



Klasifikasi Kesegaran Ikan Lemuru Berdasarkan Citra Mata Menggunakan Metode Convolutional Neural Network

Vigit Tri Deco^{1*}, Agung Nilogiri², Qurrota A'yun³

^{1,2,3}Program Studi Teknik Informatika, Universitas Muhammadiyah Jember

Email: vigitdeco@gmail.com^{1*}, agungnilogiri@unmuhjember.ac.id², qurrota.ayun@unmuhjember.ac.id³

ABSTRAK

Ikan merupakan sumber protein yang kaya bagi tubuh manusia, ikan juga merupakan salah satu komoditas bahan pangan yang sangat digemari masyarakat. Ikan juga memiliki nilai gizi tinggi, namun ikan sangatlah mudah kehilangan kualitas kesegarannya. Kesegaran ikan adalah parameter yang sangat penting dalam menentukan sebuah kualitas sebuah ikan, salah satu ciri dari menurunnya kesegaran ikan adalah dapat dilihat dari mata ikan itu sendiri, namun untuk membedakan kesegaran itu sendiri menurut mata jika dilihat dengan sekilas maka akan sulit untuk mengetahuinya. Maka dari itu dibutuhkanlah teknologi yang dapat mengidentifikasi kesegaran ikan lemuru berdasarkan citra mata. Convolutional Neural Network (CNN) merupakan salah satu pengembangan dari algoritma multilayer perceptron (MLP) yang mampu mengidentifikasi sebuah gambar ataupun suara. Pada penelitian ini arsitektur CNN yang digunakan adalah VGG-16 dengan 1920 data citra mata ikan lemuru. VGG-16 memiliki 13 convolution layer dan 5 pooling layer. VGG-16 ini memiliki dua layer fully connected layer yang memiliki 4096 neuron pada setiap layer. pada layer yang terakhir terdapat pengklasifikasian dua kelas yang menggunakan aktivasi softmax. Akurasi yang didapat pada penelitian ini adalah akurasi 100%, sensitivitas 100%, dan spesifisitas 100%. Kesimpulannya adalah algoritma Convolutional Neural Network (CNN) yang telah dibangun mampu mengidentifikasi kesegaran ikan berdasarkan citra mata dan pada tingkat efektivitas sangat baik mengidentifikasi citra mata ikan.

Kata Kunci: Lemuru, Convolutional Neural Network (CNN), VGG-16

ABSTRACT

Fish is a rich source of protein for the human body, fish is also a food commodity that is very popular with the public. Fish also has high nutritional value, but fish loses its freshness very easily. Freshness of fish is a very important parameter in determining the quality of a fish, one of the characteristics of decreasing freshness of fish is that it can be seen from the eye of the fish itself, but to distinguish the freshness itself according to the eye at a glance it will be difficult to tell. Therefore, a technology is needed that can identify the freshness of lemuru fish based on eye images. Convolutional Neural Network (CNN) is one of the developments of the multilayer perceptron (MLP) algorithm that can identify an image or sound. In this study the CNN architecture used is VGG-16 with 1920 lemuru eye image data. VGG-16 has 13 convolution layers and 5 pooling layers. VGG-16 has two fully connected layers which have 4096 neurons in each layer. in the last layer there is a classification of two classes that use softmax activation. The accuracy obtained in this study is 100% accuracy, 100% sensitivity, and 100% specificity. The conclusion is that the Convolutional Neural Network (CNN) algorithm that has been developed is capable of identifying fish freshness based on eye images and at a very good level of effectiveness in identifying fish eye images.

Keywords: Lemuru, Convolutional Neural Network (CNN), VGG-16

1. PENDAHULUAN

Ikan merupakan sumber protein yang kaya bagi tubuh manusia, ikan juga merupakan salah satu komoditas bahan pangan. Ikan memiliki nilai gizi tinggi, ikan juga mudah kehilangan kualitas, termasuk kesegarannya. Kesegaran ikan adalah parameter yang sangat penting dalam menentukan sebuah kualitas ikan. Banyak dari konsumen atau masyarakat menganggap kesegaran ikan dapat menunjukkan cita rasa. Ikan akan mengalami perubahan fisik yang sangat nyata seiring dengan menurunnya kesegaran ikan, antara lain mata, insang, bau, tekstur, warna, sisik, dan perut. Modifikasi ini dapat digunakan sebagai acuan untuk menentukan kesegaran ikan (Novianto & Erawan, 2020), antara lain masyarakat atau konsumen sering melihat kesegaran ikan melalui mata ikan, oleh karena

itu langkah terbaik sebelum memilih kesegaran ikan adalah mengidentifikasinya dari matanya. Hal ini dilakukan karena mata ikan mengalami perubahan yang sangat nyata saat ikan dalam keadaan mati.

