

PERBANDINGAN CONVOLUTION NEURAL NETWORK UNTUK KLASIFIKASI KESEGERAN IKAN BANDENG PADA CITRA MATA

Eko Prasetyo^{*1}, Rani Purbaningtyas², Raden Dimas Adityo³, Enrico Tegar Prabowo⁴, Achmad Irfan Ferdiansyah⁵

^{1,2,3,4,5}Program Studi Teknik Informatika, Fakultas Teknik, Universitas Bhayangkara Surabaya
Email: ¹eko@ubhara.ac.id, ²rpurbaningtyas@ubhara.ac.id, ³dimas@ubhara.ac.id, ⁴enricotegar10@gmail.com, ⁵ferdiansyahirfan9@gmail.com
^{*}Penulis Korespondensi

(Naskah masuk: 24 November 2020, diterima untuk diterbitkan: 10 Juni 2021)

Abstrak

Ikan merupakan salah satu sumber protein hewani dan sangat diminati masyarakat Indonesia. Dari survey bahan makanan yang diminati, bandeng peringkat keempat dibanding bahan makanan yang lain. Khususnya ikan bandeng, ikan ini menjadi satu dari enam ikan yang banyak dikonsumsi masyarakat selain tongkol, kembung, teri, mujair dan lele, maka ketelitian masyarakat ketika membeli ikan bandeng menjadi perhatian serius dalam memilih ikan bandeng segar. Deteksi kesegaran dengan menyentuh tubuh ikan dapat mengakibatkan kerusakan tanpa disengaja, maka deteksi kesegaran ikan harus dilakukan tanpa menyentuh ikan bandeng dengan memanfaatkan citra kondisi mata. Dalam riset ini, kami melakukan eksperimen implementasi klasifikasi kesegaran ikan bandeng (sangat segar dan tidak segar) berdasarkan mata menggunakan transfer learning dari empat CNN, yaitu Xception, MobileNet V1, Resnet50, dan VGG16. Dari hasil eksperimen klasifikasi dua kelas kesegaran ikan bandeng menggunakan 154 citra menunjukkan bahwa VGG16 mencapai kinerja terbaik dibanding arsitektur lainnya dimana akurasi klasifikasi mencapai 0.97. Dengan akurasi lebih tinggi dibanding arsitektur lainnya maka VGG16 relatif lebih tepat digunakan untuk klasifikasi dua kelas kesegaran ikan bandeng.

Kata kunci: kesegaran ikan, bandeng, klasifikasi, convolution neural network, transfer learning

A COMPARISON OF CONVOLUTION NEURAL NETWORK FOR CLASSIFYING MILKFISH'S FRESHNESS ON EYE IMAGES

Abstract

Fish, one source of animal protein, is an exciting food for Indonesia's people. From a survey of food-ingredients demanded, milkfish are ranked fourth compared to other food-ingredients. Especially for milkfish, this fish is one of the six fish consumed by Indonesia's people besides tuna, bloating, anchovies, tilapia, and catfish, so the exactitude of the people when buying is a severe concern in choosing fresh milkfish. Detection of freshness by touching the fish's body may cause unexpected destruction, so detecting the fish's freshness should be conducted without touching using the eye image. In this research, we conducted an experimental implementation of freshness milkfish classification (vastly fresh and not fresh) based on the eyes using transfer learning from several CNNs, such as Xception, MobileNet V1, Resnet50, and VGG16. The experimental results of the classification of two milkfish freshness classes using 154 images show that VGG16 achieves the best performance compared to other architectures, where the classification accuracy achieves 0.97. With higher accuracy than other architectures, VGG16 is relatively more appropriate for classifying two classes of milkfish freshness.

Keywords: fish freshness, milkfish, classification, convolution neural network, transfer learning

1. PENDAHULUAN

Ikan merupakan salah satu sumber protein hewani yang baik bagi manusia, apalagi masyarakat Indonesia, ikan menjadi lauk yang sangat diminati. Hasil survey konsumsi makanan masyarakat Indonesia oleh Badan Pusat Statistik (BPS) (Badan Pusat Statistik Indonesia, 2015) pada tahun 2015,

ikan menempati peringkat keempat setelah makanan dan minuman jadi, rokok, dan padi-padian. Lebih dalam lagi, dibandingkan dengan daging dan telur, konsumsi ikan jauh lebih tinggi, rata-rata per kapita sebulan sebesar Rp 35.110,-, Rp 27.912,-, dan Rp 21.157,- masing-masing untuk ikan, telur dan daging (survey dilakukan pada September 2015). Hal ini

