

Klasifikasi Jenis Gonggong Melalui Pendekatan Pengenalan Objek Berbasis MobileNet-SSD

Muhammad Noval¹, Marcel Wangnandra², Rido Ramadhan³, M Afief Anugrah⁴, Faiz Arrafi⁵, Nurul Hayaty^{6*}

^{1,2,3,4,5,6}Jurusan Teknik Informatika, FTTK, Universitas Maritim Raja Ali Haji

^{1,2,3,4,5,6}Jl. Politeknik Senggarang, Tanjungpinang 29100

*Corresponding Author: nurul.hayaty@umrah.ac.id

Abstract — Gonggong is a type of sea snail that is commonly consumed and has become an icon of the culinary specialties of the Riau Islands Province. The most commonly recognized and consumed types in the Riau Islands are *Laevistrombus turturella* and *Strombus canarium*. These two types of gonggong have similar physical characteristics and can be difficult to distinguish. Therefore, this research was conducted to find a practical solution that can classify types of gonggong based on their visual images. This study uses a real-time object detection approach based on the MobileNet SSD framework implemented in TensorFlow and applied to an Android-based mobile application. The dataset used consists of 418 images of both types of gonggong that have been augmented with and without backgrounds. The results of the tests show that the model has a confidence level of 83% for images without backgrounds, and 67% for images with backgrounds. These findings indicate that the method used has the potential for further development to improve the model's confidence level in classifying types of gonggong.

Keywords—Gonggong, Classification, MobileNet SSD

Intisari— Gonggong merupakan salah satu jenis siput laut yang sering dikonsumsi dan menjadi ikon kuliner khas daerah Provinsi Kepulauan Riau. Jenis yang paling umum dikenali dan dikonsumsi di daerah Kepulauan Riau adalah *Laevistrombus turturella* dan *Strombus canarium*. Kedua jenis gonggong tersebut memiliki ciri fisik yang serupa dan sulit untuk dibedakan. Oleh karena itu, penelitian ini dilakukan untuk menemukan solusi praktis yang dapat mengklasifikasi jenis gonggong berdasarkan citra visualnya. Penelitian ini menggunakan pendekatan deteksi objek secara real-time berbasis MobileNet SSD framework yang diimplementasikan dalam TensorFlow dan diterapkan pada aplikasi mobile berbasis Android. Dataset yang digunakan terdiri dari 418 citra kedua jenis gonggong yang telah diaugmentasi dengan dan tanpa latar belakang. Hasil pengujian menunjukkan bahwa model memiliki tingkat kepercayaan sebesar 83% untuk citra tanpa latar belakang, dan 67% untuk citra dengan latar belakang. Temuan ini mengindikasikan bahwa metode yang digunakan memiliki potensi untuk dikembangkan lebih lanjut guna meningkatkan tingkat kepercayaan model dalam klasifikasi jenis gonggong.

Kata kunci— Gonggong, Klasifikasi, MobileNet SSD.

I. PENDAHULUAN

yang menjadi kuliner khas sekaligus ikon budaya di Kepulauan Riau [1]. Hewan laut ini memiliki berbagai jenis yang dapat dibedakan

berdasarkan bentuk cangkang, ukuran, dan pola warnanya. Namun, dalam praktik sehari-hari, identifikasi jenis gonggong masih dilakukan secara manual oleh nelayan atau pedagang

berdasarkan pengalaman pribadi, yang rawan kesalahan dan tidak konsisten [1].

Seiring perkembangan zaman dan kemajuan teknologi kecerdasan buatan (*Artificial Intelligence*), khususnya dalam bidang pengolahan citra (*image recognition*), kini dimungkinkan untuk mengklasifikasikan objek secara otomatis dengan tingkat akurasi yang tinggi. Salah satu metode yang banyak digunakan adalah *Single Shot MultiBox Detector* (SSD), sebuah arsitektur deteksi objek yang efisien dan cepat [2]. Jika dipadukan dengan MobileNet sebuah model jaringan syaraf tiruan yang ringan dan cepat untuk perangkat seluler maka akan diperoleh sistem klasifikasi objek yang efisien serta dapat dioperasikan bahkan pada perangkat dengan keterbatasan daya komputasi seperti smartphone [3].

