

PENDETEKSIAN OBJEK PADA CITRA HEWAN KARNIVORA DAN HERBIVORA MENGGUNAKAN FASTER R-CNN

¹Sherien Trisnawaty Eka Putri, ²Achmad Fahrurozi
^{1,2}Fakultas Teknologi Industri Universitas Gunadarma
Jl. Margonda Raya No. 100, Depok 16424, Jawa Barat
¹sherientrisnawaty@student.gunadarma.ac.id, ²achmad.fahrurozi12@gmail.com

Abstrak

Penelitian ini bertujuan menghasilkan sistem pendeteksian objek dengan menggunakan Faster R-CNN untuk mengklasifikasikan jenis hewan dari kelompok hewan karnivora dan herbivora berbasis citra. Pembuatan program dalam penelitian ini menggunakan Faster R-CNN dengan arsitektur Inception V2 dan Google Collab pada tahap pelatihan. Data yang digunakan yaitu 2000 citra hewan yang diambil secara random menggunakan Chrome extension dan dilabelkan secara manual. Hasil akuisisi citra memberikan variasi sudut pengambilan gambar, variasi jarak pengambilan, dan variasi jumlah objek dalam citra. Pembuatan sistem pendeteksian objek ini meliputi tahap pelatihan untuk membentuk model Faster R-CNN, tahap uji coba, dan pengukuran performa sistem pendeteksian objek yang dihasilkan. Berdasarkan hasil implementasi dan uji coba, disimpulkan bahwa sistem ini dapat mengklasifikasikan jenis hewan karnivora dan herbivora dengan total loss model hasil pelatihan berada pada 0.06 dan rata-rata tingkat akurasi sebesar 89%. Hasil perhitungan Recall dan Precision menunjukkan bahwa performa dari sistem klasifikasi yang dihasilkan sangat baik, dengan nilai Recall 100% terdapat pada kelompok citra hewan Cheetah, Eagle, Komodo, Shark, Tiger, Bull, Guineapig, dan Zebra.

Kata Kunci: Deteksi Objek, Hewan Karnivora, Hewan Herbivora, Faster R-CNN, Inception V2.

Abstract

This study aims to build an object detection system using Faster R-CNN to classify the types of animals from the image-based group of carnivores and herbivores. Programming in this research uses Faster R-CNN with Inception V2 architecture and Google Collab at the training stage. The data used are 2000 animal images, taken randomly using a Chrome extension and labeled manually. Image acquisition results provide variations in the angle of shooting, variations in the distance taken, and variations in the number of objects in the data image. The construction of this object detection system includes the training step to build the Faster R-CNN model, the testing step, and measuring the performance of the resulting object detection system. Based on the results of implementation and testing, it is concluded that this system can classify the types of carnivores and herbivores with the total loss of the training model at 0.06 and an average accuracy rate of 89%. The results of the Recall and Precision calculations show that the performance of the resulting classification system is very good, with a 100% Recall value found in the animal image group of Cheetah, Eagle, Komodo, Shark, Tiger, Bull, Guineapig, and Zebra.

Keywords: Object detection, Carnivorous animal, Herbivorous animal, Faster R-CNN, Deep Learning.

PENDAHULUAN

Pengelompokkan hewan berdasarkan jenis makanannya terbagi menjadi 3 kelompok besar, yaitu kelompok hewan herbivora, karnivora, dan omnivora. Hewan yang masuk ke dalam kelompok hewan herbivora yaitu hewan-hewan pemakan tumbuhan. Contoh hewan herbivora diantaranya Gajah (*elephant*), Jerapah (*giraffe*), Unta (*camel*), Kuda Nil (*hippopotamus*), dan Badak (*rhinoceros*). Kelompok hewan karnivora yaitu hewan pemakan daging atau pemakan hewan lain seperti Harimau (*tiger*), Macan Tutul (*cheetah*), Singa (*lion*) dan Buaya (*crocodile*). Sementara kelompok hewan omnivora yaitu hewan pemakan tumbuhan dan pemakan hewan lain. Omnivora sering disebut hewan pemakan segalanya seperti ayam (*chicken*), bebek (*duck*), dan tikus (*mouse*).

