

APLIKASI IDENTIFIKASI KESEGARAN IKAN BANDENG MENGUNAKAN CONVOLUTIONAL NEURAL NETWORK

¹ACHMAD NASRUL H, ²EKO PRASETYO, ³RANI PURBANINGTYAS

Informatika, Fakultas Teknik, Universitas Bhayangkara Surabaya

Jl. Ahmad Yani Frontage Road Ahmad Yani No.114, Ketintang, Kec. Gayungan, Kota SBY, Jawa Timur 60231

e-mail: ¹excusmy@gmail.com, ²eko@ubhara.ac.id, ³rani@ubhara.ac.id

ABSTRACT

Latar Belakang: Ikan bandeng merupakan ikan yang sudah menjadi komoditas unggulan beberapa kabupaten di Indonesia seperti Banten, Semarang, dan Sidoarjo. Bagi para pelaku industri pengolahan ikan bandeng, kesegaran ikan adalah hal yang sangat penting karena mempengaruhi kualitas produk olahan. Proses penyortiran secara manual dirasa kurang efektif karena jumlah ikan yang harus disortir cukup banyak. Selain rawan terjadi kesalahan karena human error, penyortiran secara manual juga membutuhkan biaya cukup besar dan waktu lama.

Tujuan: Tujuan penelitian untuk membuat aplikasi identifikasi kesegaran ikan bandeng menggunakan metode Convolutional Neural Network (CNN).

Metode : Menerapkan metode Convolutional Neural Network (CNN) dengan model MobileNetV2 dalam pembuatan program identifikasi kesegaran ikan bandeng yang nantinya berguna dalam menentukan tingkat kesegaran ikan bandeng dimasa mendatang

Hasil : pengujian aplikasi menggunakan metode *convolutional neural network* dengan model *MobileNetV2* pada klasifikasi kesegaran ikan bandeng dari 20 data uji untuk setiap kelas, diperoleh nilai akurasi sebesar 95 % pada kelas sangat segar 70 % pada kelas segar 80% pada kelas kurang segar.

Kesimpulan: Dengan hasil pengujian klasifikasi kesegaran ikan bandeng dari 20 data uji untuk setiap kelas, diperoleh nilai akurasi sebesar 95 % pada kelas sangat segar 70 % pada kelas segar 80% pada kelas kurang segar. serta pengujian yang dilakukan dengan data diluar dari dataset mendapatkan hasil dimana model tidak dapat mendeteksi beberapa bagian dari ikan bandeng seperti yang terdeteksi hanya bagian kepala saja ataupun hanya ekornya saja yang terdeteksi atau tidak sama sekali. kendala berikut dikarenakan kurangnya variasi data pada saat melakukan training pada model *MobileNetV2*. Dikarenakan pada penelitian ini menggunakan data yang terbatas jadi untuk pengujian menggunakan data diluar dataset dirasa kurang maksimal untuk hasilnya.

Kata Kunci : CNN, *Deep Learning*, Klasifikasi Citra, Bandeng, MobileNetV2

1. LATAR BELAKANG

Ikan bandeng atau yang biasa disebut dengan bahasa latin *Chanos-chanos* sudah menjadi komoditas unggulan beberapa kabupaten di Indonesia seperti Banten, Semarang, dan Sidoarjo.[1] Ikan ini menjadi kegemaran masyarakat karena kandungan gizi dari ikan ini sangat tinggi tetapi bisa didapatkan dengan harga yang terjangkau. Setiap 100 gram daging ikan bandeng mengandung 20 mg kalsium, 150 mg fosfor, 2 mg zat besi, 150 SI vitamin A, dan 0.05 mg vitamin B1[2].

