

Klasifikasi Image Pokémon Menggunakan Convolutional Neural Networks

Maulana Sulistio Saputra Soeprijanto¹, Zulfa Hady Kusuma², Ahmad Yusuf³, Dwi Rolliawati⁴

¹²³⁴ Universitas Islam Negeri Sunan Ampel Surabaya

Corresponding Author : edocules123@gmail.com

Abstract: *This study aims to develop a Pokémon image classification model using Convolutional Neural Networks (CNN). The model is designed to identify the visual patterns of Pokémon based on their primary types, such as Water, Grass, Fire, Electric, and Poison. The research process includes dataset preparation using data sourced from Kaggle, image augmentation to enhance data variability, CNN model training, and model performance evaluation. The resulting model achieved an accuracy of 68.28% on the test data, indicating a reasonable ability to recognize complex visual patterns. Data augmentation and regularization techniques proved effective in improving the model's generalization capability. This study is expected to contribute to the development of machine learning-based applications in digital entertainment, particularly in the recognition and classification of Pokémon characters. Future research is recommended to utilize larger datasets and integrate non-visual features to improve model performance further.*

Keyword : *CNN, data augmentation, image classification, machine learning, Pokémon*

Copyright ©2024 Walisongo Journal of Information Technology

Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International License.



1. Pendahuluan

Klasifikasi gambar menggunakan Convolutional Neural Networks (CNN) menjadi metode yang semakin populer dalam mengatasi tantangan pengenalan pola visual yang kompleks. Penelitian sebelumnya menunjukkan bahwa analisis desain karakter Pokémon, seperti Kleavor, tidak hanya memperhatikan aspek estetika tetapi juga mencerminkan elemen budaya, seperti representasi suku Ainu di Jepang (Rozaq, Samudra, and Islam 2023). Hal ini menunjukkan pentingnya memahami konteks visual dan budaya dalam pengembangan metode klasifikasi berbasis pembelajaran mendalam.

Metode pembelajaran mesin seperti GAN telah menunjukkan kemampuan dalam menghasilkan gambar berbasis dataset yang dapat digunakan untuk tugas klasifikasi lebih lanjut. Sebagai contoh, penelitian sebelumnya memanfaatkan GAN untuk membuat kartu Pokémon yang konsisten dengan elemen desain asli, dengan menggabungkan klasifikasi berbasis elemen visual untuk meningkatkan kohesi desain gambar dan teks (Acharya and Oliver 2019). Temuan ini membuktikan pentingnya pendekatan terintegrasi untuk menciptakan model yang dapat menangkap kompleksitas visual.

Penelitian lain juga menunjukkan bahwa fitur non-visual, seperti simbolisme suara dalam nama Pokémon, dapat dimanfaatkan untuk klasifikasi. Dengan algoritma Random Forests,

peneliti mampu memprediksi evolusi Pokémon berdasarkan pola simbolik suara, menunjukkan akurasi yang lebih tinggi dibandingkan klasifikasi manual (Kilpatrick, Ćwiek, and Kawahara 2023). Pendekatan ini membuktikan bahwa berbagai fitur, baik visual maupun simbolik, dapat digunakan secara efektif dalam klasifikasi berbasis pembelajaran mesin.

Penelitian sebelumnya juga menggarisbawahi pentingnya efisiensi model dalam klasifikasi berbasis visual. Sebagai contoh, pendekatan yang menggabungkan struktur jaringan seperti ResNet dan DenseNet dapat menghasilkan model yang ringan dan akurat, memungkinkan implementasi yang lebih luas, termasuk pada perangkat dengan sumber daya terbatas seperti perangkat seluler. Studi ini telah berhasil mengaplikasikan arsitektur tersebut pada dataset Pokémon, menunjukkan kinerja yang optimal dengan pengurangan kompleksitas komputasi (He, Li, and Wang 2020).