Pendeteksi objek (*object detection*) adalah suatu teknologi untuk mengenali suatu object dari suatu gambar maupun video. Pendeteksian objek merupakan teknologi komputer yang berkaitan dengan *computer vision* dan *image processing* yang berhubungan dengan mendeteksi suatu objek dalam citra digital berdasarkan warna maupun bentuk objek. Algoritma *object detector* modern yang banyak digunakan dalam pengenalan citra adalah Convolutional Neural Network (CNN) dan pengembangannya. Penggunaan algoritma CNN dan pengembangannya dalam penelitian terkait analisa citra telah banyak dilakukan,

diantaranya dalam pengenalan citra wajah [1], [2], ekspresi wajah [3], prediksi usia dan jenis kelamin berbasis citra wajah [4], identifikasi nominal uang logam [5], hingga klasifikasi buah [6], [7], [8].

Penelitian terkait sistem pengenalan hewan telah dilakukan oleh Tibor, T., dkk [9], menggunakan beberapa algoritma, diantaranya PCA (Principal Components Analysis), LDA (Linear Discriminant Analysis), LBPH (Local Binary Pattern Histogram), SVM (Support Vector Machines), dan CNN (Convolutional Neural Network). Hasil eksperimennya menunjukkan bahwa CNN memberikan tingkat akurasi terbaik dibanding algoritma lainnya, yakni sebesar 98%. Data citra yang digunakan dalam penelitian tersebut memiliki variasi dalam kondisi pencahayaan yang berbeda, diambil dalam posisi depan dengan toleransi untuk sedikit gerakan samping. Faster R-CNN merupakan teknik pengenalan objek hasil pengembangan CNN yang dikembangkan oleh Ross Girshick dkk pada tahun 2015 [10].

Algoritma Faster R-CNN diklaim mampu mengeliminasi waktu training dalam jumlah besar, karena Faster R-CNN mengeliminasi algoritma selective search untuk mencari region proposal, di mana Faster R-CNN hanya butuh 300 proposal per citra sementara R-CNN and Fast R-CNN memerlukan 2000 proposal [11]. Fino, C., dkk [12] menggunakan Faster R-CNN untuk pengenalan jenis burung Lovebird. Pada penelitian tersebut digunakan data citra hewan

yang memiliki lebih banyak variasi, diantaranya variasi sudut pengambilan gambar, variasi jarak pengambilan, dan variasi jumlah objek dalam citra. Jumlah data citra burung yang digunakan adalah 800 citra, terdiri dari 8 kelas, di mana masing-masing kelas memuat 100 citra. Lavin J. H. dkk [13] mengklaim bahwa Inception V2 merupakan arsitektur CNN yang memiliki akurasi tinggi, menggunakannya untuk mendeteksi wajah dari frame CCTV. Derry dan Muhammad [14] menggunakan Faster R-CNN dengan arsitektur Inception V2 untuk mendeteksi ujung jari. Penelitian ini dibatasi pada citra dengan latar belakang homogen, memberikan tingkat akurasi tingkat akurasi 90%, 91%, 94% dan 92% dari 4 fase pelatihan yang berbeda.

METODE PENELITIAN

Metodologi penelitian yang diterapkan dalam penelitian ini dibagi menjadi tiga tahap utama, yaitu:

1. Tahap pelatihan (*training*) dengan algoritma *Faster R-CNN*, menggunakan *framework TensorFlow Object Detection* dengan *platform GPU*, menggunakan *Google Collab* saat proses *training*.
2. Tahap pengujian terhadap data uji, yaitu mengklasifikasikan jenis hewan Karnivora dan hewan Herbivora berdasarkan hasil pelatihan terhadap data latih.
3. Tahap analisa performa dari sistem pendeteksian objek hewan yang dihasilkan.

Gambaran Umum Metode Penelitian yang Digunakan

Penyusunan data melibatkan proses pengumpulan data, kemudian membuat anotasi data, lalu mengubahnya menjadi format TFRecord biner yang berguna sebagai masukan untuk proses pelatihan. Dalam pelatihan dilakukan proses pembuatan model, konfigurasi file config, dan pendefinisian kelas objek hewan Karnivora dan Herbivora diperlukan. Proses pelatihan dilakukan menggunakan framework Tensorflow API *Object Detection* dan metode *Faster R-CNN*. Setelah itu dilakukan pengujian pengenalan hewan Karnivora dan hewan Herbivora dengan hasil data uji dengan menggunakan model yang telah dilatihkan pada data latih citra itu sendiri. Terakhir adalah analisa pengujian yang telah dilakukan.