Bagi para pelaku industri pengolahan ikan bandeng, kesegaran ikan adalah hal yang sangat penting karena mempengaruhi kualitas produk olahan[3]. Sedangkan bagi para pengeksportir ikan bandeng, kesegaran ikan bisa mempengaruhi kepuasan konsumen dan keberlanjutan proses ekspor. Proses penyortiran secara manual dirasa kurang efektif karena jumlah ikan yang harus disortir cukup banyak. Selain rawan terjadi kesalahan karena human error, penyortiran secara manual juga membutuhkan biaya cukup besar dan waktu lama[4]. Jika menginginkan waktu penyortiran yang singkat maka dibutuhkan tenaga penyortir yang banyak sehingga menyebabkan membengkaknya biaya.[5]

Seiring dengan kemajuan ilmu-ilmu pengetahuan dan teknologi, diperlukan cara mengetahui cara untuk mengetahui tingkat kesegaran ikan bandeng. Telah dilakukan beberapa diantaranya penelitian tentang pengolahan citra digital. *Deep learning* memiliki kemampuan yang sangat baik dalam pengolahan citra digital, salah satunya adalah penerapan algoritma *Convolutional Neural Network (CNN)*[6], [7]. Algoritma CNN menjadi populer di dalam teknik *Deep Learning* karena memiliki faktor penting seperti menghilangkan kebutuhan untuk ekstraksi fitur secara manual,[8] dapat dilatih kembali untuk tugas-tugas dalam pengenalan suatu objek baru yang memungkinkan untuk membangun di jaringan yang sudah ada sebelumnya, serta algoritma CNN juga mempunyai beberapa model diantaranya *CNN with 1 convolutional layer*,*CNN with 2 convolutional layer*,*CNN with 3 convolutional layer*, dan *CNN with 4 convolutional layer*. [9]

Kualitas ikan yang menurun bisa dilihat dari kulit ikan yang mengalami perubahan warna, mata, tekstur dari daging ikan, dan insang ikan[10]. Untuk mengatasi masalah tersebut dibutuhkan suatu metode dalam mengidentifikasi kesegaran ikan, serta untuk mengetahui jenis ikan yang masih segar dan ikan yang sudah tidak segar[11]. aplikasi pengolahan citra tentang penentu kesegaran ikan ini dipilih untuk ikut menjaga kesehatan tubuh manusia secara tidak langsung[12].

Berdasarkan penjelasan diatas, maka tujuan dari penelitian ini adalah menerapkan metode CNN dalam pembuatan program dalam melakukan identifikasi kesegaran ikan yang nantinya akan berguna dalam menentukan tingkat kesegaran ikan dimasa yang akan datang.

1.1 BATASAN MASALAH

1. Sistem yang dibangun pada aplikasi pada penelitian ini difokuskan pada Ikan Bandeng
2. Citra masukan adalah sebuah citra dengan syarat :
 - a. Menggunakan citra berwarna (bukan greyscale)
 - b. Tipe citra yang digunakan .jpg atau .jpeg.
 - c. Ukuran citra Minimum 236 x 332 Pixel dan Maximum 1487 x 991 Pixel
 - d. Menggunakan 252 data citra sebagai data latih dan 60 data citra sebagai data uji
3. Menggunakan Framework Tensorflow
4. Menggunakan Arsitektur CNN MobileNetV2

2. METODOLOGI PENELITIAN

2.1 Dataset

Pada penelitian ini data citra diperoleh dari melakukan pengambilan citra ikan bandeng menggunakan kamera dan mengumpulkan datanya selama 6 hari. terdapat 3 jenis kesegaran ikan bandeng berdasarkan hari dimana pengambilan gambar ikan bandeng.

