov. 2024, doi: 10.18280/ijss.140310.
- [16] N. Xin, W. Zhuojun, Z. Yanyong, X. Shanzhi, Z. Zhaoying, and S. Tengcheng, "Research on the Quality Improvement Strategy of Inspection and Testing Institutions Based on AI Vision Systems," *2025 IEEE 3rd Int. Conf. Control. Electron. Comput. Technol.*, pp. 1552–1556, Apr. 2025, doi: 10.1109/ICCECT64621.2025.11339644.