Perkembangan teknologi beberapa tahun belakangan ini berkembang sangat pesat, tidak dapat dipungkiri bahwa komputer sangat dibutuhkan untuk menyelesaikan pekerjaan manusia dengan lebih cepat, semakin pesatnya perkembangan teknologi, sekarang ini banyak sekali bagian-bagian yang dikembangkan perangkat lunak yang dapat meniru kecerdasan manusia (*artificial intelligence*) (Kusumaningrum, 2018). Kecerdasan tiruan (*artificial intelligence*) merupakan salah satu program komputer yang dapat mengeksekusi sebuah perintah yang sudah dibuat atau aplikasi yang bisa menjalankan atau mengeksekusi perintah yang dari sudut pandangan manusia adalah cerdas (Pujoseno, 2018). Seiring berkembangnya teknologi kecerdasan buatan diharapkan komputer-komputer dapat meniru dan bekerja seperti halnya fungsi otak manusia dan pada akhirnya dapat diharapkan menjadi salah satu pilihan untuk mengidentifikasi kesegaran ikan menggunakan citra mata.

Saat mengolah sebuah citra, ada banyak metode untuk mengolahnya, salah satunya adalah *Convolutional Neural Network* (CNN). CNN adalah salah satu dari banyak algoritma pada *deep learning*. *Deep learning* merupakan salah satu cabang dari *machine learning* dan masuk dalam pembelajaran mesin berbasis jaringan saraf tiruan. Saat ini, *deep learning* menjadi subjek paling populer di *machine learning* yang paling populer karena kemampuannya yang luar biasa untuk memodelkan kompleksitas berbagai tipe data seperti gambar dan suara. Kemampuan *deep learning* ini dalam computer vision sangat bagus dan baik, salah satu dari banyaknya algoritma yang ada adalah penerapan algoritma *Convolutional Neural Network* (CNN) untuk mengenali sebuah citra. Karena ini lah CNN berusaha untuk meniru dan melakukan pengenalan sebuah citra pada visual korteks seperti halnya manusia (Putra et al., 2016), Sehingga CNN dapat memiliki kemampuan dalam mengolah sebuah informasi pada citra. Salah satunya adalah dapat digunakan untuk melakukan sebuah klasifikasi. Klasifikasi dilakukan secara otomatis melalui pembelajaran mesin.

Pada penelitian yang dilakukan oleh (Prasetyo et al., 2021) perbandingan *Convolutional Neural Network*. (CNN) untuk klasifikasi kesegaran ikan bandeng. Pada citra mata yang mendapatkan akurasi tinggi adalah arsitektur VGG16 yang berhasil mencapai *accuracy* sebesar 0.97 dengan jumlah seluruh data 154 citra dan dibagi menjadi beberapa data antara lain data train 92 citra, data testing 31 citra dan data uji 31 citra, selanjutnya Saputra et al. (2021) melakukan penelitian pengelompokan kesegaran ikan melalui citra mata ikan dengan train 525, data testing 27 dan 18 data uji, penelitian Saputra memiliki hasil akurasi 98,44%. Lalu (Krisdiani 2019) melakukan penelitian klasifikasi kesegaran ikan berdasarkan warna mata ikan menggunakan metode *K-Nearest Neighbour* mendapatkan akurasi 81,7% dengan menggunakan 60 citra mata ikan dan Sholihin et al. (2021) melakukan penelitian identifikasi kesegaran ikan berdasarkan citra insang dengan menggunakan 150 citra, penelitian Sholihin menghasilkan proses pengujian 97,7%.


Dataset yang digunakan pada penelitian ini Penulis ingin mencoba mengkaji dengan menggunakan teknologi *machine learning* yang dapat membedakan atau mengklasifikasikan kesegaran ikan berdasarkan citra mata lemuru dengan metode "Associative Neural Network", dengan menggunakan arsitektur VGG16, dan mengambil dataset langsung dari pasar ikan yang ada di kota Banyuwangi.

2. KAJIAN PUSTAKA

A. Citra Digital

Secara umum citra adalah kombinasi titik, garis, bidang, dan warna, untuk membuat tiruan dari suatu objek, biasanya sebuah objek fisik atau orang. Bentuk dari sebuah citra adalah gambar dua dimensi seperti foto, lukisan, untuk gambar tiga dimensi adalah patung. Secara matematis, citra digital merupakan fungsi kontinu dari intensitas cahaya pada bidang dua dimensi. Agar citra dapat diproses

oleh komputer, citra harus direpresentasikan secara numerik dengan nilai diskrit. Posisi koordinat citra digital dapat dilihat pada Gambar 1.