Selain itu, penelitian berbasis simbolisme suara menunjukkan adanya keterkaitan antara fitur linguistik dan pola evolusi Pokémon. Peneliti menggunakan algoritma Random Forests untuk mendeteksi hubungan ini, yang menunjukkan bahwa pola seperti panjang nama dan jenis suara memiliki pengaruh signifikan terhadap tahapan evolusi. Hal ini membuka peluang untuk menggabungkan pendekatan berbasis visual dan linguistik dalam model klasifikasi yang lebih komprehensif (Kilpatrick, Ćwiek, and Kawahara 2023).

Penggabungan berbagai pendekatan pembelajaran mesin ini menunjukkan potensi yang besar dalam menyelesaikan tantangan klasifikasi berbasis gambar dan fitur non-visual. Kombinasi metode seperti CNN, GAN, dan Random Forests tidak hanya meningkatkan akurasi tetapi juga memungkinkan pengembangan sistem yang lebih efisien dan adaptif. Implementasi pendekatan-pendekatan ini juga relevan untuk aplikasi yang lebih luas, termasuk dalam konteks hiburan digital dan pengembangan konten kreatif.

Di sisi lain, GAN telah berhasil diterapkan untuk menghasilkan elemen visual yang kohesif dengan desain asli. Sebagai contoh, generasi kartu Pokémon berbasis GAN tidak hanya menciptakan gambar yang estetik tetapi juga meningkatkan integrasi elemen visual seperti warna, bentuk, dan atribut desain lainnya, memungkinkan peningkatan akurasi pada proses klasifikasi berbasis elemen visual (Acharya and Oliver 2019).

Penelitian ini bertujuan untuk mengembangkan model klasifikasi gambar Pokémon menggunakan CNN, yang diharapkan mampu mengenali pola visual yang kompleks. Dengan pendekatan ini, penelitian ini berkontribusi pada pengembangan metode klasifikasi yang lebih adaptif dan mendukung inovasi dalam aplikasi pembelajaran mesin di bidang hiburan digital, khususnya dalam konteks visualisasi karakter Pokémon.

Studi oleh (Chirra et al. 2023) menggunakan pendekatan transfer learning untuk mengklasifikasikan gambar 10 karakter Pokémon seperti Pikachu, Raichu, dan Charmander. Penelitian ini memanfaatkan tujuh model pra-latih, termasuk ResNet101, MobileNetV2, dan VGG16. Dengan dataset yang diperoleh dari internet, mereka meningkatkan jumlah data melalui augmentasi gambar, menciptakan lebih dari 7.000 data sampel. Hasilnya menunjukkan bahwa model ResNet101 menghasilkan akurasi tertinggi (95,60%) dibanding model lainnya, menggarisbawahi potensi transfer learning dalam menangani dataset terbatas dengan akurasi tinggi.

Penelitian yang dilakukan oleh (He, Li, and Wang 2020) berfokus pada mengembangkan model jaringan saraf konvolusi (CNN) ringan berbasis ResNet dan DenseNet untuk aplikasi yang membutuhkan efisiensi tinggi seperti perangkat seluler. Model yang diusulkan menggabungkan konvolusi dengan kernel ukuran berbeda untuk menghasilkan feature map yang lebih baik dengan parameter lebih sedikit dibanding DenseNet dan ResNet.

Eksperimen pada dataset gambar menunjukkan bahwa model sembilan lapis yang diusulkan memiliki tingkat pengenalan lebih tinggi (97,37%) daripada ResNet18 dan DenseNet, sambil mempertahankan efisiensi dalam hal waktu pelatihan dan sumber daya komputasi.

Penelitian oleh (Kilpatrick, Ćwiek, and Kawahara 2023) mengeksplorasi hubungan antara simbolisme suara dalam nama Pokémon dengan status evolusinya. Menggunakan algoritma Random Forests, penelitian ini menganalisis dataset nama Pokémon dari beberapa bahasa (Jepang, Korea, dan Cina) serta data yang dihasilkan melalui eksperimen elisitasi. Hasil menunjukkan bahwa Random Forest dapat mempelajari pola sistematis antara elemen suara dalam nama Pokémon dan status evolusinya. Sebagai contoh, suara tertentu seperti voiced obstruents lebih sering muncul pada Pokémon pasca-evolusi. Penelitian ini menyoroti kekuatan simbolisme suara dalam membantu mesin memahami pola linguistik. Kajian Pustaka memuat ringkasan penelitian-penelitian sebelumnya yang terkait dengan penelitian yang dilakukan oleh penulis.