Penggunaan metode MobileNet SSD dalam mengklasifikasikan jenis gonggong diharapkan dapat menjadi solusi yang praktis, akurat, dan modern dalam membantu nelayan, pedagang, maupun peneliti dalam mengidentifikasi jenis gonggong secara cepat. Sistem ini juga memiliki potensi untuk dikembangkan lebih lanjut menjadi aplikasi berbasis mobile yang dapat digunakan secara langsung di lapangan.

Dengan demikian, penelitian ini menjadi relevan dalam konteks pelestarian biodiversitas lokal, modernisasi sektor perikanan dan kuliner, serta memberikan kontribusi terhadap pengembangan teknologi pengenalan objek berbasis kecerdasan buatan di Indonesia, khususnya pada spesies endemik siput laut yang hingga kini belum banyak mendapat perhatian dalam bidang teknologi informasi

II. LANDASAN TEORI

2.1 Gonggong

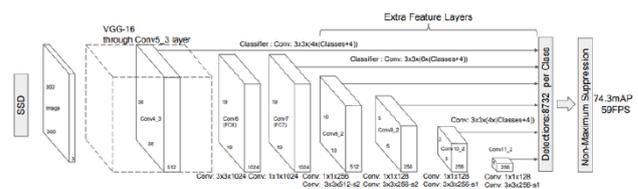
Penulis melakukan studi literatur dari jurnal-jurnal Gonggong atau siput laut merupakan makanan laut yang hanya bisa ditemukan di perairan sekitar Kepulauan Riau, yang menjadi makanan khas di Kepulauan Riau [4].

2.2 MobileNet

MobileNet adalah kelas model yang dirancang khusus untuk aplikasi visi *mobile* dan *embedded* yang menggunakan arsitektur yang disederhanakan dengan *depthwise separable convolutions* untuk membangun *neural networks* yang ringan [5].

2.3 Single Shot MultiBox Detector (SSD)

SSD adalah singkatan dari Single Shot MultiBox Detector, yaitu sebuah metode untuk mendeteksi objek pada gambar menggunakan jaringan syaraf dalam satu tahap. Dengan SSD, dapat dengan mudah dan akurat mengidentifikasi objek dari berbagai ukuran dan bentuk, tanpa perlu proposal objek atau tahap resampling yang kompleks. Berikut adalah arsitektur MobileNet SSD.



Gambar 1. Arsitektur MobileNet SSD

Arsitektur ini diawali dengan lapisan konvolusi 3x3 untuk dilakukan ekstraksi fitur lokal dari gambar input. Proses ini dilanjutkan oleh lapisan Depthwise Convolution 3x3 yang melakukan secara terpisah pada setiap saluran input untuk menangkap informasi yang mendalam dari tiap fitur. Kemudian, lapisan konvolusi 1x1 digunakan untuk menggabungkan hasil dari saluran tersebut dan mereduksi dimensi data. Kombinasi ini dilakukan secara berulang, agar membentuk hierarki fitur yang semakin kompleks, sehingga model mampu mengenali pola-pola yang bersifat lebih abstrak dan kontekstual [6].