membuktikan bahwa untuk lauk, masyarakat Indonesia lebih gemar ikan daripada lauk lainnya. Hal ini didukung oleh tingkat kebutuhan ikan nasional, data dari BPS tahun 2017 menyebutkan bahwa kebutuhan produksi ikan nasional sebesar 10.38 juta ton (Kelautan dan Perikanan, 2016). Dari kelompok ikan yang menjadi pilihan masyarakat, bandeng menjadi pilihan konsumsi sebagai lauk makanan, data dari BPS (Badan Pusat Statistik Indonesia, 2015) menyebutkan bahwa bandeng menjadi satu dari enam ikan yang banyak dikonsumsi masyarakat selain tongkol, kembung, teri, mujair dan lele. Dengan kebutuhan tinggi bagi masyarakat maka ketelitian masyarakat ketika membeli ikan bandeng menjadi perhatian serius dalam memilih ikan bandeng segar. Pada umumnya, ikan yang dijual di pasar adalah ikan segar, tetapi tidak jarang ditemukan ikan bandeng tidak segar yang sudah mengalami pengawetan dengan es selama beberapa hari. Kesegaran ikan dapat diamati dari penampilan luar, mata, atau insang (Ilyas, 1983). Mata ikan bandeng segar akan terlihat dari ciri selaput bening mata dimana permukaan cembung, sedangkan ikan tidak segar terlihat selaput kecoklatan dan permukaan mulai cekung. Penelitian sebelumnya yang dilakukan oleh (Prasetyo, R. Dimas Adityo and Purbaningtyas, 2019) (Prasetyo, Purbaningtyas and Dimas Adityo, 2020) baru melakukan identifikasi obyek mata ikan bandeng sebagai basis untuk klasifikasi kesegaran ikan bandeng, hasilnya akan diproses menggunakan metode klasifikasi konvensional seperti Support Vector Machine (SVM) atau yang lain. Maka penelitian ini menggunakan pendekatan Convolutional Neural Network (CNN) untuk membantu penyelesaian masalah deteksi kesegaran ikan bandeng dengan fokus pada bagaimana klasifikasi kesegaran ikan bandeng berdasarkan kondisi mata menggunakan CNN.

CNN saat ini menjadi topik penelitian yang banyak dikembangkan, termasuk untuk klasifikasi ikan. Penelitian yang dilakukan oleh (Darmanto, 2019) mengembangkan sistem untuk mendeteksi jenis ikan berdasarkan citra *contour otolith* menggunakan *transfer learning* dari AlexNet. Dengan menerapkan pada 403 citra 14 jenis (3 famili) dicapai kinerja akurasi 100% pada family Sciaenidae, 94.45% pada family Ariidae, 100% pada family Engraulidae, dan 95,4% pada semua family. Klasifikasi kesegaran ikan Scolopsis monogramma menggunakan CNN dilakukan dalam penelitian (Saputra, Matulatan and Hayaty, 2020) menggunakan tiga kali konvolusi dan *maxpooling*, sedangkan klasifikasi menggunakan dua *fully connected* layer dan satu layer klasifikasi. Kinerja akurasi yang dicapai sistem hingga 72.15%. Penelitian tingkat kesegaran ikan juga dilakukan dalam oleh (Dwiyatno, Iksal and Nugraha, 2018) menggunakan metode K-Nearest Neighbor dan mikrokontroler ATMEGA 328 berdasarkan nilai warna RGB. Kinerja sistem yang dikembangkan

mencapai akurasi hingga 73.33%. Sistem deteksi kesegaran ikan bandeng juga dikembangkan oleh (Prayogi, Wibisono and Abror, 2019) menggunakan ruang warna RGB. Pada sistem tersebut, akuisisi menggunakan kamera dari perangkat ponsel, dengan menggunakan metode klasifikasi SVM, sistem ini dapat mencapai akurasi hingga 98.2%.