Penelitian oleh (Li, Chen, and Zhao, n.d.) menggunakan pendekatan *Relation Network* berbasis Convolutional Neural Network (CNN) untuk mengklasifikasikan gambar Pokémon dengan skenario *few-shot learning*, di mana hanya ada satu gambar berlabel untuk setiap kelas. Penelitian ini mengganti CNN standar dengan ResNet-18, yang lebih andal dalam menangkap fitur gambar, dan menambahkan peta *saliency* untuk membantu jaringan fokus pada objek utama, meskipun gambar memiliki latar belakang yang kompleks.

Eksperimen menunjukkan bahwa ResNet-18 adalah pilihan terbaik dibandingkan arsitektur lainnya seperti ResNet-50 dan DenseNet. Dengan peta *saliency* dan mekanisme *cross-layer linkage*, pendekatan ini berhasil meningkatkan akurasi hingga 77,71% dalam skenario klasifikasi *5-way one-shot*. Hasil ini menegaskan efektivitas CNN yang dirancang dengan baik dan penggunaan teknik tambahan seperti *saliency detection* untuk meningkatkan akurasi klasifikasi pada dataset dengan jumlah data terbatas.

2. Metode

Penelitian ini mengimplementasikan algoritma Convolutional Neural Network (CNN) untuk klasifikasi gambar Pokémon dengan pendekatan berbasis pengolahan data dan pembelajaran mesin. Proses penelitian mencakup lima tahapan utama: persiapan data, praproses gambar, pembagian dataset, pelatihan model, dan evaluasi model. Tahapan-tahapan tersebut dirancang secara sistematis untuk memastikan hasil yang valid, sebagaimana divisualisasikan dalam diagram berikut:

Gambar 1 Metode Penelitian



Pada gambar 1 menjelaskan setiap urutan untuk melakukan klasifikasi Pokemon menggunakan metode *Convolutional Neural Network* (CNN).

Data Preparation

Mencari dataset pada Kaggle dan membaca dataset Pokémon dari file CSV. Dataset ini difilter untuk menyertakan hanya tipe Pokémon yang relevan, seperti "Water", "Fire", "Grass", dan lainnya. Data yang tidak relevan dibuang, sehingga dataset hanya berisi nama Pokémon dan tipe utamanya.

Image Preprocessing

Image Preprocessing
Tahap ini melibatkan pemrosesan gambar Pokémon dengan mengonversinya ke format RGB, mengubahnya menjadi array numpy, dan menggabungkannya dengan label tipe Pokémon. Augmentasi data dilakukan dengan rotasi, zoom, shear, pergeseran, dan pembalikan horizontal untuk menambah variasi dan meningkatkan performa model.

Split Data

Dataset dibagi menjadi dua bagian: data train untuk melatih model dan data test untuk mengevaluasi performa model. Pembagian ini memastikan bahwa evaluasi model dilakukan dengan data yang tidak pernah dilihat selama pelatihan.

CNN Model Training

pembangunan model CNN dengan lapisan konvolusi, pooling, dan dense. Model ini dilatih dengan data latih menggunakan fungsi kerugian Sparse Categorical Crossentropy dan optimizer Adam. Tujuannya adalah untuk membuat model memahami pola dalam gambar Pokémon.

Evaluate

Pada tahap evaluasi, model diuji menggunakan data uji seperti matriks kebingungan untuk menganalisis akurasi prediksi dan grafik akurasi serta loss selama pelatihan. Tujuan dari tahap ini adalah untuk memastikan model memiliki kemampuan generalisasi yang baik pada data baru.

Save Model

Model yang telah dilatih dengan akurasi yang baik disimpan dalam format .h5 agar dapat digunakan di masa depan tanpa harus dilatih ulang.