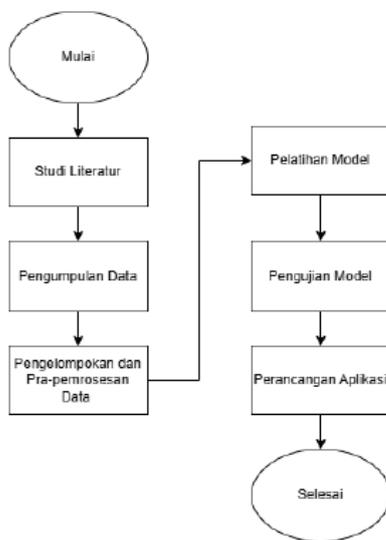
Setelah serangkaian proses konvolusi, selanjutnya lapisan Average Pooling digunakan untuk merata-ratakan informasi dari fitur yang telah diproses sebelumnya, yang menghasilkan representasi global dari citra. Informasi ini kemudian diteruskan ke lapisan Fully Connected untuk penyatuan akhir, dan terakhir diproses oleh

fungsi aktivasi Softmax untuk menghasilkan probabilitas dari masing-masing kelas objek yang terdeteksi. Dengan desain arsitektur ini, SSD Mobilenet dapat menjalankan proses deteksi objek secara efisien dan juga akurat [6].

III. HASIL DAN PEMBAHASAN

3.1 Metodologi Penelitian

Metode penelitian merupakan bagian yang berisi tahapan-tahapan yang dilakukan selama penelitian berlangsung. Berikut merupakan tahapan penelitian yang digambarkan dalam bentuk diagram alir pada gambar berikut.



Gambar 2. Metode Penelitian

Berdasarkan diagram alir diatas, penulis terlebih dahulu melakukan studi literatur untuk memperoleh pemahaman yang mendalam mengenai topik penelitian, mengidentifikasi permasalahan yang relevan, serta merumuskan landasan teori yang mendukung proses analisis dan pengembangan dalam penelitian ini. Selanjutnya penulis mengumpulkan data citra gonggong yang kemudian dikelompokkan dan diproses sehingga dapat digunakan untuk melatih model pengenalan objek Mobilenet SSD. Model yang telah dibangun kemudian diuji untuk melihat akurasi model. Model yang telah diuji akan diimplementasikan ke dalam aplikasi mobile.

3.2 Pengumpulan Data

Pada penelitian ini, data diperoleh melalui kegiatan pemotretan terhadap objek gonggong yang dilakukan langsung oleh peneliti. Sebanyak 400 citra gonggong berhasil dihimpun sebagai bahan analisis. Proses pengambilan gambar dilakukan dengan memanfaatkan pencahayaan alami serta variasi sudut pemotretan untuk menghasilkan data yang beragam. Seluruh citra diambil menggunakan satu jenis kamera smartphone guna menjaga konsistensi kualitas gambar yang dihasilkan.

Dari 400 gambar citra yang berhasil dihimpun, 88 diantaranya merupakan jenis *Laevistrombus turturella* dan sisanya merupakan jenis *Strombus canarium*. Dikarenakan adanya ketidakseimbangan jumlah data, maka peneliti memutuskan untuk menggunakan 120 citra *Strombus canarium* dengan 88 citra *Laevistrombus turturella*, sehingga total data citra yang didapatkan oleh peneliti adalah sebanyak 208 data.

Selanjutnya, dilakukan proses augmentasi untuk menambah jumlah dan variasi data. Teknik augmentasi yang diterapkan oleh peneliti adalah penghapusan latar belakang pada citra, sehingga setiap gambar memiliki dua versi, yaitu versi yang memiliki dan tanpa latar belakang. Hasil dari proses ini menghasilkan total 416 citra. Dari jumlah tersebut, 80% digunakan sebagai data pelatihan, sedangkan 20% sisanya digunakan sebagai data pengujian.

3.3 Pelabelan Data

Citra yang telah berhasil dikumpulkan selanjutnya akan melalui tahap pra-pemrosesan sebagai persiapan untuk digunakan dalam proses pelatihan model. Salah satu tahapan dalam proses ini adalah pelabelan objek, di mana setiap objek gonggong dalam citra akan diberi anotasi secara manual dalam bentuk kotak pembatas (*bounding box*). *Bounding box* ini menandai area citra yang mengandung objek gonggong, sehingga model dapat secara terarah memfokuskan proses pembelajarannya pada bagian tersebut. Melalui anotasi ini, model akan mampu mengenali pola visual, seperti bentuk, ukuran, warna, serta

tekstur yang menjadi ciri khas dari masing-masing jenis gonggong.

