

Identifikasi Kesegaran Ikan Bandeng Non-kontak menggunakan MobileNetV2

Achmad Nasrul Hidayatullah, Eko Prasetyo^{1*}, Rani Purbaningtyas²

^{1,2}Program Studi Teknik Informatika, Fakultas Teknik, Universitas Bhayangkara Surabaya

*Email: eko@ubhara.ac.id

Abstrak

Ikan bandeng merupakan komoditas yang diunggulkan di beberapa kabupaten di Indonesia yaitu Sidoarjo, Semarang, dan Banten. Ikan ini juga favorit masyarakat Indonesia karena tinggi gizi tinggi dengan harga terjangkau. Sehingga, bagi pebisnis hasil olahan ikan bandeng, kesegaran ikan bandeng menjadi parameter penting karena kesegaran ikan mempengaruhi kualitas hasil produk olahannya. Penyortiran ikan secara manual menjadi masalah ketika jumlah ikan sangat banyak, karena rawan terjadi kesalahan akibat kelelahan. Selain itu, penyortiran ikan secara manual juga boros biaya dan waktu lama. Maka dari itu, dibutuhkan sistem otomatis non-kontak untuk mengidentifikasi kesegaran ikan berbasis citra digital. Penelitian ini bertujuan mengembangkan aplikasi identifikasi kesegaran ikan bandeng dengan menerapkan model Convolutional Neural Network (CNN). Kami menerapkan model MobileNetV2 untuk mengidentifikasi kesegaran ikan bandeng menjadi 3 kelas kesegaran yaitu sangat segar, segar, dan tidak segar. Aplikasi menggunakan model MobileNetV2 pada 312 citra ikan bandeng. Kinerja klasifikasi kesegaran mencapai 95 %, 70% dan 80% masing-masing pada kelas sangat segar, segar, dan tidak segar. Akurasi global sistem mencapai 81.6% menunjukkan bahwa aplikasi dapat bekerja dengan baik. Dari eksperimen dan analisis yang dilakukan, dapat disimpulkan bahwa sistem memiliki kemampuan baik dalam mengidentifikasi kesegaran ikan.

Kata kunci: convolutional neural network, ikan bandeng, klasifikasi citra, kesegaran, mobilenet

Abstract

Milkfish is a superior commodity in several districts in Indonesia, namely Sidoarjo, Semarang, and Banten. This fish is also a favorite of Indonesians because it is nutritious and affordable. Therefore, for milkfish processed product business people, the freshness of milkfish is an important parameter because the freshness of the fish affects the quality of the processed products. Manual fish sorting is a problem when the number of fish is vast because it is prone to errors due to fatigue. In addition, manual fish sorting is also wasteful and time-consuming. Therefore, a non-contact automatic system is needed to identify fish freshness based on digital images. This study uses the Convolutional Neural Network (CNN) model to develop an application for milkfish freshness identification. We applied the MobileNetV2 model to identify the freshness of milkfish into three freshness classes, namely very fresh, fresh, and not fresh. The application uses the MobileNetV2 model on 312 milkfish images. The freshness classification performance reached 95%, 70%, and 80% in the high-fresh, fresh, and not-fresh classes, respectively. The global accuracy of the system reached 81.6%, indicating that the application can work well. From the experiments and analysis conducted, it can be concluded that the system has good capabilities in identifying fish freshness.

Keywords: convolutional neural network, milkfish, image classification, freshness, mobilenet

PENDAHULUAN

Ikan bandeng (*Chanos-chanos*) merupakan ikan yang tinggi protein dan dikonsumsi oleh satu milyar penduduk di dunia (Ahmad et al., 2020; Hussain et al., 2021). Pemenuhan konsumsi ikan secara global juga meningkat seiring pertumbuhan populasi penduduk melalui budidaya akuakultur (Hassan et al., 2021). Untuk itu, penopang besar budidaya ikan bandeng di

dunia kebanyakan dari Indonesia, Taiwan dan Filipina (Bera et al., 2021; Vasava, 2018). Di Indonesia, ikan bandeng juga menjadi komoditas unggulan sejumlah kabupaten di Indonesia yaitu Sidoarjo, Semarang, dan Banten (Siburian et al., 2012). Ikan ini juga favorit masyarakat Indonesia karena tinggi gizi dengan harga terjangkau. Pada 100 gram daging ikan bandeng mengandung 2 mg zat besi, 150 mg fosfor, 20

mg kalsium, 0.05 mg vitamin B1, dan 150 SI vitamin A (Sa'dilah Fauzi, 2016). Maka dari itu, menjaga kesehatan ikan sejak penangkapan dari kolam ikan hingga sampai ke konsumen menjadi perhatian penting banyak pihak, karena ikan segar sangat rentan terhadap pembusukan mikroba dan perubahan biologis karena kadar air tinggi, rendah asam, enzim endogen reaktif, dan kaya gizi (Yumnam et al., 2023).