Penyelesaian masalah klasifikasi citra dengan jumlah data tinggi dapat mencapai kinerja optimal ketika menggunakan pendekatan CNN, tetapi untuk jumlah data rendah biasanya menggunakan pendekatan *transfer learning* dari *pre-trained* arsitektur CNN yang sudah tersedia. Pre-trained CNN yang tersedia dan banyak digunakan diantaranya adalah VGG (Simonyan and Zisserman, 2015) sebagai perbaikan dari AlexNet (Krizhevsky, Sutskever and Hinton, 2012), ResNet dikenalkan dengan konsep residu fitur (He *et al.*, 2016), MobileNet dengan klaim memberikan arsitektur lebih sederhana tetapi handal dalam kinerja (Howard *et al.*, 2017), dan sejumlah arsitektur lainnya seperti Xception (Chollet, 2017), DenseNet (Huang *et al.*, 2017), Inception V3 (Szegedy *et al.*, 2016), dan EfficientNet (Tan and Le, 2019) yang mengenalkan arsitektur dengan pertimbangan paduan kedalaman, lebar, dan resolusi. Transfer learning dilakukan dengan memindahkan model CNN yang sudah dilatih dengan dataset original untuk menyelesaikan kasus pada dataset lainnya.

Penelitian sebelumnya dalam klasifikasi kesegaran ikan bandeng hanya mengandalkan fitur warna dan metode klasifikasi konvensional seperti SVM, meskipun ada yang menggunakan pendekatan CNN tetapi hanya menggunakan Alexnet dan penerapan pada jenis ikan Scolopsis saja. Belum ada penelitian lebih lanjut yang menggunakan pendekatan CNN dengan dukungan arsitektur yang tepat. Pendekatan CNN mengakibatkan terjadinya integrasi antara pembangkitan fitur dan klasifikasi dalam satu sistem. Maka untuk membangkitkan fitur yang terintegrasi dengan klasifikasi, maka dalam penelitian ini kami melakukan percobaan pengembangan sistem klasifikasi kesegaran ikan bandeng menggunakan CNN. Kami menerapkan transfer learning pada beberapa arsitektur CNN yang banyak dikenal seperti Xception, MobileNet V1, Resnet50, dan VGG16. Pembangkitan fitur dari konvolusi dilakukan secara internal oleh CNN sesuai dengan rancangan arsitektur. Layer klasifikasi dilakukan dengan mengintegrasikan *fully-connected* multi layer perceptron. Percobaan dilakukan dengan menerapkan transfer learning untuk menyelesaikan klasifikasi kesegaran ikan bandeng pada pre-trained CNN yang tersedia. Percobaan pada berbagai CNN adalah untuk menguji arsitektur CNN yang tepat untuk digunakan untuk klasifikasi kesegaran ikan bandeng berdasarkan kondisi mata.

2. METODE PENELITIAN

2.1. Dataset


Penelitian ini menggunakan dataset foto mata ikan bandeng yang diambil dari pasar ikan di Kota Gresik. Pemotretan dilakukan menggunakan kamera ponsel pada ikan sangat segar (hari pertama dan kedua) dan ikan segar (hari ketiga dan keempat) dan ikan tidak segar (hari kelima dan keenam). Jumlah citra ikan sangat segar, segar, dan tidak segar masing-masing adalah 74, 80, 80 citra. Resolusi citra akuisisi ikan bandeng adalah 4160 x 3120 piksel, seperti yang digunakan oleh (Prasetyo, Raden Dimas Adityo and Purbaningtyas, 2019), selanjutnya kami melakukan *cropping* bagian mata pada citra tersebut dengan ukuran bervariasi dari 250x250 piksel hingga 290x290 piksel. Untuk percobaan awal penelitian pada sistem CNN ini, kami membatasi penggunaan data dua kelas yaitu sangat segar dan tidak segar, sehingga total ada 154 citra. Dalam eksperimen, kami membagi citra menjadi tiga bagian yaitu latih, validasi, dan uji dengan proporsi masing-masing 60%, 20%, dan 20%, seperti disajikan pada Tabel 1.

2.2 Transfer learning dengan Fine Tuning

Dalam CNN, misalnya pada kasus klasifikasi citra, citra ibarat seperti makanan bagi CNN, semakin banyak citra yang dilatihkan maka kematangan model akan tercapai untuk menyelesaikan masalah dengan kinerja optimal. Bagi dataset berukuran besar tentu tidak menjadi masalah, tetapi bagi dataset berukuran kecil tidak dapat mencapai kinerja optimal. Maka dari itu, *transfer learning* menjadi pendekatan bagi dataset berukuran kecil untuk mencapai kinerja optimal. *Transfer learning* adalah pendekatan CNN, misalnya dalam klasifikasi, dengan memindahkan model yang sudah terlatih pada sebuah dataset, biasanya menggunakan Imagenet, untuk menyelesaikan masalah lainnya. Fine tuning merupakan teknik *transfer learning* dengan menerapkan pelatihan ulang pada bagian akhir blok konvolusi dan membiarkan (tidak dilatih ulang) layer konvolusi lainnya. Pelatihan ulang sebagian layer akhir bertujuan untuk memberikan generalisasi CNN pada dataset lain dan tetap mempertahankan generalisasi pada dataset original.