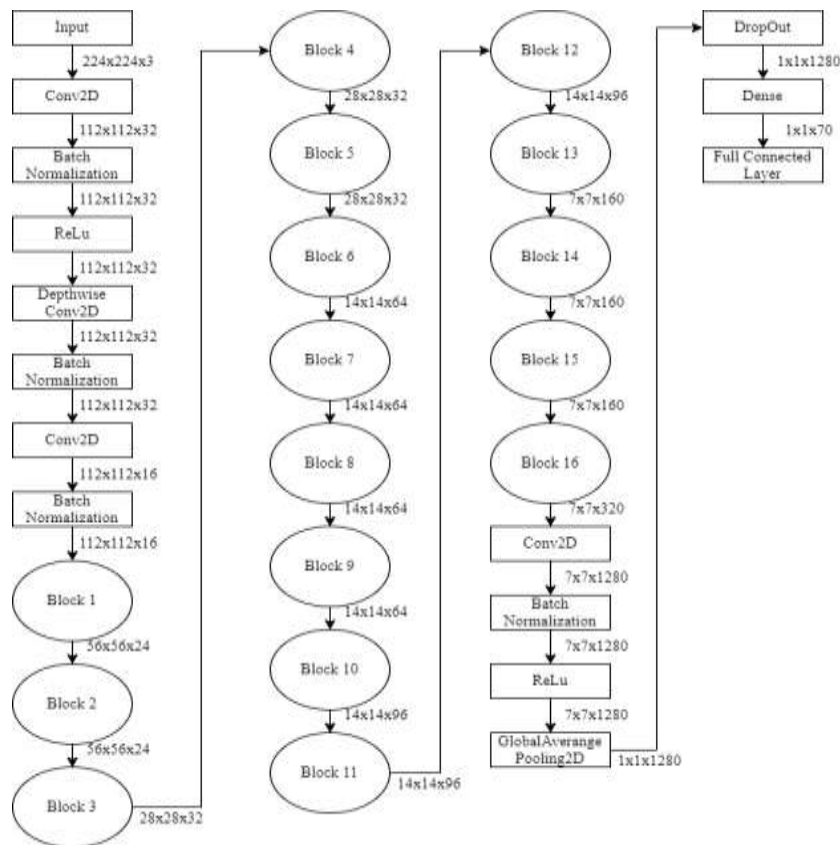
Table 1. Tingkat kesegaran ikan berdasarkan hari

Hari	Tingkat Kesegaran
1	Sangat Segar
2	
3	Segar
4	
5	Kurang Segar
6	

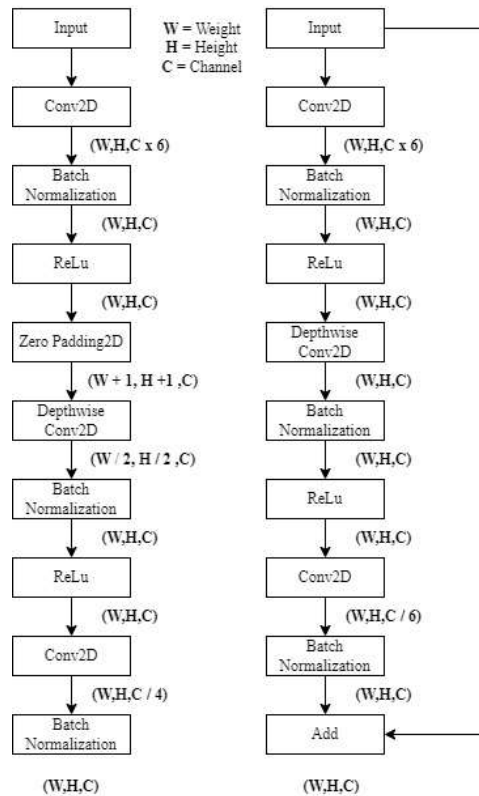
Tingkat kesegaran ikan bandeng pada tabel 1 menunjukkan bahwa pada hari pertama dan kedua kondisi ikan bandeng berada dalam tingkat kesegaran sangat segar, pada hari kedua dan ketiga kondisi ikan bandeng berada dalam tingkat kesegaran segar. Dan pada hari keempat dan kelima kondisi ikan bandeng berada dalam tingkat kesegaran tidak segar.

2.2 Pemodelan dan Pelatihan

Dalam pendekatan metode *transfer learning layer* untuk *feature extraction* menggunakan *layer* dari *MobileNetV2* yang terdiri atas 153 *Layer* serta dilanjut dengan *Full Connected Layer*