Bagi pebisnis hasil olahan ikan bandeng dalam negeri, kesehatan ikan bandeng menjadi parameter penting karena kesehatan ikan mempengaruhi kualitas produk olahan ikan (Sandi et al., 2020). Lebih lanjut, bagi para pebisnis ekspor ikan bandeng, kesehatan ikan juga memberikan pengaruh kepuasan konsumen agar bisnis terus berjalan. Pekerjaan sortir ikan oleh tenaga manusia malah menjadi hambatan ketika jumlah ikan sangat banyak. Penyortiran secara manual memiliki kelemahan yaitu sering terjadi kesalahan akibat human error karena kelelahan, sortir dengan tenaga manusia juga butuh waktu lama dan biaya besar (Agustyan, 2021). Jika strateginya adalah mengurangi waktu sortir maka kita membutuhkan tenaga manusia sangat banyak, selain itu biaya juga menjadi besar (Sarimin et al., 2019). Disamping itu, akurasi yang dicapai juga dipengaruhi oleh keahlian tenaga kerja tersebut, karena persepsi kesehatan satu orang dapat saja berbeda terhadap orang yang lain. Masyarakat umum juga menggunakan kesehatan ikan sebagai tolak ukur utama kualitas dan keamanan ikan sebelum beli (Abamba Omwange et al., 2022). Masalah tersebut sangat beralasan karena masyarakat adalah konsumen langsung yang mengkonsumsi ikan tersebut. Alat pemeriksaan kesehatan ikan yang dibutuhkan masyarakat tentunya adalah teknologi deteksi kesehatan ikan tanpa alat khusus dan non-kontak terhadap ikan di pasar. Teknologi kesehatan non-kontak menawarkan pengukuran kesehatan non-invasif tanpa merusak kemasan dan ikan itu sendiri (Gopalakrishnan et al., 2023). Untuk itu, dibutuhkan sistem otomatis sebagai alat bantu pengenalan kesehatan ikan non-kontak seperti deteksi kesehatan berbasis sensor elektronik, atau aplikasi identifikasi kesehatan berbasis citra digital, atau kombinasi keduanya.

Penelitian yang sudah dilakukan sebelumnya, umumnya menggunakan citra mata, insang, atau kepala yang sudah tersegmentasi, sehingga model memproses citra

yang sudah siap klasifikasi. Padahal untuk mendapatkan bagian tubuh tersebut, sistem harus melakukan *pre-processing* yaitu segmentasi, misalnya dengan deteksi objek. Deteksi objek ini dapat dilakukan dengan objek detektor seperti Mask-RCNN (Zhao et al., 2023), You Only Look Once (YOLO) (Prasetyo et al., 2022), atau Single Shot Multibox Detector (SSD) (Cai et al., 2022). Fungsi objek detektor ini membantu sistem untuk mengenali keberadaan objek yang dicari dalam citra secara otomatis. Sehingga tidak dibutuhkan *pre-processing* yaitu *cropping object of interest*. Maka dari itu, pengembangan sistem klasifikasi kesehatan ikan yang dikombinasikan dengan deteksi objek menjadi pilihan sistem yang lebih baik. Penelitian ini mengusulkan kombinasi deteksi objek dan klasifikasi kesehatan kepala dan ekor ikan bandeng menggunakan MobileNetV2. Deteksi objek yang digunakan adalah SSD dengan memproses citra masukan sebelum diklasifikasi. Deteksi ini bertujuan mendapatkan citra kepala dan ekor yang tampak dalam citra. Selanjutnya, citra kepala dan ekor tersebut diklasifikasi menggunakan MobileNetV2 untuk mendapatkan kelas kesehatan.

Penelitian ini menggunakan 312 citra ikan bandeng berukuran 1487x991 piksel, citra bertipe jpg. Dalam eksperimen, 252 citra digunakan sebagai data latih dan sisanya 60 citra sebagai data uji. Setiap citra berisi objek ikan bandeng utuh yang menampilkan kepala dan ekor. Kelas kesehatan yang digunakan ada tiga yaitu sangat segar, segar dan kurang segar. Hasil deteksi objek adalah kepala dan ekor yang kemudian diklasifikasi menggunakan MobileNetV2. Hasil eksperimen dan analisis menunjukkan bahwa aplikasi dapat mengklasifikasi kesehatan ikan dengan baik.

TINJAUAN PUSTAKA

Penelitian terkait identifikasi kesehatan ikan sudah dilakukan oleh peneliti-peneliti sebelumnya, seperti klasifikasi kesehatan ikan bandeng menggunakan sensor gelombang (Sandi et al., 2020). Penelitian tersebut menggunakan empat fitur dari sensor gas dan sensor warna dengan metode Naïve Bayes, akurasi yang dicapai hingga 99%. Klasifikasi kesehatan ikan dengan JST dan fitur HSV dan GLCM (Sarimin et al., 2019), klasifikasi kesehatan ikan menggunakan K-Nearest

Neighbor pada citra mata ikan mencapai akurasi 93% (Saputra et al., 2022), dan klasifikasi kesegaran ikan nila menggunakan fitur statistik dan K-Nearest Neighbor mencapai akurasi hingga 75% (Widadi et al., 2023), klasifikasi kesegaran ikan berdasarkan citra mata dengan K-Nearest Neighbor (Styorini et al., 2022).

Pengembangan klasifikasi kesegaran ikan pun kini juga dikerjakan dengan CNN (Sena, 2018; Sena Samuel, 2017) karena memiliki kemampuan rekayasa fitur dan klasifikasi dalam satu model. Pekerjaan seperti ekstraksi dan seleksi fitur secara manual tidak lagi diperlukan. CNN memungkinkan kita mengadopsi jaringan dari permasalahan sebelumnya ke permasalahan baru dengan melakukan pelatihan ulang sebagian atau seluruh bagian jaringan (Ekoputris, 2018). Maka dari itu, CNN memiliki banyak varian yang dapat dikembangkan (Polgan et al., 2022). Penelitian lainnya melakukan klasifikasi dua kelas kesegaran ikan dengan CNN berdasarkan citra digital (Agustyan, 2021), klasifikasi kesegaran ikan menggunakan citra insang dengan akurasi hingga 98% (Polgan et al., 2022), klasifikasi kesegaran ikan berdasarkan citra insang (Sholihin, 2021), klasifikasi kesegaran ikan tuna berdasarkan citra kepala mencapai akurasi 99% (Polgan et al., 2022), dan perbandingan kinerja model CNN dalam mengklasifikasi kesegaran ikan bandeng (Prasetyo et al., 2021).