3. Hasil dan Pembahasan

Data Preparation

Pada tahap persiapan data, kami menggunakan dataset Pokémon yang diunduh dari Kaggle untuk dianalisis menggunakan pendekatan Convolutional Neural Networks (CNN). Tujuan utama dari tahap ini adalah untuk mengurangi kompleksitas dataset dengan memfokuskan pada tipe Pokémon tertentu yang relevan dengan penelitian. Meskipun dataset mencakup berbagai tipe Pokémon, kami memutuskan untuk melakukan pemfilteran berdasarkan beberapa tipe utama, yaitu Water, Grass, Fire, Electric, dan Poison.

Gambar 2 Sebelum Preparation

```
data=pd.read_csv('/content/pokemon.csv')
data
```

	Name	Type1	Type2	Evolution
0	tulbasaur	Grass	Poison	ivysaur
1	ivysaur	Grass	Poison	venusaur
2	venusaur	Grass	Poison	NaN
3	chamander	Fire	NaN	chameleon
4	chameleon	Fire	NaN	charizard
...	...	...	...	...
804	stakataka	Rock	Steel	NaN
805	biscephalon	Fire	Ghost	NaN
806	zeraora	Electric	NaN	NaN
807	metan	Steel	NaN	NaN
808	metmetal	Steel	NaN	NaN

809 rows x 4 columns

Gambar 3 Sesudah Preparation

```
data=data[data.Type1.isin(['Water','Grass','Fire','Electric','Poison'])][['Name','Type1']]
data
```

	Name	Type1
0	tulbasaur	Grass
1	ivysaur	Grass
2	venusaur	Grass
3	chamander	Fire
4	chameleon	Fire
...	...	...
787	artara	Grass
802	popok	Poison
803	naganadel	Poison
805	biscephalon	Fire
806	zeraora	Electric

319 rows x 2 columns

Pemfilteran ini bertujuan untuk menyederhanakan dataset dan fokus pada gambar Pokémon dengan tipe utama yang ditentukan.

Hasil dari tahap ini adalah dataset yang telah difilter hanya menyertakan Pokémon dengan tipe utama yang relevan. Dataset yang telah dipilih ini kini terdiri dari dua kolom utama, yaitu "Name" untuk nama Pokémon dan "Type1" untuk tipe utama Pokémon. Kolom lainnya, seperti "evolution" dan "Type2" (tipe kedua), dihapus karena tidak diperlukan dalam analisis ini. Dengan langkah pemfilteran ini, dataset menjadi lebih terstruktur dan fokus, memudahkan penggunaannya dalam langkah-langkah berikutnya, seperti augmentasi gambar, pelatihan model, dan evaluasi model CNN. Dengan demikian, tahap persiapan data berhasil menghasilkan dataset yang lebih efisien dan terarah untuk proses klasifikasi.

Image Preprocessing

Sebelum melakukan Image Preprocessing, kita menampilkan gambar-gambar Pokémon dalam bentuk aslinya untuk melihat data yang tersedia. Setelah itu, gambar-gambar tersebut akan melalui tahapan preprocessing, termasuk normalisasi dan augmentasi, untuk mempersiapkannya agar lebih siap digunakan dalam pelatihan model. Hasil gambar setelah

preprocessing akan menunjukkan perubahan yang terjadi, seperti variasi data yang dihasilkan melalui augmentasi.

Gambar 4 Sebelum



Gambar 5 Sesudah



Setelah menampilkan gambar-gambar Pokémon sebelum dan sesudah Image Preprocessing, kita dapat melihat bagaimana proses preprocessing, seperti normalisasi dan augmentasi, telah memperkaya dataset. Augmentasi gambar menambahkan variasi dengan rotasi, pergeseran, dan perubahan lainnya, sementara normalisasi memastikan bahwa piksel gambar berada dalam rentang yang sesuai untuk pelatihan model. Perubahan ini diharapkan dapat meningkatkan kemampuan model dalam mengenali pola dan membuat prediksi yang lebih akurat pada data yang belum pernah dilihat sebelumnya.