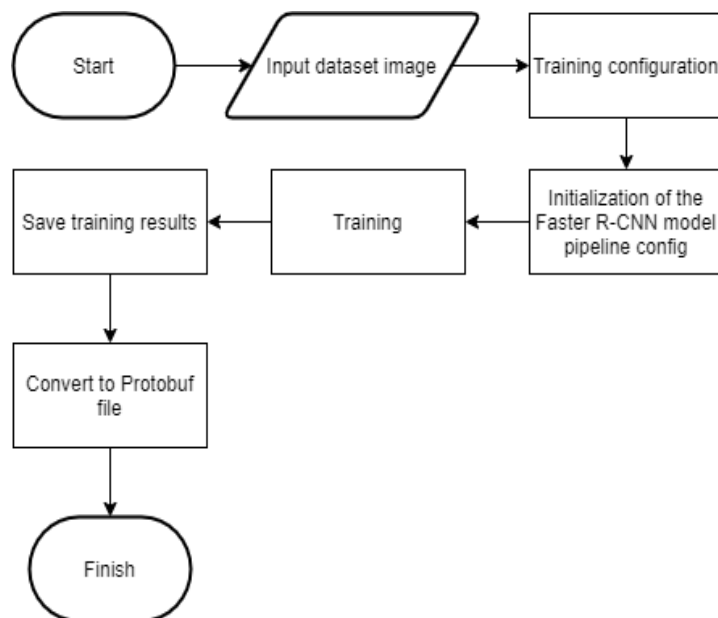
Proses Pelatihan

Diagram alir ini menampilkan alur proses pelatihan pada dataset yang diinput oleh pengguna. Lebih jelasnya bisa dilihat pada Gambar 1 yang menyajikan *Flowchart* dari proses Pelatihan. *Flowchart* pada Gambar 1 menunjukkan proses pelatihan pada sebuah dataset yang diawali dengan menginput dataset gambar yang telah diberi label atau dianotasi dengan 20 klasifikasi kelas yaitu hewan Karnivora dan Herbivora, berdasarkan jenis hewan masing-masing 10 jenis Hewan Karnivora dan 10 jenis hewan Herbivora. Selanjutnya dilakukan proses konfigurasi pelatihan dengan memasukkan ukuran batch,

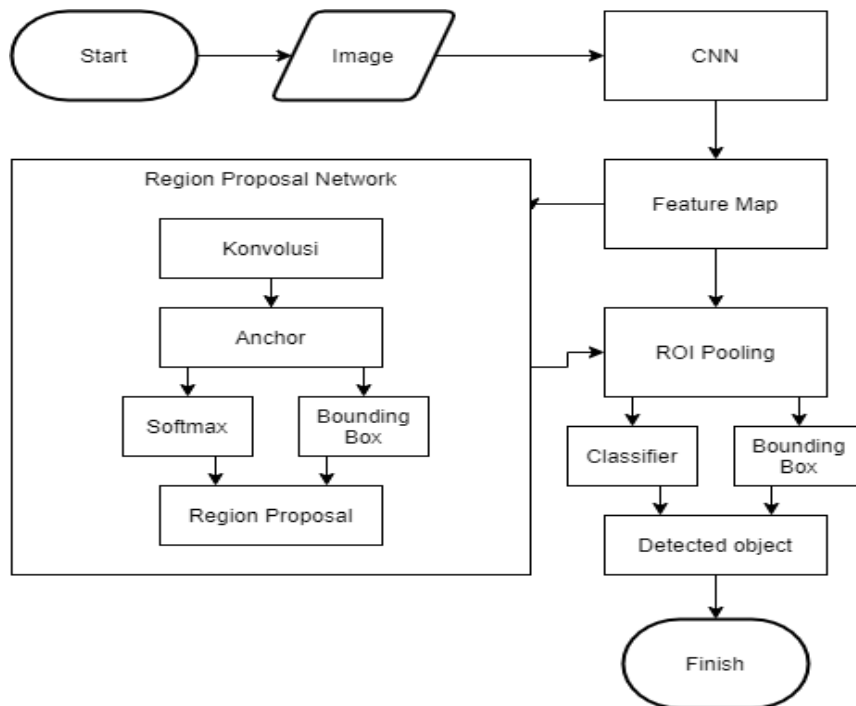
langkah-langkah dan konfigurasi jalur untuk melakukan konfigurasi pelatihan. Ukuran batch yang digunakan adalah 1, untuk jumlah langkah yang akan diambil pada proses pelatihan sebanyak 50.000 langkah, sedangkan untuk jalur penyesuaian *mengatur* semua file yang ada di komputer atau laptop. Pada tahap berikutnya, inialisasi pipeline training model *Faster Recurrent Convolutional Neural Network* (Faster R-CNN) digunakan dalam proses pelatihan. Algoritma yang digunakan dalam penelitian ini adalah *Faster R-CNN* dengan arsitektur *Inception V2* sebagai model untuk proses *Transfer Learning* dan *Fine Tuning*. *Inception V2* digunakan karena dapat mengurangi kompleksitas jaringan konvolusi, di mana modul ini membuat jaringan