3.4 Pelatihan model

Dalam penelitian ini, peneliti melakukan proses pelatihan menggunakan *framework TensorFlow* untuk melatih model pembelajaran dalam (*deep learning*) yang ditujukan untuk mendeteksi dan mengklasifikasikan jenis gonggong. Model yang digunakan adalah MobileNet SSD yang merupakan arsitektur pembelajaran mesin yang menggabungkan MobileNet sebagai komponen ekstraksi fitur dengan SSD yang merupakan komponen pengenalan dan deteksi objek secara *real-time*.

Model MobileNet SSD dipilih karena model ini memiliki keunggulan dimana model ini hanya membutuhkan tingkat komputasi yang rendah sehingga cocok untuk diimplementasikan ke dalam perangkat mobile dalam bentuk aplikasi Android.

Adapun tahapan kerja dari MobileNet SSD secara singkat adalah sebagai berikut:

- a. Pra-pemrosesan: Model menerima masukan berupa citra dan mengubah ukurannya menjadi 320x320 piksel.
- b. Ekstraksi fitur: Model mengekstraksi fitur unik dari citra menggunakan MobileNet, seperti batas tepi, bentuk, dan tekstur yang menjadi ciri khas objek dalam citra.
- c. Prediksi: Model memprediksi posisi *bounding box* dan klasifikasi objek dalam citra menggunakan SSD.

Sebelum model dapat digunakan untuk mendeteksi jenis gonggong secara akurat, tahap pelatihan (*training*) perlu dilakukan terlebih dahulu agar model dapat mengenali karakteristik visual masing-masing jenis gonggong. Data pelatihan yang telah disiapkan dan telah dilabeli pada tahapan sebelumnya dimasukkan ke dalam proses pelatihan dengan parameter yang ditentukan, seperti jumlah *epoch*, *learning rate*, dan *batch size*.

3.5 Pengujian

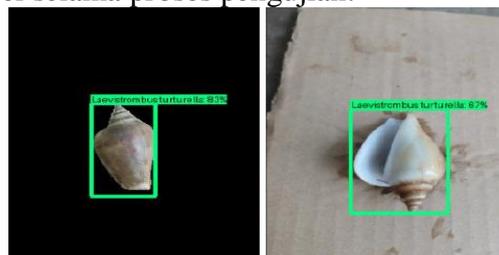
Setelah model melewati proses pelatihan, maka tahapan selanjutnya adalah pengujian untuk melihat kinerja model dan melakukan evaluasi seberapa baik model dalam mengenali dan mengklasifikasikan objek gonggong pada data pengujian. Tahapan pengujian ini juga dilakukan untuk mengukur kemampuan generalisasi model, yaitu kemampuan model dalam mengklasifikasi objek terhadap data citra yang baru, bukan hanya data yang digunakan selama proses pelatihan.

Pengujian dilakukan menggunakan dataset pengujian yang telah dipisahkan sebelumnya dari total dataset yang ada. Dataset pengujian terdiri dari 20% dari total 416 citra yang tersedia, melingkupi kedua jenis gonggong, yaitu *Laevistrombus turturella* dan *Strombus canarium* dengan variasi latar belakang dan orientasi objek dalam gambar.

Model yang telah dilatih kemudian diuji untuk mendeteksi objek pada citra pengujian, serta mengklasifikasikannya ke dalam jenis yang sesuai. Pada tahap ini, model menghasilkan dua informasi utama untuk setiap citra, yaitu:

- a. Lokasi objek, model menunjukkan posisi objek dalam citra menggunakan *bounding box*.
- b. Label klasifikasi, model menunjukkan jenis gonggong yang terdeteksi dalam bentuk label yang berisi nama jenis gonggong yang terdeteksi.
- c. Tingkat keyakinan, model menunjukkan tingkat *confidence* atau keyakinan model terhadap objek yang telah diklasifikasikan. Dalam penelitian ini, model diatur untuk menunjukkan objek yang dikenali apabila tingkat keyakinan model diatas 50%.