Pengembangan klasifikasi kesegaran ikan menggunakan pendekatan konvensional membutuhkan usaha yang tinggi untuk merekayasa fitur dan metode klasifikasi agar mencapai kinerja tinggi. Terbukti pada penelitian yang berbasis citra sebelumnya, akurasi tertinggi yang dicapai adalah 93%. Meskipun ada yang mencapai 99%, namun penelitian ini tidak murni menggunakan citra, melainkan kombinasi sensor, dimana ada kebutuhan alat lebih kompleks untuk mendeteksi kesegaran ikan. Pada penelitian menggunakan CNN, kinerja yang dicapai hingga 99% namun menggunakan model CNN yang bekerja pada data dengan 2 kelas kesegaran saja. Penelitian ini bereksperimen menggunakan model CNN dengan arsitektur yang lebih ringan dan bekerja pada data dengan 3 kelas kesegaran. Kinerja yang dicapai oleh sistem dengan data 3 kelas akan lebih berat dibandingkan dengan 2 kelas. Selain itu, penelitian ini juga menggabungkan CNN untuk deteksi objek dan klasifikasi citra.

METODE

3.1 Dataset

Pada penelitian ini data citra diperoleh dari melakukan pengambilan citra ikan bandeng menggunakan kamera ponsel. Jarak kamera terhadap objek sekitar 30-40 cm. Ikan dilakukan penyimpanan dengan es selama 6 hari dengan perbandingan es dan ikan adalah 1:1. Setiap hari, ikan dilakukan pemotretan untuk mendapatkan sampel data citra ikan. Pengumpulan data dilakukan selama 6 hari dengan jumlah citra yang didapatkan adalah 312 citra. Kelas kesegaran yang digunakan dalam penelitian ini adalah 3 jenis kesegaran yaitu sangat segar, segar, dan kurang segar, sebagaimana disajikan dalam (Dutta et al., 2016).

Tabel 1. Tingkat kesegaran ikan berdasarkan hari

Tingkat kesegaran	Hari
Sangat segar	1 - 2
Segar	3 - 4
Kurang segar	5 - 6

Data pada Tabel 1 menyajikan kelas kesegaran ikan selama 6 hari. Kelas sangat segar didefinisikan sebagai kondisi ikan hari pertama dan kedua. Kelas segar sebagai kondisi pada hari ketiga dan keempat. Sedangkan kurang segar sebagai hari kelima dan keenam.

3.2 Kerangka Kerja Penelitian

Penelitian ini menggunakan kerangka kerja seperti disajikan Gambar 1, terdiri dari 5 langkah yaitu: akuisisi citra, pembagian data, deteksi objek dengan SSD, pelatihan model dengan MobileNetV2 dan klasifikasi kesegaran dengan MobileNetV2. Langkah-langkah tersebut dijelaskan sebagai berikut:

1. Akuisisi citra

Tahap pertama ini kami melakukan akuisisi citra dengan memotret ikan setiap hari selama 6 hari. Kami menggunakan kamera ponsel dengan jarak kamera ke objek 30-40 cm. Total citra yang kami dapatkan adalah 312 citra.

2. Pemisahan data

Untuk keperluan pelatihan dan pengujian kami membagi data menjadi dua bagian yaitu data *training* dan data *testing*. Kami mengalokasikan 252 citra sebagai data *training* dan sisanya 60 citra sebagai data uji. Data *training* digunakan untuk melatih model SSD dan MobileNetV2. Data uji

digunakan untuk menguji model dengan data yang belum pernah dibaca saat pelatihan. Hal ini penting untuk mengetahui kehandalan sistem dalam mengolah data baru yang belum pernah ditemui.

3. Deteksi objek menggunakan SSD

Untuk otomatisasi pengambilan objek kepala dan ekor ikan, kami menggunakan SSD sebagai model yang membantu untuk mendapatkan kepala dan ekor. Semua citra latih digunakan untuk melatih model SSD menggunakan pre-trained bobot yang tersedia. Objek kepala dan ekor yang dideteksi menjadi masukan bagi MobileNetV2 sebagai data latih.

4. Pelatihan model MobileNetV2

Model utama yang kami gunakan dalam penelitian ini adalah MobileNetV2 dengan bobot *pre-trained* yang sudah dilatih sebelumnya dengan Imagenet. Kami melatih ulang dengan mengganti *fully-connected layer* yang disesuaikan dengan 3 kelas kesegaran.

5. Klasifikasi

Hasil pelatihan pada tahap sebelumnya adalah model MobileNetV2 yang siap digunakan untuk klasifikasi citra uji. Citra uji diawali dengan deteksi objek kepala dan ekor menggunakan SSD. Selanjutnya objek yang ditemukan dilakukan klasifikasi kesegaran menggunakan MobileNetV2.

6. Evaluasi

Tahap akhir dalam penelitian ini adalah evaluasi sistem. Kami membandingkan kelas hasil klasifikasi oleh sistem dengan kelas kesegaran realnya, kemudian kami menghitung akurasi. Semakin tinggi akurasi yang dicapai maka semakin baik sistem yang dihasilkan.