Tabel 1. Dataset mata ikan bandeng dan proporsi pembagian data

No.	Kelas	Jumlah	Latih	Validasi	Uji
1	Sangat segar	74	44	15	15
2	Tidak segar	80	48	16	16



a. Sangat segar b. Tidak segar
Gambar 1. Citra mata ikan bandeng

Banyak penelitian yang menerapkan transfer learning. Riset yang dilakukan oleh (Abu Mallouh, Qawaqneh and Barkana, 2019) mendeteksi usia dari wajah menggunakan dua rancangan arsitektur CNN yang diusulkan, kemudian membandingkan kinerjanya dengan *pre-trained* CNN seperti GoogLeNet, ResNet, dan VGG. CNN pembanding tersebut menerapkan transfer learning dari *pre-trained* masing-masing. Riset yang dilakukan oleh (Deepak and Ameer, 2019) menerapkan transfer learning dari GoogLeNet untuk mengklasifikasi citra MRI pasien menjadi tiga jenis tumor otak. Kinerja sistem yang diusulkan menunjukkan hasil optimal dan mengungguli hasil pada riset sebelumnya. Riset yang dilakukan oleh (Sharma, Berwal and Ghai, 2019) melakukan transfer learning dengan fine tuning untuk mengklasifikasi penyakit pada citra daun tomat. Hasilnya, model yang dilatih dengan citra tomas tersegmentasi lebih unggul dibanding tidak tersegmentasi. (Vasan *et al.*, 2020) juga menggunakan transfer learning dengan *fine tuning* untuk mendeteksi malware dalam jaringan komputer. Hasilnya, sistem dapat mencapai akurasi klasifikasi hingga 98.82%.

2.3 Pre-trained CNN


Banyak arsitektur CNN yang sudah dikembangkan peneliti sebelumnya. VGG16 diusulkan oleh (Simonyan and Zisserman, 2015) dengan meningkatkan kinerja ZFNet untuk klasifikasi citra Imagenet menggunakan parameter CNN. ResNet diusulkan oleh (He *et al.*, 2016) dengan memperkenalkan konsep *residual convolution* dimana hasil konvolusi layer bawah masih digunakan oleh konvolusi layer atas. MobileNet diusulkan oleh (Howard *et al.*, 2017) dengan memperkenalkan konsep *deep separable convolution* yang menawarkan konvolusi lebih ringan karena menggunakan lebih sedikit parameter tetapi menawarkan kinerja lebih optimal serta ukuran model lebih kecil. Xception diusulkan oleh (Chollet, 2017) dengan membalik konsep deepwise separable convolution dimana urutan konvolusi adalah point wise dilanjutkan *channel-wise convolution*. Dalam penelitian ini kami melakukan *transfer learning* menggunakan *pre-trained* CNN tersebut dengan melatih ulang menggunakan dataset kami. Pelatihan ulang dilakukan pada 8 layer akhir konvolusi bersama dengan layer klasifikasi.

2.4 Kerangka kerja klasifikasi kesegaran ikan bandeng dengan transfer learning

Dalam penelitian ini, kami melakukan *transfer learning* dari arsitektur CNN yang sudah dilatih sebelumnya (*pre-trained* CNN) untuk menyelesaikan masalah klasifikasi kesegaran ikan bandeng berdasarkan mata. Seperti ditunjukkan pada Gambar 2, *pre-trained* CNN sudah dilatih menggunakan dataset awal, biasanya Imagenet (dataset berisi jutaan citra dan ribuan kelas), kemudian CNN tersebut

diterapkan pada dataset mata ikan untuk menyelesaikan masalah klasifikasi kesegaran ikan bandeng. Pendekatan *transfer learning* ini tepat digunakan pada kasus ini karena jumlah data sangat sedikit, dimana jumlah citra pada dataset adalah 154 citra. Arsitektur CNN umumnya terdiri dari dua bagian utama, bagian pertama adalah konvolusi dan ekstraksi fitur, bagian kedua adalah klasifikasi. Bagian konvolusi inilah yang biasanya ditransfer untuk menyelesaikan kasus lainnya. Pada bagian konvolusi selalu menggunakan mask (W_1, \dots, W_n) pada tiap layer untuk melakukan filter pada tiap tahap konvolusi. Diakhir bagian konvolusi, model disambung dengan layer klasifikasi untuk melakukan klasifikasi citra (bisa menggunakan *fully-connected layer* atau metode klasifikasi lainnya) menjadi sejumlah kelas dataset. Pada penelitian ini kami menggunakan klasifikasi dua kelas: sangat segar dan tidak segar.