Gambar 1. Koordinat Citra Digital (Sumber: <https://nenkk.wordpress.com/2013/06/26/representasi-citra-digital/>)

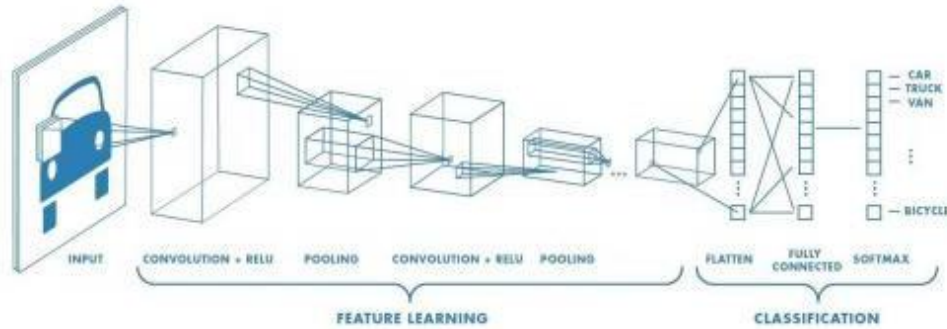
B. Convolutional Neural Network

Convolutional Neural Network (CNN) adalah salah satu algoritma *deep learning* yang dikembangkan dari *Multilayer Perceptron* (MLP), dirancang untuk memproses pola gambar yang berbeda dari sisi data yang berbeda dalam bentuk *grid*. Contoh gambar dua dimensi adalah gambar atau suara. CNN pertama kali dikembangkan oleh Fukushima (1980) di Tokyo, Jepang, namun pada saat itu masih dikenal sebagai *neurocognition*. Kemudian, CNN dikembangkan kembali oleh LeCun, yang terinspirasi oleh model *neurocognition* yang dibuat sebelumnya. Model CNN LeNet telah berhasil diterapkan oleh LeCun dalam masalah pengenalan angka pada tulisan tangan (Anugerah, 2018). Tahun 2012, Krizhevsky et al. menerapkan metode CNN ke *Imagenet LargeScale Visual Recognition Challenge* (ILSVRC) dan memenangkan kompetisi. Sejak kemenangan Alex Krizhevsky dalam kompetisi tersebut, dapat dibuktikan bahwa metode CNN dapat mengungguli pengenalan objek citra dengan mengalahkan metode *machine learning* lainnya.

CNN memiliki lapisan tunggal dengan susunan tiga dimensi neuron yang meliputi lebar, tinggi dan kedalaman. Lebar dan tinggi adalah ukuran. Matriks didasarkan pada lapisan, sedangkan kedalaman mengacu pada kuantitas. Saluran warna gambar atau bagian lain juga dapat disebut sebagai angka, penyaringan, kemudian pada lapisan ini secara berurutan melalui berbagai proses.

Secara umum memiliki lapisan yang dibagi menjadi dua tipe, yaitu *feature learning* atau disebut lapisan Ekstraksi fitur dan *classification* disebut lapisan klasifikasi. Pada lapisan pertama adalah feature learning, lapisan di atas arsitektur yang pada arsitektur awal ini memiliki banyak lapisan dan setiap lapisan itu sendiri terdiri dari neuron yang terhubung ke area lapisan sebelumnya atau dengan area lokal.

Kemudian untuk lapisan pengklasifikasi kedua, yang terdiri dari beberapa lapisan, masing-masing dengan lapisan neuronnya sendiri yang terhubung penuh (*fully connected*) dengan lapisan lainnya. Pengklasifikasi ini menerima input dari lapisan ekstraksi fitur sebagai gambar vektor, dan kemudian gambar vektor diubah menjadi jaringan multi-neural dengan menambahkan beberapa lapisan tersembunyi. Hasil dari pengolahan ini adalah skor kelas untuk klasifikasi.