3.3 MobileNetV2

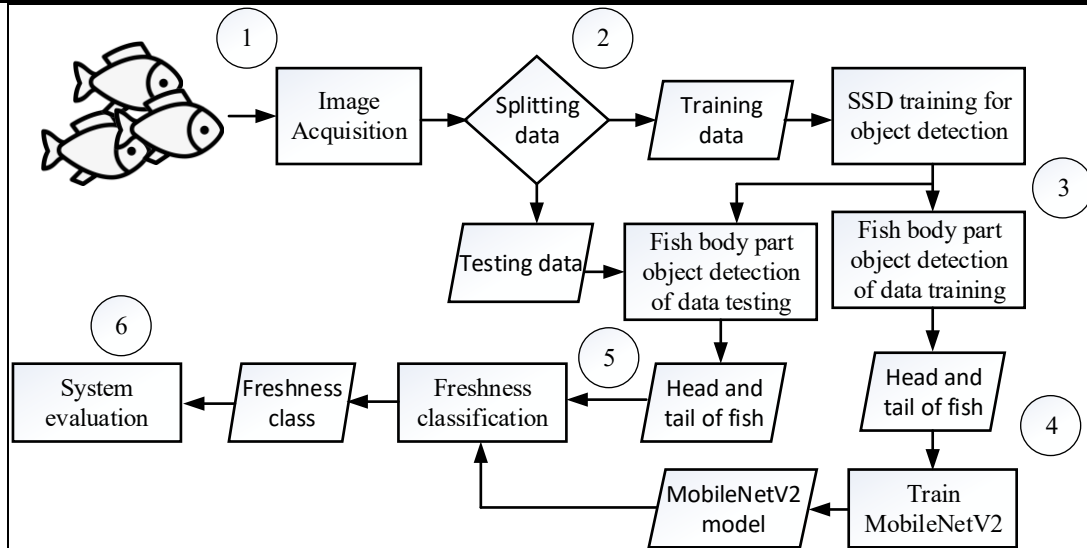
Dalam implementasi pendekatan *transfer learning*, pada bagian *feature extraction* kami mempertahankan sejumlah *layer* dari *MobileNetV2* yang tersusun atas 153 *layer*. Selanjutnya, dari *layer* tersebut kami menyambung dengan *Full Connected Layer* sebanyak 2 *layer* yaitu *hidden layer* dan *output layer*.

Pada Gambar 2 lapisan pertama, input citra yang digunakan adalah citra RGB dengan ukuran 244x244x3. Kemudian dilakukan proses

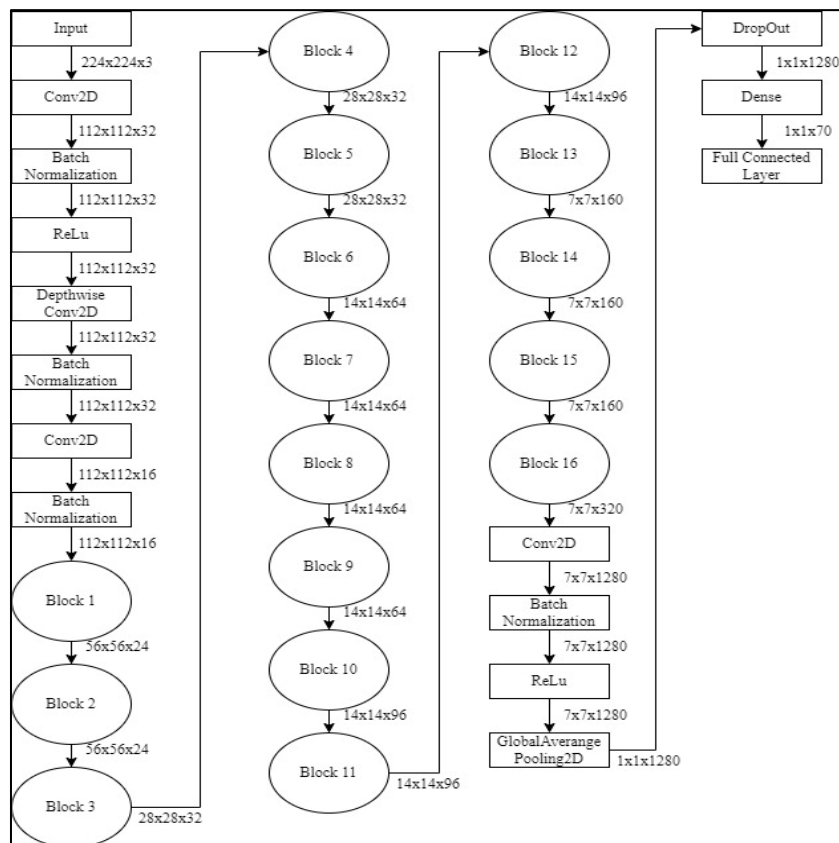
konvolusi untuk mengekstraksi fitur-fitur yang ada pada citra tersebut dengan menggunakan aktivasi ReLu. Setelah itu, dimensi citra yang semula 244x244x3 berubah menjadi 112x112x32 sebelum masuk ke proses konvolusi selanjutnya. Selanjutnya adalah proses konvolusi *depthwise separable convolution*. Dalam pendekatan konvolusi ini, model menggunakan *depthwise convolution* (DC) dan *pointwise convolution* (PC). DC menggunakan single mask tiap channel peta fitur kernel berukuran 3x3, sedangkan PC 1x1xN. N adalah ukuran peta fitur (*channel*). PC bertujuan untuk memberikan kombinasi/gabungan linear semua channel fitur pada hasil olah DC. Setiap kali setelah konvolusi, model melakukan *batch normalization*. Hasil akhir dimensi sesuai citra yang disajikan adalah 112x112x16. Setelah selesai konvolusi kedua, hasilnya dijadikan masukan bagi blok dasar berikutnya. Pada blok dasar 1, 3, 6, dan 13 dilakukan juga penurunan resolusi karena DSC yang dilakukan. Setelah dua kali konvolusi standar diantara DC sebelum dan sesudah, dilakukan juga *batch normalization* dan aktivasi ReLU. Setelah melalui blok dasar 16 kali, kita mendapatkan hasil ekstraksi fitur berdimensi 7x7x1280. Setelah melewati arsitektur inti MobileNetV2, dilakukan proses penyesuaian input untuk masuk ke *fully-connected layer* dengan cara melakukan *Global average pooling* dan *dropout*, menghasilkan dimensi akhir 1x1x1280. Hasil ini kemudian dihubungkan ke lapisan *fully connected* dan proses klasifikasi akhir dilakukan menggunakan fungsi *softmax*. Pada Gambar 3 dapat dilihat terdapat 2 jenis block dasar yaitu block dasar yang diawali dengan input dan diakhiri dengan *batch normalization* seperti konvolusi standar, sedangkan disebelahnya adalah block dasar dengan *skip connection* terhadap inputnya.