konvolusi tidak menjadi lebih dalam, namun lebih meluas [14].

Saat proses pelatihan sedang berjalan, hasilnya akan disimpan dalam bentuk file *.ckpt* atau langkah pemeriksaan yang akan otomatis disimpan setiap 10 menit selama proses pelatihan berjalan. Pada akhirnya file *.ckpt* akan diubah menjadi file grafik dengan format *.Pb* (Protobuf) sehingga dapat dijalankan untuk proses deteksi dan klasifikasi pada sistem. Proses selanjutnya adalah proses pelatihan dataset yang telah diproses untuk mendeteksi objek seperti hewan Karnivora dan Herbivora. Berikut adalah gambaran alur proses yang terjadi selama proses pelatihan. Gambar 2 menyajikan *Flowchart* pelatihan data menggunakan Faster R-CNN.



Gambar 1. Flowchart dari Proses Pelatihan



Gambar 2. Flowchart Pelatihan Data Menggunakan Faster R-CNN.

Berikut adalah keterangan dari Gambar 2 di atas:

1. Citra masukan memuat semua citra dalam himpunan latih yang telah dianotasi atau diberi label sebelum melalui proses konvolusi pada model CNN. Proses ini berlangsung menggunakan fungsi aktivasi ReLU dan operasi MaxPolling.
2. Hasil konvolusi oleh CNN selanjutnya akan melalui proses Region Proposal Network (RPN), yaitu proses memisahkan latar belakang dari objek untuk menghasilkan sekumpulan wilayah yang dideteksi menjadi objek yang dimaksud.
3. Proses ROI Pooling akan memperkecil ukuran area pada *feature maps* dari hasil proses RPN.
4. Hasil dari proses ROI Pooling diklasifikasikan dan menghasilkan kotak pembatas (*bounding box*) untuk citra jenis

hewan karnivora dan hewan herbivora beserta keterangan dari objeknya.

Alur proses deteksi objek berbasis citra yang dihasilkan pada penelitian ini diawali dengan input gambar yang akan digunakan untuk mendeteksi objek hewan Karnivora dan Herbivora, kemudian sistem akan membaca input gambar yang dimasukkan untuk kemudian diproses untuk mendeteksi objek yang terdapat didalamnya gambar. Selanjutnya dilakukan pemanggilan hasil proses pelatihan yang telah diubah menjadi file protobuf dan memanggil labelmap untuk mendapatkan definisi label untuk deteksi objek.