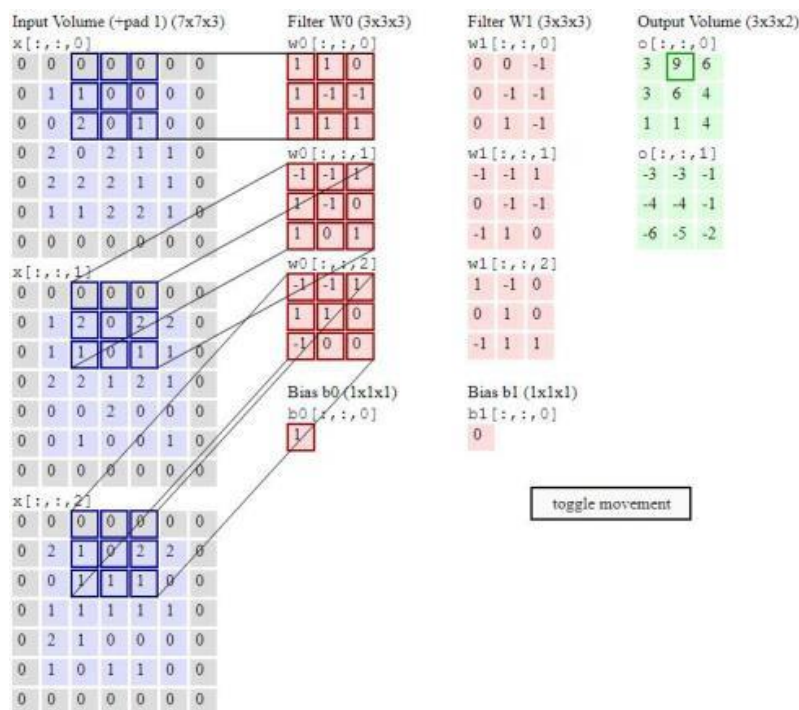


Gambar 2. Ilustrasi Arsitektur CNN (Sumber: <https://medium.com/@samuelsena/pengenalan-deep-learning-part-7-convolutional-neural-network-cnn-b003b477dc94>)

C. Convolution Layer

Convolution Layer merupakan proses iteratif dari operasi matematika yang disebut konvolusi, dan hasil dari proses konvolusi tersebut menghasilkan informasi yang dikenal sebagai *feature maps* (Nielsen, 2015).


Convolution layer memiliki parameter yang terdiri dari *kernel size*, *filters*, *strides*, dan *padding*. Parameter *kernel size* menentukan berapa ukuran konvolusi yang akan di filter. Parameter *filters* menentukan berapa banyak *feature maps* yang akan di hasilkan dari proses convolution. Parameter *stride* menentukan berapa jarak *kernel* bergeser. Dan parameter *padding* menambahkan nilai 0 di tepi terluar *input* (Uchida et al., 2018).



Gambar 3. Operasi Convolution (Sumber: <https://medium.com/@samuelsena/pengenalan-deep-learning-part-7-convolutional-neural-network-cnn-b003b477dc94>)

D. Pooling Layer

Pooling layer merupakan bagian dari CNN dimana metode ini digunakan setelah *convolution layer*. Pada *pooling layer* yang menerima *output* dari *convolutional layer*, pada layer ini ukuran citra akan diperkecil secara spasial dengan mengurangi jumlah parameter. Menurut Nurfitra & Ariyanto (2020) yaitu *pooling layer* disederhanakan menjadi *feature maps* yang dihasilkan oleh layer konvolusi. Penyederhanaan ini memungkinkan untuk memulihkan informasi penting dari hasil konvolusi layer atau yang bisa disebut *feature maps* dan memilih detail yang tidak lagi digunakan sehingga komputasi layer berikutnya lebih ringan. Adapun dua jenis *pooling layer*, yaitu *average pooling* dan *max pooling*. Salah satu yang sering digunakan atau umum digunakan untuk *pooling* pada CNN adalah *max pooling*, di mana metode ini mengambil nilai yang paling maksimal dari setiap masing-masing *grid*, nilai maksimum dari setiap *grid* untuk membuat *feature maps* yang disederhanakan.



Gambar 4. Ilustrasi Max Pooling (Sumber gambar : <https://medium.com/@samuelkena/pengenalan-deep-learning-part-7-convolutional-neural-network-cnn-b003b477dc94>)

E. ReLU

Aktivasi *Rectified Linear Unit* (ReLU) adalah lapisan aktivasi yang umum digunakan dalam model CNN. Kelas aktivasi ini merupakan lapisan aktivasi pada model CNN yang menerapkan fungsi $f(x) = \max(0, x)$ yang artinya nilai keluaran dari neuron dinyatakan 0 jika nilai masukannya negatif, sedangkan jika nilai masukannya adalah positif, maka nilai keluarannya adalah nilai dari masukannya sendiri (Ramachandran et al., 2018).