Gambar 1. Arsitektur lengkap pada model MobileNetV2



Gambar 2. Block Residual pada Arsitektur MobileNetV2

Pada Gambar 1 lapisan pertama, input gambar yang digunakan adalah gambar RGB dengan ukuran 244x244x3. Kemudian dilakukan proses konvolusi untuk mengekstraksi fitur-fitur yang ada pada gambar tersebut dengan menggunakan aktivasi ReLu. Setelah itu, dimensi gambar yang semula 244x244x3 akan berubah menjadi 112x112x32 sebelum masuk ke proses konvolusi selanjutnya. Proses selanjutnya adalah konvolusi depthwise, di mana pada tahap ini sebuah blok terdiri dari 1x1 pointwise convolution dan depthwise convolution. Depthwise digunakan untuk mengaplikasikan single filter tiap input channel sedangkan pointwise convolution digunakan untuk membuat kombinasi linear dari keluaran depthwise layer. Setelah itu dilakukan konvolusi sekali lagi dan yang terakhir adalah melakukan batch normalisasi pada setiap selesai melakukan konvolusi dengan hasil akhir dimensi gambar menjadi 112x112x16. Setelah melakukan proses konvolusi yang kedua kali, hasilnya akan dimasukkan ke dalam layer block residual. Pada block residual 1, 3, 6, dan 13 terjadi pengurangan resolusi karena proses konvolusi depthwise yang dilakukan. Kemudian setelah dilakukan 2 kali konvolusi biasa diantara depthwise konvolusi sebelum dan sesudah dilakukan depthwise konvolusi dan dilakukan batch normalisasi serta ditambahkan fungsi aktivasi ReLu pada setiap proses konvolusi yang dilakukan pada block pertama dan kedua. Setelah dilakukan residual block sebanyak 16 kali didapatkan hasil Feature Extraction dengan dimensi 7x7x1280. Setelah selesai dengan arsitektur inti dari MobileNetV2, dilakukan proses Penyelarasan input untuk masuk ke full 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 sigmoid. Sedangkan pada Gambar 2 bisa dilihat terdapat 2 jenis block residual yaitu block residual yang diawali dengan input dan diakhiri dengan batch normalisasi seperti konvolusi biasa dan yang satu lagi adalah block residual yang melakukan skip connection terhadap inputnya.

2.3 Single Shot Detector

Single Shot Detector (SSD) adalah salah satu jenis algoritma objek deteksi yang memungkinkan deteksi objek secara cepat dan efisien. Dalam objek deteksi, tugas utama adalah untuk menentukan lokasi dan jenis objek pada gambar atau video. Algoritma objek deteksi biasanya melibatkan dua tahap utama, yaitu: Ekstraksi fitur dan deteksi objek. Metode *Single Shot Detector* (SSD) ini termasuk kedalam deteksi objek secara *real time*. Arsitektur SSD termasuk kedalam jenis *Convolutional Neural Network* (CNN), yang merupakan salah satu jenis *Neural Network* yang biasa digunakan pada data citra. Arsitektur dari CNN dibagi menjadi 2 bagian besar, *Feature Extraction Layer* dan *Convolutional Layer*[13]. SSD memadukan kedua tahap ini menjadi satu proses inferensi tunggal. Proses ini mencakup prediksi objek dan lokasi mereka secara bersamaan, yang membuatnya lebih efisien dibandingkan dengan metode deteksi objek lainnya. SSD menggunakan jaringan neural untuk melakukan tahap ekstraksi fitur dan deteksi objek. SSD bekerja dengan memecahkan gambar menjadi banyak grid, dan setiap grid dievaluasi untuk menentukan apakah ada objek pada grid tersebut. Jika ada objek, maka algoritma akan menentukan lokasi dan jenis objek tersebut. Keunggulan SSD adalah kemampuannya untuk memproses gambar secara real-time, yang sangat penting bagi aplikasi deteksi objek dalam dunia nyata. Keunggulan SSD adalah kecepatannya dalam real-time objek deteksi, meskipun mungkin kurang akurat dibandingkan metode deteksi objek lain yang memiliki dua tahap terpisah.