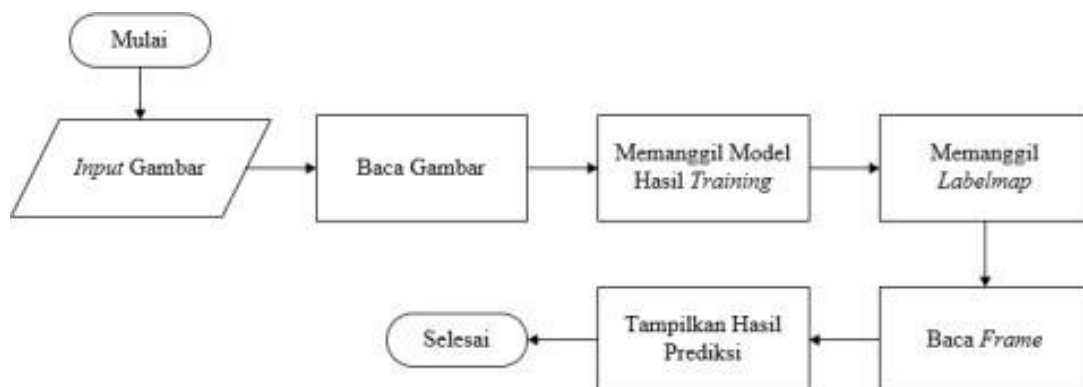
Tahapan selanjutnya sistem akan membaca frame pada gambar yang telah diinput kemudian menampilkan hasil deteksi dari objek yang dideteksi. Gambar 3 menyajikan *flowchart* proses deteksi objek berbasis citra yang dihasilkan pada penelitian

ini. Hasil deteksi yang didapatkan yaitu citra baru dengan menampilkan *output* keterangan pada citra baru tersebut. Hasilnya dapat berupa matriks sesuai dengan parameter yang digunakan. Parameter pengujian yang digunakan dalam penelitian ini diantaranya adalah tingkat Akurasi, *Recall*, dan *Precision* berdasarkan *confusion matrix* hasil klasifikasi. Secara umum, *confusion matrix* merupakan tabel berdimensi dua yang terdiri dari data prediksi dan data aktual berdasarkan kelas masing-masing, dimana data prediksi terletak pada bagian baris dan data aktual terletak pada bagian kolom, sebagaimana disajikan pada Tabel 1 [15]. Berdasarkan Tabel 1, maka

Akurasi dapat dinyatakan sebagai hasil pembagian antara data yang diprediksi dengan benar (TP ditambah TN) dan jumlah seluruh data uji. Sementara *Precision* dan *Recall* dihitung berdasarkan nilai positif benar (TP), positif palsu (FP), dan negatif palsu (FN). *Precision* adalah banyaknya prediksi kelas positif dari semua kelas positif, dinyatakan oleh persamaan (1), sedangkan *Recall* adalah jumlah prediksi kelas positif yang dibuat dari semua hasil prediksi, dinyatakan oleh persamaan (2) [16].

$$Precision = \frac{TP}{(TP+FP)} \quad (1)$$

$$Recall = \frac{TP}{(TP+FN)} \quad (2)$$



Gambar 3. Flowchart Proses Deteksi Objek Berbasis Citra.

Tabel 1. Confusion Matrix

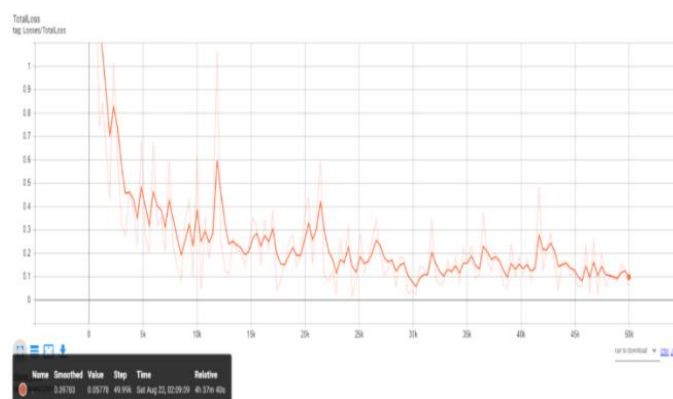
	Aktual Positif	Aktual Negatif
Prediksi Positif	True Positive (TP)	False Negative (FN)
Prediksi Negatif	False Positive (FP)	True Negative (TN)

HASIL DAN PEMBAHASAN

Hasil Pelatihan Data Latih

Pada penelitian ini dilakukan beberapa uji coba nilai parameter untuk pembentukan model Faster R-CNN yang digunakan. Berdasarkan hasil uji coba, diperoleh hasil pelatihan terbaik sebagai berikut:

1. Model yang terbentuk adalah model hasil pelatihan dengan jumlah 50.000 *steps* dengan *batch size* yaitu berupa *graph inference* yang terdiri dari *file checkpoint*, *frozen_inference_graph.pb*, dan terdapat 3 file *model-ckpt* yang masing-masing berekstensi *.data-00000-of-00001*, *.index*, dan *.meta* yang diletakkan dalam satu direktori yang sama dan digunakan untuk melakukan pengujian model pada saat melakukan pendeteksian objek.
2. Grafik *total loss* model hasil pelatihan yang berada pada 1.5 hingga 0.06, disajikan pada Gambar 4, menunjukkan nilai kehilangan pada proses pelatihan semakin kecil dan mampu memperbaiki hasil deteksi.



Gambar 4. Grafik *Total Loss* dengan 50.000 *Steps*

Hasil Pengujian Data Uji

Tahap selanjutnya adalah proses pengujian hasil deteksi terhadap data uji berbasis data latih yang telah dilatih dengan menggunakan metode *Machine Learning*. Adapun pengujian yang dilakukan dengan cara membandingkan hasil deteksi data uji oleh sistem yang dibuat dengan label dari data uji yang dilabelkan secara manual.

Hasil perhitungan tingkat akurasi didapatkan rata-rata sebesar 89%, sehingga performa pengklasifikasian jenis hewan Karnivora dan Herbivora oleh sistem dapat dikategorikan baik. Parameter performa lainnya, yaitu *Recall* dan *Precision* juga memberikan hasil perhitungan yang baik, di mana terdapat kelompok citra hewan dengan nilai pada *recall* adalah 1 atau 100%. Kelompok citra hewan yang memiliki nilai *Recall* sebesar 100% diantaranya adalah objek hewan *Cheetah*, *Eagle*, *Komodo*, *Shark*, *Tiger*, *Bull*, *Guinepig*, dan *Zebra*. Gambar 5 menyajikan *output* deteksi pada salah satu jenis hewan karnivora, sementara Gambar 6 menyajikan *output* deteksi pada salah satu jenis hewan herbivora.



Gambar 5. *Output* Deteksi Pada Salah Satu Jenis Hewan Karnivora



Gambar 6. *Output* Deteksi Pada Salah Satu Jenis Hewan Herbivora

Tabel 2. Rangkuman Tingkat Akurasi Deteksi Objek Hewan Karnivora dan Herbivora
Kelompok Hewan

Karnivora		Herbivora	
Jenis Hewan	Akurasi	Jenis Hewan	Akurasi
Bear	90%	Bull	90%
Cheetah	95%	Camel	70%
Crocodile	100%	Elephant	80%
Eagle	80%	Giraffe	80%
Komodo	80%	Guineapig	95%
Lion	95%	Hippopotamus	95%
Shark	80%	Koala	100%
Tiger	90%	Rhinoceros	90%
Whale	90%	Tapir	100%
Wolf	95%	Zebra	70%

Akurasi Rata-Rata = 89%

Dapat dilihat pada Gambar 5 dan Gambar 6, bahwa sistem pendeteksian objek yang dibangun memberikan *output* berupa objek hewan yang ditandai dengan *bounding box* disertai nama jenis hewan dan kelompoknya, apakah karnivora atau herbivora. pada Gambar 6, dapat dilihat bahwa sistem dapat mendeteksi objek hewan dengan

cukup akurat, walaupun terdapat objek lain berupa manusia dalam citra yang sama. Tabel 2 merangkum ketepatan hasil deteksi objek dari sistem yang dihasilkan pada penelitian ini.

Berdasarkan Tabel 2 diperoleh bahwa tingkat akurasi tertinggi dimiliki oleh citra hewan dari jenis Crocodile (Buaya), Koala, dan Tapir, yakni sebesar 100%. Sementara

tingkat akurasi terendah dimiliki oleh citra hewan dari jenis Camel (Unta) dan Zebra, dengan akurasi sebesar 70%. Perhitungan akurasi rata-rata untuk semua citra uji memberikan hasil 89%, sehingga performa dari sistem pendeteksian objek yang dibangun dalam penelitian ini cukup menjanjikan.