Kerangka kerja klasifikasi kesegaran ikan bandeng menggunakan *transfer learning* CNN ditunjukkan pada Gambar 2. Sistem dimulai dengan arsitektur CNN yang sudah dilatih menggunakan dataset Imagenet (dataset dengan jutaan jumlah data dan ribuan kelas). Arsitektur ini banyak dikembangkan oleh peneliti lain sebelumnya, seperti Xception, ResNet, VGG, atau MobileNet. Kemudian *pre-trained* CNN tersebut dipindahkan ke arsitektur yang kami kembangkan untuk dilatih menggunakan dataset mata ikan bandeng. Kami menerapkan *fine-tuning* dengan tidak melakukan pelatihan ulang pada semua layer bagian konvolusi. Ada delapan layer akhir bagian konvolusi yang dilatih ulang, sedangkan sisanya tidak dilatih ulang untuk menjaga sifat generalisasi dataset sebelumnya yang umumnya dapat diterapkan untuk menyelesaikan masalah lainnya.



Gambar 2. Kerangka kerja klasifikasi kesegaran ikan bandeng menggunakan *transfer learning* CNN

Tabel 2. Hyperparameter CNN


No.	Hyperparameter	Nilai
1	Jumlah neuron pada hidden fully connected layer	1024
2	Dropout	0.1
3	Optimizer	RMSprop
4	Learning rate	1e-5
5	Loss function	Binary cross entropy
6	Epoch	100
7	Step per epoch	10
8	Batch size	8

Kami melakukan percobaan *transfer learning* pada arsitektur CNN sebagai berikut: Xception (Chollet, 2017), VGG (Simonyan and Zisserman, 2015), ResNet50 (He *et al.*, 2016), dan MobileNet V1 (Howard *et al.*, 2017) untuk melakukan klasifikasi kesegaran ikan bandeng menggunakan dataset mata ikan bandeng. Pada eksperimen ini kami juga mengatur hyperparameter CNN seperti disajikan pada Tabel 2. Kami melakukan penyesuaian hyperparameter selama eksperimen sebagai berikut: jumlah neuron pada *fully connected* layer 1024 neuron, dropout 0.1, optimizer menggunakan RMSprop, learning rate 1e-5, loss function menggunakan binary cross entropy, epoch 100 kali, step per epoch juga 10, dan batch size disesuaikan menjadi 8.

3. HASIL DAN PEMBAHASAN

3.1. Hasil Eksperimen Pelatihan

Kami melakukan percobaan dengan eksperimen pelatihan pada empat CNN sebagai berikut: Xception, ResNet50, MobileNet V1, dan VGG16, hasilnya disajikan pada Gambar 2. Dalam eksperimen ini kami melakukan pelatihan 100 epoch dengan hyperparameter seperti pada Tabel 2. Dari gambar tersebut, dapat dilihat bahwa Xception mengalami *overfitting* dimana grafik akurasi pelatihan terus bergerak naik sejak iterasi pertama. Meskipun akurasi pelatihan selalu naik dan turun tetapi mempunyai kecenderungan naik, sedangkan akurasi validasi tidak dapat naik sejak epoch ke-40. Perilaku akurasi validasi juga naik dan turun tetapi semakin jauh dari akurasi pelatihan sejak epoch ke-40. Grafik proses pelatihan yang ditunjukkan oleh MobileNet V1 dan ResNet50 mempunyai pola pergerakan yang mirip, keduanya juga naik dan turun tetapi cenderung naik dari epoch ke epoch selanjutnya. Pola pergerakan kinerja yang ditunjukkan oleh VGG16 ada kemiripan dengan MobileNet V1 dan ResNet50, tetapi fluktuasi VGG16 sangat tinggi. Hal berbeda yang ditunjukkan oleh VGG16 adalah bahwa VGG16 dapat mencapai akurasi 1.00 ketika epoch mencapai sekitar 58. Hasil akhir semua CNN yang kami uji menunjukkan bahwa VGG16 mencapai kinerja terbaik.