Gambar 3. Image dengan Fitur SSD


2.4 OPTIMASI

Proses pelatihan membutuhkan pengaturan yang tepat agar berjalan dengan baik, dan dalam hal ini menggunakan optimasi momentum sebagai model dalam deep learning. Optimasi momentum bekerja dengan mengikuti gradien yang memiliki noise dan mengurangi ukuran langkah pada setiap iterasinya dengan menggunakan gradien stochastic untuk meminimalisasi fungsi kerugian yang dipilih dengan menggunakan fungsi linear. Untuk mengatur learning rate, digunakan metode Cosine Annealing yang memiliki efek dimulai dengan learning rate yang tinggi dan cepat dikurangi ke nilai minimum sebelum naik lagi. Dalam rangka memastikan proses pelatihan berjalan dengan baik, dilakukan pengaturan ulang learning rate dengan cara disebut warm restart. Proses ini bertindak seperti simulasi proses pembelajaran dan menggunakan kembali bobot yang baik sebagai titik awal. Bobot awal dalam hal ini adalah 0.79999999821186066, dan melakukan warm restart setiap 1000 step dengan pengurangan learning rate sebesar 0.02666660000485420227. Total step dalam proses pelatihan adalah 5000 kali.

2.5 PELATIHAN

2.5.1 Input Layer

Tahapan pertama dalam melakukan pelatihan terhadap model adalah memasukan data citra ikan ke *input layer*, pada *layer* ini citra gambar dikonversi kedalam matrix tiga dimensi, dengan ukuran panjang x lebar x 3 *channel RGB* (*Red, Green, Blue*). Pada penelitian ini nilai *RGB* pada setiap *pixel* dinormalisasi menjadi rentang 0-1 untuk mempermudah proses komputasi dengan cara membagi setiap nilai *RGB* setiap *pixel* dengan 255.



Gambar 4. Channel RGB Pada Citra Input

2.5.2 Convolution Layer

Data besaran nilai *RGB channel* pada setiap piksel kemudian diproses dilapisan konvolusi (*convolution layer*). Fungsi lapisan ini adalah untuk mengekstraksi fitur-fitur (*feature map*) yang ada pada citra dengan menggunakan filter. Sebagai contoh pada Gambar 5 adalah *input* citra pada *channel* warna merah (*red*). angka - angka tersebut mewakili besaran nilai intensitas warna merah pada citra gambar 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 5. Input Channel Merah (red)

Untuk mendapatkan fitur dari citra tersebut maka diperlukan proses konvolusi dengan filter, filter sendiri merupakan kumpulan nilai (*weight*) yang diinisiasi secara acak. Contoh Nilai filter terdapat pada gambar 6

2	2	2	2	2
1	1	1	1	1
0	0	0	0	0
-1	-1	-1	-1	-1
-2	-2	-2	-2	-2

Gambar 6. Contoh Filter

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

$$(W * x)_{m,n} = 23 \times 2 + 11 \times 2 + 70 \times 2 + 32 \times 2 + 99 \times 2 + 71 \times 1 + 8 \times 1 + 6 \times 1 + 76 \times 1 + 94 \times 1 + 9 \times (-1) + 41 \times (-1) + 50 \times (-1) + 50 \times (-1) + 25 \times (-1) + 18 \times (-1) + 11 \times (-2) + 39 \times (-2) + 40 \times (-2) + 11 \times (-2) + 40 \times (-2) = 240$$


$$y_{m,n} = g \left(\sum_j w_j x_j + b \right)$$

$$y_{0,1} = \max(241 + 1, 0) = 241$$


241
...
...
...
...

Gambar 7. Output Proses Konvolusi

Pada lapisan konvolusional terjadi proses ekstraksi fitur untuk menghasilkan peta fitur (*feature map*) pada data citra, untuk mendapatkan dan mengenal pola pada setiap citra. Proses ekstraksi fitur dilakukan dengan filter pada lapisan konvolusional dengan besaran sesuai dengan besaran kernel. Visualisasi terhadap nilai filter pada lapisan konvolusi pertama yang digunakan pada data ikan bandeng terdapat pada gambar 8. filter tersebut kemudian dikonvolusi dengan data *input* sehingga menghasilkan peta fitur yang dapat mendeteksi tepian (*edge*) yang membentuk pola (Gambar 8), proses konvolusi dan *pooling* yang dilakukan terus menerus akan membentuk pola yang lebih detail (Gambar 9).