Split Data

Dalam penelitian ini, pembagian data latih dan uji dilakukan menggunakan fungsi `train_test_split` yang disediakan oleh pustaka `scikit-learn`. Fungsi tersebut dipanggil dengan data citra (X) dan label (y_{final}) sebagai masukan, beserta parameter `test_size` yang ditetapkan sebesar 0.2. Konfigurasi ini mengindikasikan bahwa 20% dari keseluruhan data akan dialokasikan sebagai data uji (X_{test} , y_{test}) untuk keperluan evaluasi model, sedangkan 80%

sisanya akan dimanfaatkan sebagai data latih (X_{train} , y_{train}) guna melatih model CNN. Rasio pembagian 80:20 ini merupakan praktik umum yang banyak diadopsi dalam pengembangan model pembelajaran mesin, khususnya ketika ukuran dataset terbatas. Pendekatan ini menyeimbangkan kebutuhan untuk melatih model dengan data yang cukup representatif dan kebutuhan untuk mengevaluasi model secara independen.

Segmentasi data menjadi data latih dan uji merupakan langkah krusial untuk mengukur kinerja model CNN secara komprehensif terhadap data yang belum pernah diproses sebelumnya. Dengan demikian, evaluasi yang dilakukan dapat memberikan gambaran yang lebih representatif mengenai kemampuan model dalam memprediksi tipe Pokémon berdasarkan citra baru. Penerapan strategi Train-Test Split ini bertujuan untuk mencegah overfitting, yaitu kondisi di mana model terlalu spesifik terhadap data latih dan gagal dalam menggeneralisasi pola pada data baru. Dengan memastikan bahwa model yang dikembangkan memiliki kapabilitas generalisasi yang optimal, model tersebut dapat diimplementasikan pada data Pokémon di luar himpunan data yang digunakan selama pelatihan, meningkatkan relevansi dan kegunaan model dalam konteks yang lebih luas.

CNN Model Training

Model Convolutional Neural Network (CNN) dikonstruksi menggunakan Keras dengan arsitektur berlapis yang terdiri dari tiga lapisan konvolusi, masing-masing diikuti oleh lapisan *max pooling* dan *dropout* untuk ekstraksi fitur dan pencegahan *overfitting*. Setelah diratakan, data diproses oleh lapisan *fully connected* dengan 128 neuron dan fungsi aktivasi ReLU, sebelum mencapai lapisan output dengan 5 neuron dan fungsi aktivasi softmax untuk klasifikasi multi-kelas. Model dikompilasi menggunakan optimizer Adam, fungsi kerugian *SparseCategoricalCrossentropy*, dan metrik akurasi. Pelatihan model dilakukan selama 20 epoch menggunakan data latih, dengan data uji digunakan untuk validasi.

Pemanfaatan arsitektur berlapis pada model ini didasarkan pada optimalisasi proses ekstraksi fitur dan klasifikasi citra Pokémon. Lapisan konvolusi berperan dalam mengidentifikasi pola-pola visual yang terkandung dalam citra, sedangkan lapisan *max pooling* berfungsi untuk mereduksi dimensi data dan meningkatkan efisiensi komputasi. Penerapan *dropout* ditujukan untuk mencegah *overfitting* dengan menonaktifkan neuron secara acak selama pelatihan, sehingga model tidak terlampau bergantung pada fitur-fitur spesifik dari data latih. Lapisan *fully connected* berperan sebagai pengklasifikasi yang menerima fitur-fitur hasil ekstraksi dan menghasilkan probabilitas untuk setiap kelas tipe Pokémon. Pemilihan optimizer Adam didasarkan pada kapabilitasnya dalam mengoptimalkan parameter model secara efisien, sementara fungsi kerugian *SparseCategoricalCrossentropy* dianggap sesuai untuk tugas klasifikasi multi-kelas dengan label berupa bilangan bulat. Metrik akurasi digunakan sebagai indikator kinerja model dalam memprediksi tipe Pokémon secara tepat.