Gambar 3. Grafik pelatihan 100 epoch

Tabel 3. Kinerja diakhir pelatihan

No.	Arsitektur	Akurasi	
		Latih	Validasi
1	Xception	0.9200	0.6774
2	MobileNet V1	0.8600	0.7742
3	ResNet50	0.9700	0.9032
4	VGG16	0.9800	1.00

Secara umum, dari empat CNN yang kami gunakan, Xception menunjukkan hasil yang kurang baik karena mengalami *overfitting*, kemungkinan bisa disebabkan arsitektur terlalu kompleks atau jumlah dan variasi dataset terbatas. MobileNet V1 dan ResNet50 menunjukkan kinerja selama pelatihan kurang optimal dimana ini ditunjukkan dari akurasi lebih lambat mencapai hasil yang baik. Berbeda dengan VGG16, dimana VGG16 sebenarnya sudah mencapai akurasi validasi lebih dari 90% pada epoch 30, dan mencapai akurasi validasi 100% berulang kali sejak epoch 55, kemudian terus naik dan turun. Di akhir epoch, VGG16 mencapai akurasi validasi 100%.

Kinerja CNN pada akhir epoch pelatihan, seperti disajikan pada Tabel 3, dapat diamati bahwa secara urut akurasi pelatihan tertinggi dicapai oleh VGG16, ResNet50, Xception, dan MobileNet V1 masing-masing sebesar 0.98, 0.97, 0.92 dan 0.86. Kinerja validasi tertinggi juga dicapai oleh VGG16, kemudian diikuti oleh ResNet50, MobileNet V1, dan Xception masing-masing sebesar 1.00, 0.90, 0.77, dan 0.67. Jika dibandingkan hanya pada sesi validasi, sebenarnya ada dua kelompok kinerja yaitu kelompok tinggi dicapai oleh VGG16 dan ResNet50, dan kelompok rendah dicapai oleh MobileNet V1 dan Xception. Kelompok tinggi disini disebabkan akurasi diatas 0.9 sedangkan kelompok rendah mencapai akurasi dibawah 0.9. Jadi secara umum pada sesi validasi, VGG16 dan ResNet50 mencapai kinerja tinggi tetapi VGG16 mencapai kinerja terbaik, bahkan sempurna dengan akurasi 1.00.

3.2. Hasil Pengujian

Jika data validasi digunakan sebagai kontrol kinerja pada proses pelatihan dan selalu dilihat pada tiap epoch, maka data uji merupakan data yang belum pernah dilihat oleh CNN selama pelatihan. Artinya, data ini dapat menjadi tolak ukur ketika sistem diimplementasikan pada kasus nyata. Adakalanya, sebuah sistem mempunyai kinerja yang baik pada saat eksperimen, tetapi gagal ketika diimplementasikan pada kasus nyata. Data pada kasus nyata adalah data yang belum pernah dilihat oleh sistem, jadi disinilah pentingnya kita juga menguji sistem menggunakan data uji. Kami membagi dataset dengan proporsi seperti pada Tabel 1 untuk menyediakan juga data yang belum pernah dilihat oleh CNN. Kinerja sistem pada data uji disajikan pada Tabel 4.

Dari hasil yang disajikan pada Tabel 4, ada dua arsitektur dimana kinerja precision mencapai hasil 1.00 yaitu MobileNet V1 dan VGG 16 pada kelas sangat segar. Sedangkan arsitektur yang mencapai precision terendah juga MobileNet V1 yaitu 0.73 untuk kelas tidak segar. Jadi meskipun MobileNet V1 mempunyai precision tertinggi untuk satu kelas tapi juga precision terendah untuk kelas lainnya.

Tabel 4. Kinerja pada data uji

Model	Matrik Confusion	Kelas	Precision	Recall	F1-score	Akurasi
Xception	[11 4]	Sangat Segar	0.79	0.73	0.76	0.77
	[3 13]	Tidak Segar	0.76	0.81	0.79	
MobileNet V1	[9 6]	Sangat Segar	1	0.6	0.75	0.81
	[0 16]	Tidak Segar	0.73	1	0.84	
ResNet50	[12 3]	Sangat Segar	0.92	0.80	0.86	0.87
	[1 15]	Tidak Segar	0.83	0.94	0.88	
VGG16	[14 1]	Sangat Segar	1.00	0.93	0.97	0.97
	[0 16]	Tidak Segar	0.94	1.00	0.97	

Berbeda dengan VGG16, arsitektur ini juga mencapai kinerja precision unggul dibanding lainnya untuk kelas tidak segar yaitu 0.94. Kinerja recall juga menunjukkan hasil mirip, MobileNet V1 dan VGG16 mencapai recall 1.00 pada kelas tidak segar, tetapi MobileNet juga mencapai recall terendah pada kelas sangat segar sebesar 0.6. Untuk VGG16, recall sebesar 0.93 masih kalah dibanding ResNet50 pada kelas tidak segar sebesar 0.94.