Analisa Hasil Uji Coba Berdasarkan False Rate

Analisa yang dilakukan adalah analisis terhadap kesalahan atau *error* yang didapatkan pada hasil identifikasi jenis hewan, baik itu untuk kelompok hewan karnivora ataupun kelompok hewan herbivora. *Error* yang diamati ini dibagi menjadi dua, yaitu *positive false rate* dan *negative false rate*. *Positive false rate* adalah kesalahan dalam mengenali data uji, dimana hasilnya tidak menunjukkan label yang sebenarnya dari data uji tersebut. Sedangkan *negative false rate* adalah kesalahan dalam pendeteksian objek dalam data uji, dimana hasilnya tidak mendeteksi objek yang seharusnya dideteksi. Pada analisa

hasil uji coba dari penelitian ini, terdapat dua *positive false rate* yang terjadi, yaitu salah mengidentifikasi objek dan mengidentifikasi dua objek. Salah mengidentifikasi objek disebabkan karena objek tersebut memiliki sedikit kemiripan dengan objek lain. Gambar 7 menyajikan kasus kesalahan mengidentifikasi objek yang terjadi dalam eksperimen ini.

Dapat dilihat pada Gambar 7 bahwa anak gajah salah diidentifikasi sebagai *Rhinoceros* (Badak) dalam eksperimen. Hal ini diduga karena pada gambar tersebut posisi dan penampakan anak gajah dari sudut pengambilan gambar memiliki kemiripan dengan Badak. Pada penelitian ini tidak terdapat kasus *negative false rate*, yaitu kesalahan sistem pendeteksian objek berupa tidak mendeteksi objek yang diinginkan. Artinya sistem yang dibangun pada penelitian ini selalu dapat mendeteksi objek hewan yang ada dalam citra uji. Kesalahan hanya terjadi pada identifikasi jenis hewan yang terdeteksi oleh sistem.



Gambar 7. Contoh citra Uji yang Mengalami Kesalahan Identifikasi Objek

KESIMPULAN DAN SARAN

Berdasarkan hasil analisis yang telah dilakukan, diperoleh bahwa tingkat akurasi rata-rata dari sistem pendeteksi citra hewan karnivora dan herbivora yang dihasilkan adalah sebesar 89%. Berdasarkan hasil *Recall* dan *Precision* yang didapatkan, maka performa sistem termasuk dalam kategori baik, dengan nilai pada *Recall* 100% terdapat pada objek hewan *Cheetah*, *Eagle*, *Komodo*, *Shark*, *Tiger*, *Bull*, *Guineapig*, dan *Zebra*. Berdasarkan penelitian yang telah dilakukan, maka dapat diberikan beberapa saran sebagai berikut:

1. Menambahkan jumlah *dataset* dan ragam objek pada gambar untuk melatih model maupun menambah jumlah pada langkah pelatihan hingga mencapai akurasi yang lebih tinggi.
2. Mengembangkan kembali pengenalan objek dengan fokus untuk mendeteksi hewan karnivora dan herbivora menggunakan model atau arsitektur yang lainnya, ataupun mengembangkan klasifikasi secara realtime baik itu menggunakan *webcam* atau video.
3. Menggunakan spesifikasi perangkat yang lebih tinggi yaitu dengan menggunakan komputer dengan *Random Access Memory (RAM)* yang tinggi dan menggunakan *Graphics Processing Unit (GPU)* untuk mempercepat proses pelatihan.
4. *Output* yang dihasilkan dari sistem

dalam penelitian ini masih berupa *text*, sehingga untuk pengembangan selanjutnya dapat ditambahkan *output* berupa suara (*voice*) yang memuat jenis hewan dan makanannya.