Tabel 1 Arsitektur CNN

Layer (type)	Output Shape	Param #
conv2d [Conv2D]	(None, 112, 112, 16)	320
max_pooling2d [MaxPooling2D]	(None, 56, 56, 16)	0
dropout [Dropout]	(None, 56, 56, 16)	0
conv2d_1 [Conv2D]	(None, 56, 56, 32)	36,800
max_pooling2d_1 [MaxPooling2D]	(None, 28, 28, 32)	0
dropout_1 [Dropout]	(None, 28, 28, 32)	0
conv2d_2 [Conv2D]	(None, 28, 28, 64)	121,600
max_pooling2d_2 [MaxPooling2D]	(None, 14, 14, 64)	0
dropout_2 [Dropout]	(None, 14, 14, 64)	0
flatten [Flatten]	(None, 1120)	0
dense [Dense]	(None, 128)	143,360
dense_1 [Dense]	(None, 5)	640


Total params: 1,861,920 (18.62 MB)
 Trainable params: 1,861,917 (18.59 MB)
 Non-trainable params: 0 (0.00 B)

Pada Tabel 1 menampilkan struktur arsitektur jaringan saraf konvolusional (Convolutional Neural Network/CNN) lengkap dengan rincian setiap lapisan, bentuk keluaran (output shape), dan jumlah parameter. Model ini diawali dengan lapisan konvolusi 2D (conv2d_3) yang memiliki 32 filter dengan keluaran berukuran 118x118, dilanjutkan dengan lapisan pooling (max_pooling2d_3) dan dropout untuk mengurangi risiko overfitting. Tahapan konvolusi dan pooling berlanjut hingga fitur diperkecil menjadi ukuran yang lebih kompak, yang kemudian diratakan melalui lapisan flatten untuk diolah lebih lanjut oleh dua lapisan dense. Lapisan dense pertama (dense_2) memiliki 128 unit, sedangkan lapisan kedua (dense_3) memiliki 5 unit, menunjukkan bahwa model ini dirancang untuk klasifikasi dengan 5 kelas. Secara keseluruhan, jumlah parameter terbesar terdapat pada lapisan dense pertama dengan total 2.862.917 parameter.


Evaluate

Evaluasi model dilakukan melalui dua tahapan, yaitu evaluasi selama pelatihan dan evaluasi pasca-pelatihan. Pada tahap pertama, model dievaluasi pada setiap epoch menggunakan data validasi yang terpisah dari data latih. Hal ini memungkinkan pemantauan kinerja model terhadap data yang belum pernah diproses sebelumnya dan membantu dalam mengidentifikasi potensi *overfitting*. Pemantauan dilakukan dengan mengamati nilai *loss* dan akurasi pada data validasi, yang direkam dalam objek histor. Setelah proses pelatihan selesai, model dievaluasi secara komprehensif menggunakan data uji yang independen dari data latih dan validasi. Evaluasi ini dijalankan menggunakan fungsi `cnn.evaluate()`, yang menghasilkan nilai *loss* dan akurasi pada data uji. Nilai akurasi pada data uji menjadi indikator utama kinerja model dalam mengklasifikasikan tipe Pokemon berdasarkan citra baru.


Gambar 6 Grafik Model Accuracy



Gambar tersebut menampilkan grafik yang merepresentasikan performa model selama proses pelatihan dan validasi. Grafik diatas menggambarkan perubahan akurasi, di mana akurasi pada data pelatihan meningkat secara signifikan seiring bertambahnya epoch. Sementara itu, akurasi validasi juga menunjukkan peningkatan pada awal pelatihan, tetapi cenderung stabil setelah mencapai titik tertentu. Garis putus-putus merah pada grafik ini menunjukkan akurasi pada data uji (test accuracy), yang berada di sekitar 68,34%.


Gambar 7 Grafik Model Loss

Grafik diatas menunjukkan nilai loss model untuk data pelatihan dan validasi. Nilai loss data pelatihan terus menurun secara konsisten, menunjukkan bahwa model mampu belajar dengan baik dari data pelatihan. Sebaliknya, nilai loss pada data validasi juga mengalami penurunan pada tahap awal pelatihan tetapi mulai stabil di epoch-epoch akhir, mendekati nilai loss pada data uji yang digambarkan oleh garis putus-putus merah. Pola ini mengindikasikan bahwa model tidak menunjukkan overfitting yang signifikan, meskipun performanya pada data uji masih dapat ditingkatkan.