3.4 Single Shot Multibox Detector (SSD)

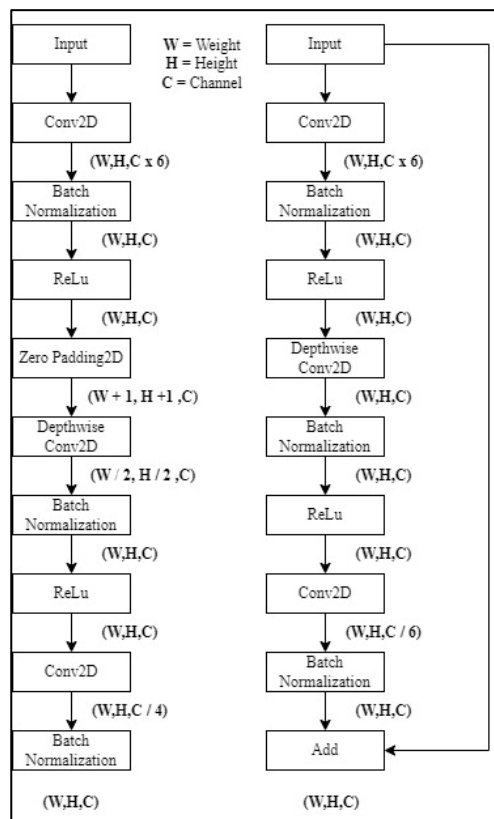
Single Shot Multibox Detector (SSD) merupakan salah satu model deteksi objek yang memungkinkan kita dapat mendeteksi objek lebih cepat dan efisien. Tugas utama deteksi objek adalah menentukan lokasi dan jenis objek yang ditemukan didalam gambar atau video. Algoritma deteksi objek umumnya terdiri dari dua tahap, yaitu ekstraksi fitur dan deteksi objek.



Gambar 1. Kerangka kerja penelitian



Gambar 2. Arsitektur model MobileNetV2



Gambar 3. Block modul dasar arsitektur MobileNetV2

Model SSD dapat dikategorikan deteksi objek *real-time* karena lokasi dan jenis objek yang ditemukan dapat segera diketahui saat itu juga. Arsitektur CNN juga termasuk jenis CNN yang diterapkan pada data citra. Arsitektur CNN juga terbagi menjadi dua bagian yaitu blok ekstraksi fitur dan layer konvolusi (Younis et al., 2020). SSD berusaha menggabungkan dua tahap ini dalam satu proses inferensi tunggal. Proses tersebut meliputi lokasi dan jenis objek secara bersamaan, ini menjadikan SSD lebih efisien dibanding deteksi objek lainnya. SSD menggunakan jaringan neural dalam pekerjaan ekstraksi fitur dan deteksi objek. Secara intuitif, cara kerja SSD adalah memecahkan gambar menjadi sejumlah grid, setiap grid dievaluasi untuk menentukan apakah terdapat objek dalam grid. Jika terdapat objek, maka algoritma bekerja menentukan jenis dan lokasi objek tersebut. SSD lebih unggul dalam kemampuannya memproses gambar secara *real-time*. Inilah hal yang sangat penting bagi aplikasi deteksi objek ketika diterapkan di dunia nyata. Keunggulan ini juga

membawa akibat akurasi deteksi masih kalah baik dibandingkan pendekatan deteksi objek yang melakukan dua tahap secara terpisah.




Gambar 4. Citra ikan dengan objek yang terdeteksi oleh SSD

3.5 Pelatihan

3.5.1 Input Layer

Pelaksanaan pelatihan model diawali dengan memasukkan citra ikan sebagai masukan bagi input layer. Dimensi citra masukan adalah tiga dimensi dengan channel RGB (*Red, Green, Blue*). Pada tahap ini, nilai RGB tiap piksel dinormalisasi dalam jangkauan $[0,1]$. Hal ini untuk menyederhanakan komputasi dengan membagi setiap nilai RGB terhadap 255.



Gambar 5. Channel RGB Pada Citra Input

3.5.2 Convolutional Layer

Pada setiap nilai RGB piksel, kemudian melalui layer konvolusi untuk mengekstraksi fitur-fitur (*feature map*) yang terdapat pada citra menggunakan kernel/filter. Contoh, pada Gambar 6 adalah citra masukan pada channel merah (*red*). Angka-angka tersebut merepresentasikan besaran nilai intensitas merah pada citra tersebut $[0,255]$.

23	11	70	32	99	62	38	84	1	97
71	8	6	76	94	10	2	92	56	62
82	80	60	77	50	42	13	97	70	67
9	41	50	25	18	78	82	70	53	43
11	39	40	11	40	15	80	56	68	50
84	21	56	36	71	46	23	51	66	97
43	2	25	80	58	19	20	72	2	99
62	43	77	29	19	72	74	37	22	34
30	45	90	71	73	63	39	43	75	8
76	88	31	42	8	12	61	37	24	34

Gambar 6. Input channel merah (red)

Pembangkitan fitur dilakukan dengan proses konvolusi menggunakan kernel/filter, dimana filter adalah kumpulan nilai (*weight*) yang diinisiasi dengan nilai acak. Contoh nilai filter disajikan pada Gambar 7(a).

2	2	2	2	2	241
1	1	1	1	1
0	0	0	0	0
-1	-1	-1	-1	-1
-2	-2	-2	-2	-2
(a) Contoh filter					(b) Hasil konvolusi sebuah piksel				


Gambar 6. Contoh filter dan hasil konvolusinya

Konvolusi antara citra dengan filter dilakukan dengan perkalian *inner-product* antara sebuah piksel dengan sejumlah tetangga yang didefinisikan oleh formula (1).