Kinerja F1-score juga menunjukkan hasil serupa, F1-score tertinggi dicapai oleh VGG16 sebesar 0.97 baik kelas sangat segar maupun tidak segar, dimana nilai ini jauh lebih unggul dibanding lainnya. Diposisi tertinggi kedua F1-score dicapai oleh ResNet50 sebesar 0.88 dan 0.86, selanjutnya diikuti oleh MobileNet V1 dan Xception. Dari sisi kinerja akurasi, VGG16 tetap lebih unggul dibanding lainnya sebesar 0.97. Secara urut dari kinerja terbaik dicapai oleh VGG16, ResNet50, MobileNet V1, dan Xception.

Dari hasil eksperimen perbandingan beberapa arsitektur CNN untuk transfer learning dalam menyelesaikan masalah klasifikasi kesegaran ikan bandeng, VGG16 mencapai kinerja terbaik dibanding arsitektur lainnya seperti ResNet50, MobileNet V1, dan Xception. Baik kinerja precision, recall, F1-score dan akurasi, semuanya menunjukkan hasil bahwa VGG16 lebih tepat diimplementasikan karena memberikan kinerja lebih baik.

4. KESIMPULAN

Dari hasil eksperimen yang dilakukan pada penelitian ini, dapat disimpulkan bahwa VGG16 mencapai kinerja lebih baik dibanding arsitektur CNN lainnya dalam menyelesaikan masalah klasifikasi kesegaran ikan bandeng berdasarkan citra mata, dimana akurasi VGG16 mencapai 0.97 pada data uji. Capaian kinerja ini menunjukkan bahwa VGG16 lebih tepat diimplementasikan pada klasifikasi kesegaran ikan bandeng dua kelas. Sebenarnya arsitektur Xception seharusnya memberikan kinerja optimal, tetapi dalam penelitian ini menunjukkan kinerja *overfitting* dimana akurasi pelatihan terus naik tetapi akurasi validasi tidak dapat naik, maka perlu dilakukan investigasi lebih lanjut apakah arsitektur Xception terlalu kompleks atau kurang variasi data, sehingga Xception dapat menjadi alternatif pilihan CNN untuk klasifikasi kesegaran ikan bandeng.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Direktorat Riset dan Pengabdian Masyarakat (DRPM) DIKTI yang memberikan pendanaan penelitian pada skim Penelitian Dasar tahun anggaran 2020 kepada peneliti di Universitas Bhayangkara Surabaya dengan nomor kontrak: 008/SP2H/AMD/LT/MULTI/L7/2020 tanggal 10 Juni 2020 dan 048/VI/AMD/LPPM/2020/UBHARA tanggal 11 Juni 2020.

DAFTAR PUSTAKA

- ABU MALLOUH, A., QAWAQNEH, Z. and BARKANA, B. D. (2019) 'Utilizing CNNs and transfer learning of pre-trained models for age range classification from unconstrained face images', *Image and Vision Computing*. Elsevier Ltd, 88, pp. 41–51. doi: 10.1016/j.imavis.2019.05.001.
- Badan Pusat Statistik Indonesia (2015) *Ringkasan Eksekutif Pengeluaran dan Konsumsi Penduduk Indonesia*. Badan Pusat Statistik. Available at: <https://media.neliti.com/media/publications/48424-ID-ringkasan-eksekutif-pengeluaran-dan-konsumsi-penduduk-indonesia-berdasarkan-hasi.pdf>.
- CHOLLET, F. (2017) 'Xception: Deep learning with depthwise separable convolutions', in *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*. doi: 10.1109/CVPR.2017.195.
- DARMANTO, H. (2019) 'Pengenalan Spesies Ikan Berdasarkan Kontur Otolith Menggunakan Convolutional Neural Network', *Joined Journal (Journal of Informatics Education)*, 2(1), pp. 41–59. doi: 10.31331/joined.v2i1.847.
- DEEPAK, S. and AMEER, P. M. (2019) 'Brain tumor classification using deep CNN features via transfer learning', *Computers in Biology and Medicine*. Elsevier Ltd, 111, p. 103345. doi: 10.1016/j.compbiomed.2019.103345.
- DWIYATNO, S., IKSAL, I. and NUGRAHA, S. (2018) 'Alat Pendeteksi Kesegaran Ikan Menggunakan Metode K-nearest Neighbor Berdasar Warna Mata Berbasis ATMEGA 328', *PROSISKO: Jurnal Pengembangan*