Gambar 8 Test Accuracy

Hasil evaluasi model pada data uji menunjukkan nilai akurasi sebesar 73,04% dengan nilai loss sebesar 1,4206, sebagaimana tercantum pada keluaran evaluasi model. Namun, nilai akurasi tersebut berbeda dengan angka yang dilaporkan pada bagian lain dalam naskah. Oleh karena itu, konsistensi nilai akurasi perlu diperiksa kembali berdasarkan informasi eksperimen yang tersedia sebelum hasil penelitian difinalisasi.

Gambar 9 Confusion Matrix



Gambar di atas menampilkan matriks kebingungan (confusion matrix) untuk model klasifikasi gambar jenis Pokémon, dengan sumbu vertikal menunjukkan label asli (True Labels) dan sumbu horizontal menunjukkan label hasil prediksi (Predicted Labels). Matriks ini terdiri dari lima kategori: Grass, Fire, Water, Poison, dan Electric, dimana setiap elemen merepresentasikan jumlah data yang diklasifikasikan ke dalam kelas tertentu. Model menunjukkan kinerja sempurna tanpa adanya kesalahan klasifikasi, ditandai dengan ketiadaan False Positive (FP) maupun False Negative (FN). Sebagai contoh, seluruh 78 sampel dengan label asli "Grass," 53 sampel "Fire," 114 sampel "Water," 34 sampel "Poison," dan 40 sampel "Electric" berhasil diklasifikasikan dengan benar. True Positive (TP) untuk masing-masing kelas menunjukkan prediksi yang akurat, sementara True Negative (TN) juga mencerminkan jumlah prediksi yang tepat di luar kelas terkait. Hasil ini menegaskan kemampuan model dalam mengklasifikasikan dataset dengan akurasi tinggi, meskipun pengujian lebih lanjut pada dataset yang lebih beragam diperlukan untuk memastikan keandalannya dalam skenario yang lebih kompleks.

Implementasi/Penerapan Model

Pasca pelatihan dan evaluasi, model CNN diimplementasikan untuk melakukan prediksi tipe Pokémon berdasarkan citra baru. Implementasi ini diwujudkan dalam fungsi `test_model_on_image` yang menerima *path* citra sebagai masukan. Fungsi tersebut akan memuat citra, melakukan *preprocessing* yang meliputi *resizing* dan normalisasi, kemudian meneruskan citra yang telah diproses ke dalam model CNN untuk memperoleh prediksi. Model CNN menghasilkan probabilitas untuk setiap kelas tipe Pokémon, dan kelas dengan probabilitas tertinggi ditetapkan sebagai prediksi akhir. Fungsionalitas ini memungkinkan model untuk diaplikasikan pada citra Pokémon yang belum pernah ditemui sebelumnya, sehingga dapat dimanfaatkan untuk identifikasi dan klasifikasi Pokémon secara otomatis.

Selain melakukan prediksi, fungsi `test_model_on_image` juga dilengkapi dengan mekanisme untuk mendeteksi citra yang tidak termasuk dalam kelas-kelas yang telah dipelajari oleh model. Mekanisme ini bekerja dengan menetapkan *threshold* probabilitas minimum agar suatu prediksi dianggap valid. Citra yang memiliki probabilitas prediksi di bawah *threshold* akan diklasifikasikan sebagai 'unknown', mengindikasikan bahwa model tidak memiliki keyakinan

yang cukup untuk mengklasifikasikan citra tersebut ke dalam salah satu kelas yang telah diketahui. Fitur ini meningkatkan keandalan model dalam menghadapi citra-citra yang berada di luar cakupan dataset pelatihan.