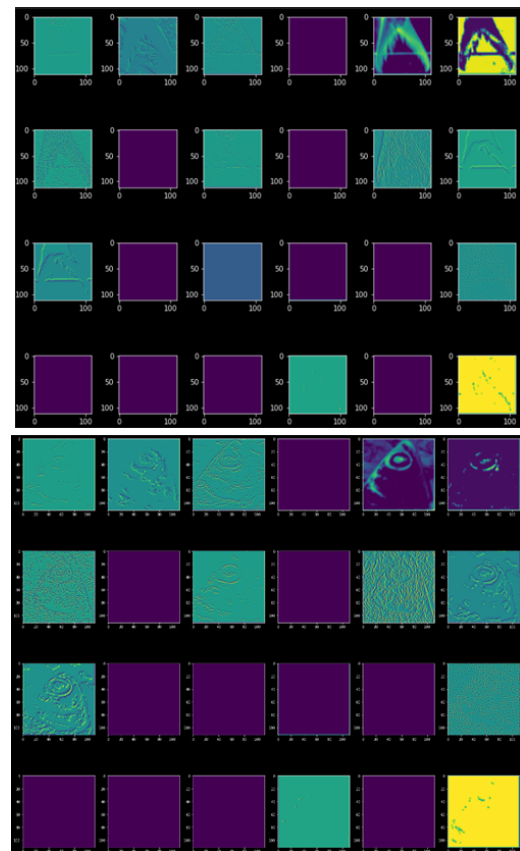
$$y_{m,n} = g \left(\sum_j \sum_k x[j,k] W[m-n, n-k] + b \right) \quad (1)$$

Contoh hasil konvolusi sebuah piksel ditunjukkan oleh Gambar 6(b).

Layer konvolusi bekerja untuk membangkitkan peta fitur (*feature map*) dari citra untuk mendapatkan pola fitur citra. Pembangkitan fitur ini dilakukan menggunakan filter di layer konvolusi dengan nilai sesuai kernel. Visualisasi hasil konvolusi di layer pertama citra ikan bandeng disajikan pada Gambar 7. Peta fitur tersebut kemudian dikonvolusi lagi di layer berikutnya sehingga menghasilkan peta fitur lain yang lebih banyak seperti tepian (*edge*). Proses konvolusi dan *pooling* ini dilakukan pada setiap layer untuk membangkitkan fitur lain baik fitur besar maupun kecil, seperti disajikan pada Gambar 8.



Gambar 7. Peta fitur di layer konvolusi



Gambar 8. Pola pada peta fitur

3.5.3 Fully Connected Layer

Setelah selesai layer konvolusi, peta fitur melewati *fully connected layer*, dimulai dengan mengubah susunan data matrik 3 dimensi menjadi vektor 1 dimensi (*flatten*). Perhitungan dilakukan dengan perkalian nilai di neuron (x) dengan bobot (w) kemudian ditambah bias (b). Hasil ini menjadi masukan bagi neuron selanjutnya (y). Pada layer ini kami menggunakan satu *hidden layer* dengan 100 neuron. Layer keluaran menyajikan kelas kesegaran dengan 3 neuron.

HASIL DAN PEMBAHASAN

Kami melakukan pengujian dengan menggunakan model MobileNetV2 untuk mengklasifikasi kepala dan ekor ikan yang berhasil dideteksi oleh SSD. Kemudian hasilnya dibandingkan dengan kelas original yang dimiliki objek tersebut. Data uji yang digunakan adalah 60 citra, terdiri dari 20 citra untuk setiap kelasnya. Pengujian dilakukan pada aplikasi dengan mengunggah citra pada aplikasi, kemudian aplikasi memberikan jawaban berupa objek kepala dan ekor yang ditemukan beserta kelas kesegaran hasil prediksi. Tampilan citra hasil olahan aplikasi disajikan pada Gambar 9, kami menampilkan kotak pembatas objek kepala dan ekor yang ditemukan bersama dengan kelas kesegaran yang dihasilkan.






Pada sampel data hasil pengujian ini, dapat dilihat bahwa pada semua citra kelas sangat segar berhasil diklasifikasikan kelas kesegarannya dengan benar oleh sistem. Hasil ini tentu dipengaruhi oleh citra yang variasi citra sangat segar yang beragam dan berbeda secara visual terhadap kelas yang lain. Sehingga semua






citra pada kelas sangat segar dapat terprediksi dengan benar juga. Lain hasil kelas lainnya, pada kelas segar, ada hasil yang salah klasifikasi ke kelas sangat segar dan kurang segar. Demikian pula kelas kurang segar, ada data yang diprediksi ke kelas sangat segar. Hasil ini tentu dipengaruhi oleh banyak hal seperti kondisi lingkungan sekitar saat pengambilan citra.



Gambar 9. Tampilan hasil klasifikasi

Tabel 2. Hasil Pengujian Klasifikasi Menggunakan CNN

No	Citra	Kelas Asli	Hasil Klasifikasi Menggunakan CNN						Kesesuaian
			Sangat Segar		Segar		Kurang Segar		
			Ekor	Kepala	Ekor	Kepala	Ekor	Kepala	
1		Sangat Segar	√	√					Sesuai
2		Sangat Segar	√	√					Sesuai
3		Sangat Segar	√	√					Sesuai
4		Segar		√	√				Tidak Sesuai
5		Segar	√	√					Tidak Sesuai

No	Citra	Kelas Asli	Hasil Klasifikasi Menggunakan CNN						Kesesuaian
			Sangat Segar		Segar		Kurang Segar		
			Ekor	Kepala	Ekor	Kepala	Ekor	Kepala	
6		Segar			√	√			Sesuai
7		Kurang Segar					√	√	Sesuai
8		Kurang Segar	√					√	Tidak Sesuai
9		Kurang Segar					√	√	Sesuai
10		Kurang Segar	√	√					Tidak Sesuai

Kami menyajikan sampel 10 data citra ikan bandeng yang sudah dilakukan prediksi kesegaran, seperti pada Tabel 2. Pengujian citra ikan bandeng menggunakan MobileNetV2. Hasil yang didapatkan cukup baik dimana hasil prediksi yang sesuai sebanyak 6 dan tidak sesuai sebanyak 4.