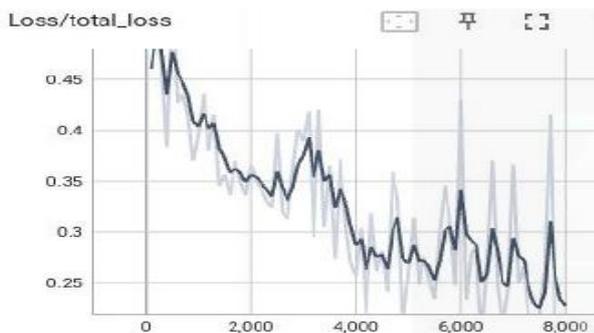
Berikut merupakan contoh output dari model selama proses pengujian:



Gambar 3. Output Model

Terlihat dari gambar diatas, model memiliki tingkat keyakinan yang lebih tinggi saat mendeteksi citra gonggong yang tidak memiliki latar belakang, sedangkan untuk citra gonggong dengan latar belakang, model Hal ini menunjukkan bahwa keberadaan elemen visual tambahan dalam latar belakang dapat mempengaruhi tingkat kepercayaan dan kinerja deteksi model secara signifikan.

Selain evaluasi visual yang menunjukkan posisi *bounding box*, nama gonggong, tingkat kepercayaan model 83% untuk citra tanpa latar belakang dan 67% untuk citra dengan latar belakang, peneliti juga melakukan evaluasi numerik menggunakan TensorBoard untuk melihat performa pelatihan model. Salah satu aspek utama yang diamati merupakan nilai total loss yang dihasilkan oleh model selama proses pelatihan.



Gambar 4. Total Loss Model

Dari grafik total loss, terlihat bahwa model memiliki tingkat loss yang cukup rendah, yaitu sebesar 0.3329 pada akhir pelatihan. Nilai ini mengindikasikan bahwa model telah berhasil mempelajari pola-pola dan fitur khas objek dari data pelatihan. Namun pada saat melakukan pengujian, model mengalami kinerja yang rendah pada kasus data citra gonggong yang memiliki latar belakang. Hal ini menunjukkan model mengalami kesulitan dalam mengenali objek gonggong ketika terdapat visual latar belakang.

Oleh karena itu, untuk meningkatkan kemampuan generalisasi model, peneliti dapat memperluas dataset dengan menambahkan lebih banyak citra gonggong yang memiliki latar belakang yang beragama dan kondisi pencahayaan yang berbeda-beda. Pendekatan ini diharapkan dapat membantu model dalam

mengenali objek dengan tingkat kepercayaan yang lebih tinggi.

3.6 Implementasi

Setelah proses pelatihan dan pengujian telah selesai dilakukan, maka tahap selanjutnya adalah mengimplementasikan model ke dalam aplikasi mobile berbasis Android. Implementasi ini dilakukan dengan tujuan untuk memungkinkan pengguna secara langsung mengklasifikasikan jenis gonggong melalui perangkat seluler secara praktis dan *real-time*.

Model yang telah dilatih akan diekspor ke dalam format TensorFlow Lite (TFLite), yang merupakan versi ringan dari model TensorFlow sehingga dapat digunakan pada perangkat mobile dan embedded system. Berikut merupakan tahapan peneliti dalam mengimplementasikan model ke dalam aplikasi mobile:

- Ekspor model ke format TFlite, model yang dilatih dikonversi menggunakan TensorFlow Lite Converter yang nantinya akan menghasilkan berkas .tflite yang siap diimplementasikan ke dalam aplikasi Android.
- Pengembangan aplikasi, aplikasi dikembangkan menggunakan Android Studio IDE dengan bahasa Java. Aplikasi yang dikembangkan memiliki tampilan antarmuka yang sederhana dan memiliki tampilan output yang serupa dengan output yang ditampilkan pada proses pengujian model, yaitu dengan menampilkan bounding box, label jenis gonggong, serta tingkat kepercayaan model. Aplikasi memerlukan akses kamera secara real-time sehingga memungkinkan aplikasi untuk melakukan klasifikasi objek menggunakan model TFLite secara *real-time*.