Gambar 8. Feature map pada lapisan konvolusi



Gambar 9. Pola pada Feature map

2.5.3 Activation Function


Untuk mengenal objek dalam citra diperlukan pemisahan objek dengan latar belakang pada objek. Pada penelitian ini *activation function ReLu* digunakan untuk menentukan aktif tidaknya *neuron* pada *neural network* (Gambar 10). sehingga hanya *neuron* yang berhubungan dengan objek ikan saja yang dipilih . selain itu tujuan dari fungsi aktivasi adalah untuk menambahkan properti non linear ke fungsi, yang merupakan *neural network*



Gambar 10. Hasil dari Activation Function

2.5.4 Pooling Layer


Pooling Layer berfungsi untuk mengurangi ukuran spasial dari citra dan mengurangi jumlah parameter dan perhitungan dalam *neural network*. *Pooling layer* beroperasi pada setiap fitur secara independen. Pada lapisan ini menerima *input* dari hasil peta fitur (*feature map*) dari hasil proses konvolusi pada *convolutional layer*.



Gambar 11. Input Pooling Layer dan Output Pooling Layer

2.5.5 Fully Connected Layer

Tahap selanjutnya dari CNN adalah fully connected layer, tahapan awal pada fully connected layer adalah mengubah data matriks 3 dimensi pada tahap konvolusi menjadi 1 dimensi vektor (flatten). Nilai yang ada pada neuron(x) dikalkulasi dengan bobot (w) dan ditambahkan dengan bias (b), yang akan menentukan neuron selanjutnya (y). Gambaran keseluruhan neural network pada model ikan bandeng dapat dilihat pada Gambar 12



Gambar 12. Contoh Salah Satu Neural Network

Berikut adalah proses untuk mendapatkan nilai pada *neuron* tujuan (*y*) dengan menggunakan persamaan

$$y = g(0.6 * (-0.2) + 0.72 * 0.4 + 0.1 * 0.3 + 0.2) = 0.398$$

$$y = g(0.6 * 0.3 + 0.72 * 0.25 + 0.1 * (-0.1) + 0.2) = 0.55$$

2.5.6 Backpropagation

Tahap terakhir dari proses pelatihan *neural network* dalam satu iterasi (*epoch*) adalah *backpropagation*, yaitu proses untuk memperbaharui bobot dan bias untuk mengurangi *loss* secara keseluruhan pelatihan dengan metode *stochastic gradient descent* yang mana dalam pelatihan ini menggunakan *Coisine annealing*.semakin kecil *loss* maka akan semakin baik model dan semakin baik tingkat akurasi.










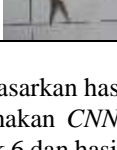
3. PENGUJIAN DAN PEMBAHASAN HASIL

Pengujian yang dilakukan pada sistem identifikasi kesegaran ikan bandeng adalah melakukan klasifikasi menggunakan *Convolutional Neural Network*, untuk membuktikan apakah hasil dari progam sama dengan hasil asli atau bahkan jauh berbeda dengan hasil hasil aslinya, maka dari itu perlu di uji coba dan dibandingkan hasil progam dengan hasil realnya. Pada penelitian ini menjalankan progam pada laptop untuk mendapatkan data uji sebanyak 20 citra untuk tiap kelasnya . setelah mendapatkan citra lanjut untuk melakukan pengklasifikasian dengan mengupload citra pada data uji Seperti pada gambar 13. Dan mencatat setiap prediksi yang benar dan prediksi yang salah, kemudian hasil tersebut dikumpulkan dan digunakan untuk menghitung nilai akurasi pada setiap tingkat kesegaran ikan