Kami menyajikan hasil prediksi 60 citra di Tabel 3. Sesuai dengan tiga kelas kesegaran, kami menyajikan secara terpisah hasil prediksi terhadap ketiga kelas. Kita dapat melihat bahwa untuk kelas sangat segar, segar dan kurang segar masing-masing mencapai akurasi 95%, 70%, dan 80%. Sedangkan akurasi keseluruhan dicapai 81.67%. Hasil ini menunjukkan bahwa aplikasi dapat mengidentifikasi kesegaran ikan bandeng dengan baik.

Kinerja aplikasi ini tentu sejalan dengan analisa kami pada sampel citra diatas bahwa citra kelas sangat segar lebih mudah terprediksi dan dapat diprediksi dengan benar ke kelasnya sendiri. Sehingga akurasi yang dicapai disini juga paling tinggi. Kelas lainnya terdapat lebih banyak salah prediksi. Salah prediksi menyebar ke dua kelas lainnya. Hasil terjelek dicapai oleh kelas segar. Hasil ini masuk akal karena kelas ini berada ditengah sehingga kondisi kesegaran ikan bisa di sangat segar atau kurang segar. Analisa

secara keseluruhan hasil klasifikasi 60 data uji ini menunjukkan kinerja yang baik, karena mencapai 81.6%. Untuk semua sistem yang harus mendeteksi kelas dengan fitur visual yang lemah, hasil ini adalah awalan yang baik pula.

Tabel 2. Hasil Pengujian Tiap Kelas

Pengujian Data	Hasil prediksi sesuai		Hasil prediksi tidak sesuai	
	Jumlah	Akurasi	Jumlah	Akurasi
Sangat segar	19	95%	1	5%
Segar	14	70%	6	30%
Kurang Segar	16	80%	4	20%

SIMPULAN

Berdasarkan eksperimen dan diskusi yang disajikan, sistem identifikasi kesegaran ikan bandeng dapat disimpulkan bahwa pengembangan aplikasi dengan model MobileNetV2 untuk klasifikasi kesegaran ikan bandeng mencapai kinerja yang baik dengan akurasi keseluruhan 81.6%. Kinerja klasifikasi pada masing-masing kelas sangat segar, segar dan tidak segar masing-masing adalah 95%, 70%, dan 80%. Hasil ini merupakan awal yang

baik bagi sebuah aplikasi yang harus mengklasifikasi kelas kesegaran menggunakan fitur visual yang lemah.

Penelitian berikutnya yang penting dilakukan adalah peningkatan kinerja klasifikasi dengan augmentasi data, *pre-processing* untuk peningkatan kualitas citra atau modifikasi arsitektur CNN.

DAFTAR PUSTAKA

- Abamba Omwange, K., Saito, Y., Firmanda Al Riza, D., Zichen, H., Kuramoto, M., Shiraga, K., Ogawa, Y., Kondo, N., & Suzuki, T. (2022). Japanese dace (*Tribolodon hakonensis*) fish freshness estimation using front-face fluorescence spectroscopy coupled with chemometric analysis. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 276, 121209. <https://doi.org/10.1016/J.SAA.2022.121209>
- Agustyan, A. (2021). Pengolahan Citra untuk Membedakan Ikan Segar dan Tidak Segar Menggunakan Convolutional Neural Network. *Indonesian Journal of Applied Informatics*, 5(1), 11. <https://doi.org/10.20961/ijai.v5i1.41770>
- Ahmad, N., Siddiqui, J. P. A., Nabi, G., Khan, K. M., Ali, A., Zamir, Y., Siddique, M. A. M., Amir, S. A., Khokhar, F. N., & Amin, M. (2020). Partial Substitution of Fishmeal with Plant Protein Source the Soybean Meal in the Diets of Arabian Yellowfin Seabream *Acanthopagrus arabicus* Juveniles. *Thalassas*, 36(2), 589–596. <https://doi.org/10.1007/S41208-020-00225-9/METRICS>
- Bera, A., Kailasam, M., Mandal, B., Padiyar, A., Ambasankar, K., Sukumaran, K., Makesh, M., Kumararaja, P., Subburaj, R., Thiagarajan, G., & Vijayan, K. K. (2021). Maturity induction and extended spawning kinetics of milkfish (*Chanos chanos*) administered with combined GnRH α and 17 α -methyl testosterone pellet at varied frequencies. *Aquaculture*, 543, 736993. <https://doi.org/10.1016/J.AQUACULTUR.2021.736993>
- Cai, J., Makita, Y., Zheng, Y., Takahashi, S., Hao, W., & Nakatoh, Y. (2022). Single shot multibox detector for honeybee detection. *Computers and Electrical Engineering*, 104, 108465. <https://doi.org/10.1016/J.COMPELECEN.2022.108465>
- Dutta, M. K., Issac, A., Minhas, N., & Sarkar, B. (2016). Image processing based method to assess fish quality and freshness. *Journal of Food Engineering*. <https://doi.org/10.1016/j.jfoodeng.2015.12.018>
- Ekoputris, R. O. (2018, May). *MobileNet: Deteksi Objek pada Platform Mobile | by Rizqi Okta Ekoputris | Nodeflux | Medium*. 9 May 2018.
- Gopalakrishnan, S., Nejati, S., Sedaghat, S., Gupta, K., Mishra, R. K., & Rahimi, R. (2023). Electronic-free and low-cost wireless sensor tag for monitoring fish freshness. *Sensors and Actuators B: Chemical*, 381, 133398. <https://doi.org/10.1016/J.SNB.2023.133398>
- Hassan, H. U., Gabol, K., Wattoo, J., Chatta, A. M., Ali, Q. M., Mahmood, K., Hussain, M., Abro, N. A., Attaullah, M., Rahman, S. U., Rashid, A., Rahman, M. A., & Hossain, M. Y. (2021). First pacific white shrimp, *litopenaeus vannamei* (Boone, 1931) culture in Pakistan: Evaluation of optimum salinity level for the growth performance and survival in the hypo saline and hyper saline condition under pond ecosystem. *Journal of Animal and Plant Sciences*, 31(5), 1492–1500. <https://doi.org/10.36899/JAPS.2021.5.0351>
- Hussain, M., Hassan, H. U., Siddique, M. A. M., Mahmood, K., Abdel-Aziz, M. F. A., Laghari, M. Y., Abro, N. A., Gabol, K., Nisar, Rizwan, S., & Halima. (2021). Effect of varying dietary protein levels on growth performance and survival of milkfish *Chanos chanos* fingerlings reared in brackish water pond ecosystem. *The Egyptian Journal of Aquatic Research*, 47(3), 329–334. <https://doi.org/10.1016/J.EJAR.2021.05.001>
- Polgan, J. M., Arif, Z., & Lutfi, M. (2022). Identifikasi Kesegaran Ikan Berdasarkan Citra Insang dengan Metode Deep Convolution Neural Network. *Jurnal Minfo Polgan*, 11(2), 1–6. <https://doi.org/10.33395/JMP.V11I2.1163>