IV. KESIMPULAN

Penelitian ini bertujuan untuk mengembangkan sebuah aplikasi mobile yang mampu mengklasifikasikan dua jenis gonggong, yaitu *Laevistrombus turturella* dan *Strombus Canarium* menggunakan metode deteksi objek

M. Noval, Marcel Wangnandra, Rido Ramadhan, M Afief A, Faiz A, N. Hayaty “Klasifikasi Jenis Gonggong Melalui Pendekatan Pengenalan Objek Berbasis MobileNet-SSD”.

MobileNet SSD berbasis TensorFlow Object Detection API. Berdasarkan hasil pelatihan, model menunjukkan performa yang cukup baik dengan nilai *total loss* sebesar 0,3329 yang mengindikasikan model mampu mempelajari pola dan fitur khas gonggong yang ada dalam dataset pelatihan.

Sedangkan untuk evaluasi model dengan dataset pengujian, model menunjukkan tingkat kepercayaan sebesar 83% untuk citra tanpa latar belakang, dan 67% untuk citra yang memiliki latar belakang. Hasil ini menunjukkan kehadiran latar belakang visual memberikan tantangan tersendiri terhadap tingkat kepercayaan dan akurasi deteksi model.

Dengan demikian, dapat disimpulkan bahwa pendekatan MobileNet SSD memiliki potensi yang tinggi dalam mengklasifikasikan jenis gonggong. Namun performa model dapat ditingkatkan kembali melalui pengayaan dataset citra yang lebih bervariasi, khususnya data citra yang mengandung latar belakang yang bervariasi.

UCAPAN TERIMKASIH

Terima kasih kepada dosen pengampu mata kuliah Pengolahan Citra dan Universitas Maritim Raja Ali Haji atas dukungan dalam pelaksanaan penelitian ini.

REFERENSI

[1] Muzahar dan Viruly, L., “Identifikasi, reproduksi dan karakterisasi profil protein siput gonggong - ikon kota Tanjungpinang,” dalam Universitas Maritim Raja Ali Haji Press., Tanjungpinang, 2020, hlm. 1-3.

- [2] Vrbaski, V., Josic, S., Vranjkovic, V., Teodorovic, P., dan Struharik, R., “Puppis: Hardware accelerator of single-shot multibox detectors for edge-based applications,” dalam MDPI AG., 2023, hlm. 1.
- [3] Srinivasu, P. N., SivaSai, J. G., Ijaz, M. F., Bhoi, A. K., Kim, W., dan Kang, J. J., “Classification of skin disease using deep learning neural networks with MobileNet V2 and LSTM,” dalam MDPI., 2021, hlm. 6.
- [4] Muzahar, M., Zahra, A., dan Wulandari, R. ‘Profil Hemolim Siput Gonggong, Laevistrombus Turturella Asal Perairan Pesisir Pulau Bintan Provinsi Kepulauan Riau Sebagai Kandidat Biota Budidaya,” dalam Jurnal Riset Akuakultur., 2021, hal. 195-196.
- [5] Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., dan Adam, H., “MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications,” dalam *arXiv: Computer Vision and Pattern Recognition.*, 2017, vol. 1, no. 1, hlm. 1-9.
- [6] Abdillah, G., dan Ilyas, R., “Deteksi Objek Bahasa Isyarat Huruf Bisindo Menggunakan SSD Mobilenet,” dalam *KESATRIA: Jurnal Penerapan Sistem Informasi (Komputer & Manajemen).*, 2024, vol. 5, no. 1, hlm. 52–53.