Gambar 13. Tampilan Hasil Klasifikasi

Table 2. Hasil Pengujian Klasifikasi Menggunakan CNN

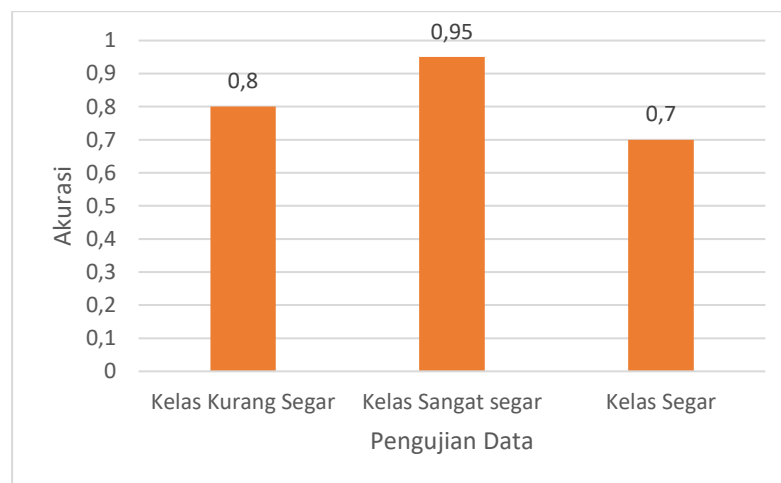
No	Citra	Kelas Asli	Hasil Klasifikasi Menggunakan CNN						Hasil
			Sangat Segar		Segar		Kurang Segar		
			Ekor	Kepala	Ekor	Kepala	Ekor	Kepala	
1		Sangat Segar	√	√					Benar
2		Sangat Segar	√	√					Benar
3		Sangat Segar	√	√					Benar
4		Segar		√	√				Salah
5		Segar	√	√					Salah
6		Segar			√	√			Benar
7		Kurang Segar					√	√	Benar
8		Kurang Segar	√					√	Salah
9		Kurang Segar					√	√	Benar
10		Kurang Segar	√	√					Salah

Berdasarkan hasil pengujian pada citra bandeng secara acak dapan dilihat pada tabel 2, pengujian citra bandeng menggunakan CNN Model *MobileNetV2* Mendapatkan hasil yang cukup baik dinama mendapatkan hasil benar sebanyak 6 dan hasil salah sebanyak 4 dari data berikut dapat disimpulkan bahwa CNN Model *MobileNetV2* Cukup baik untuk mendeteksi tingkat kesegaran ikan bandeng berdasarkan Kepala dan Ekor.

Berdasarkan pengujian yang dilakukan tiap kelas, maka didapatkan hasil akurasi tertinggi pada pengujian kelas ikan bandeng sangat segar dengan nilai akurasi 95% dan hasil akurasi terendah pada kelas bandeng segar dengan nilai akurasi 70% dan dapat dilihat pada tabel 2 dan Gambar 14

Table 2. Hasil Pengujian Tiap Kelas

Pengujian Data	Hasil Benar	Tingkat Akurasi	Hasil Salah	Tingkat Error
Kelas Sangat segar	19	95%	1	5%
Kelas Segar	14	70%	6	30%
Kelas Kurang Segar	16	80%	4	20%



Gambar 14. Grafik Hasil Pengujian Tiap Kelas kesegaran Ikan

4. KESIMPULAN

Berdasarkan hasil uji coba sistem klasifikasi kesegaran ikan bandeng diperoleh kesimpulan sebagai berikut :

1. Berdasarkan hasil pengujian aplikasi menggunakan metode *convolutional neural network* dengan model *MobileNetV2* pada klasifikasi kesegaran ikan bandeng dari 20 data uji untuk setiap kelas, diperoleh nilai akurasi sebesar 95 % pada kelas sangat segar, 70 % pada kelas segar 80%, pada kelas kurang segar. Dari hasil akurasi tersebut bisa disimpulkan bahwa aplikasi sudah cukup baik untuk mengidentifikasi kesegaran ikan bandeng berdasarkan tingkat kesegaran perharinya.
2. Pengujian yang dilakukan dengan data diluar dari dataset mendapatkan hasil dimana model tidak dapat mendeteksi beberapa bagian dari ikan bandeng seperti yang terdeteksi hanya bagian kepala saja ataupun hanya ekornya saja yang terdeteksi atau tidak sama sekali. kendala berikut dikarenakan kurangnya variasi data pada saat melakukan training pada model *MobileNetV2*. Dikarenakan pada penelitian ini menggunakan data yang terbatas jadi untuk pengujian menggunakan data diluar dataset dirasa kurang maksimal untuk hasilnya.