- 3
- Prasetyo, E., Purbaningtyas, R., Dimas Adityo, R., Prabowo, E. T., & Ferdiansyah, A. I. (2021). Perbandingan Convolution Neural Network Untuk Klasifikasi Kesegaran Ikan Bandeng Pada Citra Mata. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 8(3), 601–608. <https://doi.org/10.25126/JTIK.2021834369>
- Prasetyo, E., Suciati, N., & Fatichah, C. (2022). Yolov4-tiny with wing convolution layer for detecting fish body part. *Computers and Electronics in Agriculture*, 198, 107023. <https://doi.org/10.1016/J.COMPAG.2022.107023>
- Sa'dilah Fauzi. (2016, March). *Profil Komoditas Ikan Bandeng | Warta Pasar Ikan*.
- Sandi, G. D. K., Syauqy, D., & Maulana, R. (2020). Sistem Pendeteksi Kesegaran Ikan Bandeng Berdasarkan Bau Dan Warna Daging Berbasis Sensor Mq135 Dan Tcs3200 Dengan Metode Naïve Bayes. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer E-ISSN*, 2548(10), 964X.
- Saputra, S., Yudhana, A., & Umar, R. (2022). Identifikasi Kesegaran Ikan Menggunakan Algoritma KNN Berbasis Citra Digital. *Krea-TIF: Jurnal Teknik Informatika*, 10(1), 1–9. <https://doi.org/10.32832/KREA-TIF.V10I1.6845>
- Sarimin, M., Bettiza, M., Hayaty, N., & Nugraha, S. (2019). Implementasi HSV dan GLCM untuk Deteksi Kesegaran Ikan Bawal menggunakan Radial Basis Function Berbasis Android. *Jurnal Sustainable: Jurnal Hasil Penelitian Dan Industri Terapan*, 08(01), 1–7.
- Sena, S. (2018). *Pengenalan Deep Learning Part 7: Convolutional Neural Network (CNN) | by Samuel Sena | Medium*.
- Sena Samuel. (2017). *Pengenalan Deep Learning Part 1: Neural Network | by Samuel Sena | Medium*. 2017.
- Sholihin, M. (2021). Identifikasi Kesegaran Ikan Berdasarkan Citra Insang dengan Metode Convolution Neural Network. *JATISI (Jurnal Teknik Informatika Dan Sistem Informasi)*, 8(3), 1352–1360. <https://doi.org/10.35957/jatisi.v8i3.939>
- Siburian, E. T. P., Dewi, P., Kariada, N., Biologi, J., Mipa, F., & Semarang, U. N. (2012). Pengaruh Suhu dan Waktu Penyimpanan Terhadap Pertumbuhan Bakteri dan Fungi Ikan Bandeng. *Life Science*, 1(2).
- Styorini, W., Pratiwi, A., & Widiyari, C. (2022). Identifikasi Tingkat Kesegaran Ikan Berbasis Android. *Jurnal Amplifier : Jurnal Ilmiah Bidang Teknik Elektro Dan Komputer*, 12(1), 12–18. <https://doi.org/10.33369/JAMPLIFIER.V12I1.19174>
- Vasava, R. (2018). Nutritional and Feeding Requirement of Milk Fish (Chanos chanos). *International Journal of Pure & Applied Bioscience*, 6(2), 1210–1215. <https://doi.org/10.18782/2320-7051.6463>
- Widadi, R., Arifwidodo, B., Masykuroh, K., & Saputra, A. (2023). Klasifikasi Tingkat Kesegaran Ikan Nila Menggunakan K-Nearest Neighbor Berdasarkan Fitur Statistis Piksel Citra Mata Ikan. *Jurnal Media Informatika Budidarma*, 7(1), 242–249. <https://doi.org/10.30865/MIB.V7I1.5196>
- Younis, A., Shixin, L., Jn, S., & Hai, Z. (2020). *Real-Time Object Detection Using Pre-Trained Deep Learning Models MobileNet-SSD*. <https://doi.org/10.1145/3379247.3379264>
- Yumnam, M., Hatiboruah, D., Mishra, R., Sathyaseelan, K., Nath, P., & Mishra, P. (2023). A Smartphone-based optical sensor with polyaniline label for quantitative determination of freshness of freshwater fish fillets. *Sensors and Actuators A: Physical*, 361, 114557. <https://doi.org/10.1016/J.SNA.2023.114557>
- Zhao, X., Xu, T., Peng, L., Li, S., Zhao, Y., Liu, H., He, J., & Liang, S. (2023). Recognition and segmentation of teeth and mandibular nerve canals in panoramic dental X-rays by Mask RCNN. *Displays*, 78, 102447. <https://doi.org/10.1016/J.DISPLA.2023.102447>