DAFTAR PUSTAKA

- [1] M. Zufar dan B. Setiyono, "Convolutional Neural Networks untuk Pengenalan Wajah Secara Real-Time", *Jurnal Sains dan Seni ITS*, Vol. 5 (2), hal. 72-77, 2016.
- [2] H. Abhirawa, Jondri, dan A. Arifianto, "Pengenalan Wajah Menggunakan Convolutional Neural Network" e-Proceeding of Engineering: Vol. 4 (3), Desember 2017, hal. 4907-4916.
- [3] P. A. Nugroho, I. Fenriana, dan R. Arijanto, "Implementasi Deep Learning Menggunakan Convolutional Neural Network (CNN) Pada Ekspresi Manusia", *Jurnal ALGOR*, Vol. 2 (1), hal. 12-21, 2020.
- [4] A. Zein, "Memprediksi Usia dan Jenis Kelamin Menggunakan Convolutional Neural Networks", *Sainstech*, Vol. 30 (1), hal. 1-7, 2020.
- [5] R. A. Doga, H. F. J. Lami, dan S. I. Pella, "Sistem Identifikasi Nominal Uang Logam Menggunakan Tensorflow dan Convolutional Neural Network Berbasis Raspberry PI", *Seminar Nasional Sains dan Teknik Fst Undana (SAINSTEK)*, 25 Oktober 2019, hal. 503-511.

- [6] S. Juliansyah dan A. D. Laksito, “Klasifikasi Citra Buah Pir Menggunakan Convolutional Neural Networks”, *InComTech: Jurnal Telekomunikasi dan Komputer*, Vol. 11 (1), hal. 65-72, 2021.
- [7] F. F. Maulana dan N. Rochmawati, “Klasifikasi Citra Buah Menggunakan Convolutional Neural Network”, *Journal of Informatics and Computer Science (JINACS)*, Vol. 1 (2), hal. 104-108, 2019.
- [8] T. D. Antoko, M. A. Ridani, dan A. E. Minarno, “Klasifikasi Buah Zaitun Menggunakan Convolution Neural Network”, *Komputika: Jurnal Sistem Komputer*, Vol. 10 (2), hal. 119 – 126, 2021.
- [9] T. Trnovszky, P. Kamencay, R. Orjesek, M. Benco, dan P. Sykora, “Animal Recognition System Based on Convolutional Neural Network”, *Advances In Electrical And Electronic Engineering*, Vol. 15 (3), hal. 517-525, 2017.
- [10] R. Gandhi, “R-CNN, Fast R-CNN, Faster R-CNN, YOLO — Object Detection Algorithms”, 2018, <https://towardsdatascience.com/r-cnn-fast-r-cnn-faster-r-cnn-yolo-object-detection-algorithms-36d53571365e>, 5 November 2021.
- [11] Y. Rizki, R. M. Taufiq, D. Putri, dan H. Mukhtar, “Klasifikasi Pola Kain Tenun Melayu Menggunakan Faster R-CNN”, *IT Journal Research and Development (ITJRD)*, Vol. 5 (2), hal. 215-225, 2021.
- [12] F. Charli, H. Syaputra, M. Akbar, S. Sauda, dan F. Panjaitan, “Implementasi Metode Faster Region Convolutional Neural Network (Faster R-CNN) Untuk Pengenalan Jenis Burung Lovebird”, *Journal of Information Technology Ampera*, Vol. 1 (3), hal. 185-197, 2020.
- [13] L. J. Halawa, A. Wibowo, dan F. Ernawan, “Face Recognition Using Faster R-CNN with Inception-V2 Architecture for CCTV Camera”, 2019 3rd International Conference on Informatics and Computational Sciences (ICICoS), 29-30 Oktober 2019, hal. 1-6.
- [14] Derry Alamsyah dan Muhammad Fachrurrozi, “Faster R-CNN with Inception V2 for Fingertip Detection in Homogenous Background Image”, *IOP Conf. Series: Journal of Physics: Conf. Series*, 1196 (012017), hal. 1–6, 2019.
- [15] L. A. Septiandi, E. M. Yuniarno, dan A. Zaini, “Deteksi Kedipan dengan Metode CNN dan Percentage of Eyelid Closure (PERCLOS)”, *Jurnal Teknik ITS*, Vol. 10 (1), hal. A56-A63, 2021.
- [16] P. M. Pavithra dan R. Bhavani, “Object Detection and Classification Using YOLO V3”, *International Research Journal of Engineering and Technology (IRJET)*, Vol. 8 (3), hal. 153-158, 2021.