REFERENCES

- [1] E. T. P. Siburian, P. Dewi, N. Kariada, J. Biologi, F. Mipa, and U. N. Semarang, "Pengaruh Suhu dan Waktu Penyimpanan Terhadap Pertumbuhan Bakteri dan Fungi Ikan Bandeng," *Life Sci.*, vol. 1, no. 2, 2012.
- [2] Sa'dilah Fauzi, "Profil Komoditas Ikan Bandeng | Warta Pasar Ikan," Mar. 02, 2016. <http://wpi.kkp.go.id/?q=node/46> (accessed Dec. 15, 2021).
- [3] G. D. K. Sandi, D. Syauqy, and R. Maulana, "Sistem Pendeteksi Kesegaran Ikan Bandeng Berdasarkan Bau Dan Warna Daging Berbasis Sensor Mq135 Dan Tcs3200 Dengan Metode Na $\{ \backslash "i\}$ ve Bayes," *J. Pengemb. Teknol. Inf. dan Ilmu Komput. e-ISSN*, vol. 2548, no. 10, p. 964X, 2020.
- [4] A. Agustyawan, "Pengolahan Citra untuk Membedakan Ikan Segar dan Tidak Segar Menggunakan Convolutional Neural Network," *Indones. J. Appl. Informatics*, vol. 5, no. 1, p. 11, Nov. 2021, doi: 10.20961/ijai.v5i1.41770.
- [5] M. Sarimin, M. Bettiza, N. Hayaty, and S. Nugraha, "Jurnal Sustainable : Jurnal Hasil Penelitian dan Industri Terapan Implementasi HSV dan GLCM untuk Deteksi Kesegaran Ikan Bawal menggunakan Radial Basis Function Berbasis Android," vol. 08, no. 01, pp. 1–7, 2019.
- [6] Sena Samuel, "Pengenalan Deep Learning Part 1 : Neural Network | by Samuel Sena | Medium," 2017, 2017. <https://medium.com/@samuelsena/pengenalan-deep-learning-8fbb7d8028ac> (accessed Dec. 22, 2021).
- [7] S. Sena, "Pengenalan Deep Learning Part 7 : Convolutional Neural Network (CNN) | by Samuel Sena | Medium," 2018. <https://medium.com/@samuelsena/pengenalan-deep-learning-part-7-convolutional-neural-network-cnn-b003b477dc94> (accessed Dec. 22, 2021).
- [8] R. O. Ekoputris, "MobileNet: Deteksi Objek pada Platform Mobile | by Rizqi Okta Ekoputris | Nodeflux | Medium," 9 May 2018, May 09, 2018. <https://medium.com/nodeflux/mobilenet-deteksi-objek-pada-platform-mobile-bbbf3806e4b3> (accessed Dec. 15, 2021).
- [9] J. M. Polgan, Z. Arif, and M. Lutfi, "Identifikasi Kesegaran Ikan Berdasarkan Citra Insang dengan Metode Deep Convolution Neural Network," *J. Minfo Polgan*, vol. 11, no. 2, pp. 1–6, Aug. 2022, doi: 10.33395/JMP.V11I2.11633.
- [10] M. Sholihin, "Identifikasi Kesegaran Ikan Berdasarkan Citra Insang dengan Metode Convolution Neural Network," *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 8, no. 3, pp. 1352–1360, 2021, doi: 10.35957/jatisi.v8i3.939.
- [11] N. W. R. Situmorang, "Penerapan Metode K-Nearest Neighbor dalam Identifikasi Kesegaran Ikan," 2019, Accessed: Dec. 15, 2021. [Online]. Available: <https://repositori.usu.ac.id/handle/123456789/16143>.
- [12] T. Wijayanti, "Aplikasi Pengolahan Citra untuk Menentukan Kesegaran Ikan Dilihat dari Insang," 2017, [Online]. Available: https://www.google.com/url?sa=t&source=web&rct=j&url=http://repository.untag-sby.ac.id/715/8/JURNAL.pdf&ved=2ahUKEwi_27Gp6LDoAhX_8HMBHXxYD-YQFjABegQIBRAI&usq=AOvVaw2pP_oc6_qnJrH7UyAD5S5_&cshid=1584974047738.
- [13] A. Younis, L. Shixin, S. Jn, and Z. Hai, "Real-Time Object Detection Using Pre-Trained Deep Learning Models MobileNet-SSD," 2020, doi: 10.1145/3379247.3379264.