Predicted: Electric, Accuracy: 0.9952



Gambar menampilkan hasil prediksi sebuah model klasifikasi terhadap jenis Pokémon pada gambar tersebut. Model memprediksi bahwa Pokémon ini termasuk dalam tipe *Electric*, dengan tingkat keyakinan yang tinggi, yaitu sebesar 99,52%. Akurasi ini mencerminkan kepercayaan model yang sangat kuat terhadap hasil prediksinya. Berdasarkan atribut visual yang terlihat pada gambar, prediksi tersebut tampak relevan dan sesuai dengan karakteristik umum tipe *Electric*.

Tingkat akurasi yang tinggi menunjukkan bahwa model telah dilatih dengan baik dan mampu mengenali fitur-fitur unik dari setiap jenis Pokémon dengan akurat. Visual yang dihasilkan ini juga menjadi salah satu indikator keberhasilan model dalam mempelajari pola-pola tertentu dari dataset yang digunakan selama proses pelatihan. Dengan demikian, model ini menunjukkan performa yang sangat baik dalam klasifikasi Pokémon berdasarkan jenisnya.

5. Kesimpulan

Penelitian ini mengembangkan model klasifikasi citra Pokémon menggunakan metode Convolutional Neural Network (CNN) untuk mengenali lima tipe Pokémon, yaitu Water, Grass, Fire, Electric, dan Poison. Proses penelitian meliputi persiapan dataset, prapemrosesan citra, augmentasi data, pembagian dataset, pelatihan model, dan evaluasi kinerja. Hasil pengujian menunjukkan bahwa model mampu melakukan klasifikasi citra Pokémon, meskipun konsistensi nilai akurasi yang dilaporkan pada beberapa bagian naskah masih perlu diverifikasi sebelum hasil akhir ditetapkan.

Penggunaan augmentasi data bertujuan untuk memperkaya variasi citra selama proses pelatihan, sedangkan lapisan dropout digunakan untuk membantu mengurangi risiko overfitting. Namun, efektivitas masing-masing teknik terhadap peningkatan kinerja model belum dapat dipastikan tanpa perbandingan hasil eksperimen yang sesuai. Oleh karena itu,

evaluasi lebih lanjut diperlukan untuk memperoleh gambaran yang lebih komprehensif mengenai kemampuan generalisasi model.

Penelitian selanjutnya dapat menggunakan dataset yang lebih besar dan beragam, mengevaluasi konfigurasi arsitektur CNN yang berbeda, serta membandingkan pendekatan CNN dengan metode lain, termasuk transfer learning. Pengembangan tersebut diharapkan dapat mendukung peningkatan kinerja klasifikasi citra Pokémon dan penerapannya pada aplikasi edukasi maupun hiburan digital.

References

- Acharya, D., Aljammaz, R., Oliver, B., & Stolee, M. (2020). Gotta generate 'em all! Pokémon (with deep learning). ACM. https://creativecoding.soe.ucsc.edu/courses/cmpm202_w19/projects/GottaGenerateEmAll_ACM_Project3.pdf
- Chirra, V. R. R., Syeda, A., Kolla, N., Ghanta, N., & Muvva, S. (2023). Pokepedia: Pokémon image classification using transfer learning. *Review of Computer Engineering Studies*, 10(1), 14–19. <https://doi.org/10.18280/rces.100103>
- He, C., Li, D., & Wang, S. (2020). A lightweight convolutional neural network model for target recognition. *Journal of Physics: Conference Series*, 1651(1), Article 012138. <https://doi.org/10.1088/1742-6596/1651/1/012138>
- Kilpatrick, A. J., Ćwiek, A., & Kawahara, S. (2023). Random forests, sound symbolism and Pokémon evolution. *PLOS ONE*, 18(1), Article e0279350. <https://doi.org/10.1371/journal.pone.0279350>
- Li, X., Chen, Q., & Zhao, X. (n.d.). COMP 4901J project final report: One-shot Pokémon classification. <https://colinzhaoust.github.io/data/pokemon.pdf>
- Rozaq, A., Samudra, A., & Islam, A. (2023). Analisis desain visual karakter Kleavor dalam game Pokémon Legends: Arceus. *Jurnal Barik*, 5(1), 298–309. <https://ejournal.unesa.ac.id/index.php/IDKV/>