- Riset dan Observasi Sistem Komputer*, 5(2). Available at: <https://ejournal.lppmunsera.org/index.php/PROSISK/O/article/view/789>.
- HE, K. *et al.* (2016) ‘Deep residual learning for image recognition’, in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. doi: 10.1109/CVPR.2016.90.
- HOWARD, A. G. *et al.* (2017) ‘MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications’. Available at: <http://arxiv.org/abs/1704.04861> (Accessed: 25 November 2019).
- HUANG, G. *et al.* (2017) ‘Densely connected convolutional networks’, in *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*. doi: 10.1109/CVPR.2017.243.
- ILYAS (1983) *Teknologi Refrigerasi Hasil Perikanan Jilid 1 Teknik Pendingin Ikan*. Edited by B. P. dan P. Pertanian. Jakarta: Paripurna.
- Kelautan dan Perikanan, K. (2016) ‘Peta Sentra Produksi Perikanan Budidaya’. Edited by D. P. dan U. B. Direktorat Jenderal Perikanan Budidaya. Jakarta.
- KRIZHEVSKY, A., SUTSKEVER, I. and HINTON, G. E. (2012) ‘ImageNet classification with deep convolutional neural networks’, in *Advances in Neural Information Processing Systems*.
- PRASETYO, E., ADITYO, R. DIMAS and PURBANINGTYAS, R. (2019) ‘Classification of segmented milkfish eyes using cosine K-nearest neighbor’, in *Proceedings of ICAITI 2019 - 2nd International Conference on Applied Information Technology and Innovation: Exploring the Future Technology of Applied Information Technology and Innovation*. Institute of Electrical and Electronics Engineers Inc., pp. 93–98. doi: 10.1109/ICAITI48442.2019.8982124.
- PRASETYO, E., ADITYO, RADEN DIMAS and PURBANINGTYAS, R. (2019) ‘Segmentasi Mata Ikan Bandeng dengan Klasifikasi’, in *CITEE*, pp. 213–219.
- PRASETYO, E., PURBANINGTYAS, R. and DIMAS ADITYO, R. (2020) ‘Cosine K-Nearest Neighbor in Milkfish Eye Classification’, *International Journal of Intelligent Engineering and Systems*, 13(3). doi: 10.22266/ijies2020.0630.02.
- PRAYOGI, Y. R., WIBISONO, C. L. and ABROR, A. H. (2019) ‘Deteksi Kesegaran Ikan Bandeng Berbasis Pengolahan Citra Digital’, *REMIK (Riset dan E-Jurnal Manajemen Informatika Komputer)*. Politeknik Ganesha, 4(1), p. 53. doi: 10.33395/remik.v4i1.10228.
- SAPUTRA, R., MATULATAN, T. and HAYATY, N. (2020) *Pengelompokan Kesegaran Ikan Melalui Citra Mata Ikan Menggunakan Metode CNN (Convolution Neural Network)*, *Student Online Journal (SOJ) UMRAH - Teknik*.
- SHARMA, P., BERWAL, Y. P. S. and GHAI, W. (2019) ‘Performance analysis of deep learning CNN models for disease detection in plants using image segmentation’, *Information Processing in Agriculture*. China Agricultural University. doi: 10.1016/j.inpa.2019.11.001.
- SIMONYAN, K. and ZISSERMAN, A. (2015) ‘Very deep convolutional networks for large-scale image recognition’, in *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*.
- SZEGEDY, C. *et al.* (2016) ‘Rethinking the Inception Architecture for Computer Vision’, in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. doi: 10.1109/CVPR.2016.308.
- TAN, M. and LE, Q. V. (2019) ‘EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks’, *36th International Conference on Machine Learning, ICML 2019*. International Machine Learning Society (IMLS), 2019-June, pp. 10691–10700. Available at: <http://arxiv.org/abs/1905.11946> (Accessed: 11 June 2020).
- VASAN, D. *et al.* (2020) ‘IMCFN: Image-based malware classification using fine-tuned convolutional neural network architecture’, *Computer Networks*. Elsevier B.V., 171, p. 107138. doi: 10.1016/j.comnet.2020.107138.

Halaman ini sengaja dikosongkan