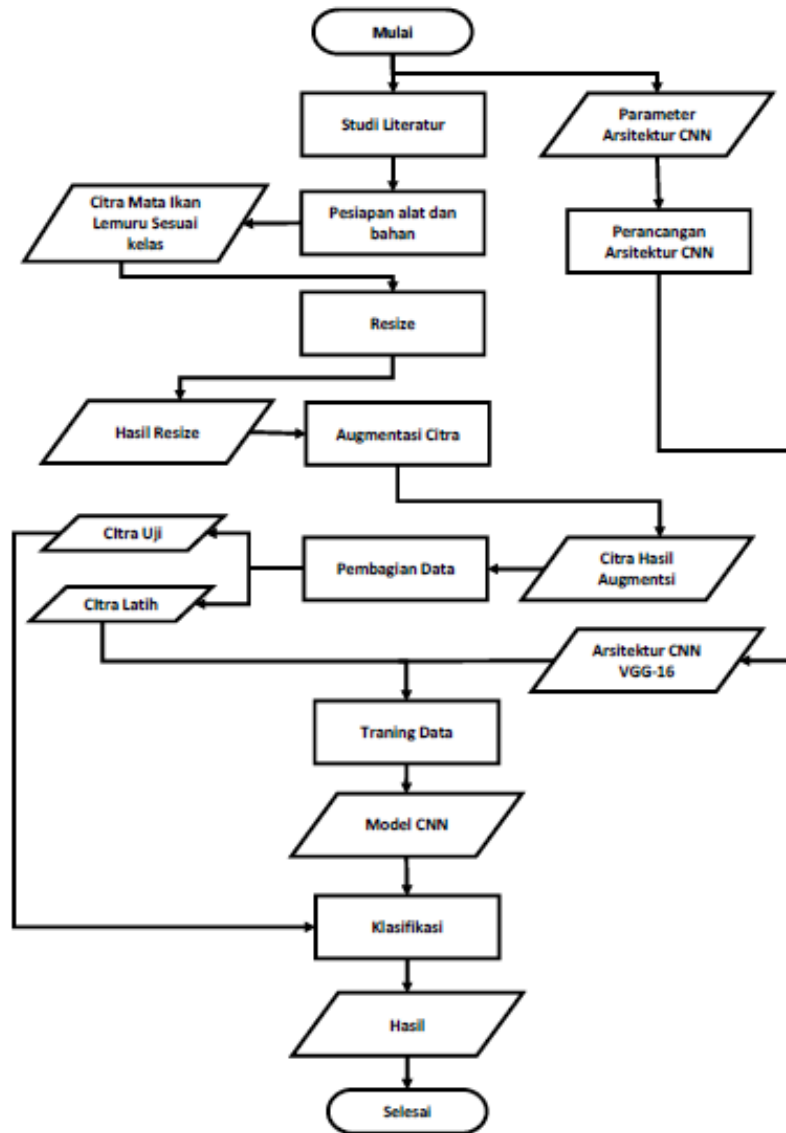
F. Softmax

Aktivasi *Softmax* alias *Softmax Classifier* merupakan salah satu fungsi aktivasi yang digunakan di CNN. Fungsi aktivasi *softmax* ini digunakan pada lapisan keluaran atau *output layer*. Fungsi *softmax* pada dasarnya adalah probabilitas eksponensial yang dinormalisasi dari pengamatan kelas yang dinyatakan sebagai aktivasi neuron. Fungsi eksponensial adalah untuk meningkatkan probabilitas nilai terbesar atau terbesar dari kelas sebelumnya

$$f_i(X) = \frac{e^{x_i}}{\sum_k e^{x_k}} \quad (1)$$

3. METODE PENELITIAN

Gambar 6 berikut menunjukkan diagram alir prosedur penelitian yang dilakukan pada peneliti ini:



Gambar 6. Diagram Alir Prosedur Penelitian


A. Pra-Proses Data

Pada proses ini peneliti mempersiapkan dataset sebelum diolah mulai dari pengambilan data sebelum diproses pada tahap selanjutnya. Dataset citra yang telah diperoleh selanjutnya akan dilakukan pengolahan citra hingga siap untuk digunakan oleh arsitektur CNN yang telah dibangun. Selanjutnya data citra akan di-*resize* sesuai ukuran pixel yang telah disesuaikan program dan sekaligus data tersebut diperbanyak atau diaugmentasi untuk memperbanyak data citra yang sebelumnya sudah diperoleh. Data yang sudah di *resize* dan *augmentasi data* kemudian diolah dan dijadikan dua bagian yaitu data uji dan data latih.

1) Resize Citra

Data yang telah diperoleh kemudian dilakukan *Resize* dengan menggunakan Bahasa pemrograman *python*, agar diperoleh ukuran gambar yang tidak terlalu besar. Gambar yang diperoleh


saat pengambilan dataset berukuran 3020 x 3020 *pixels*, kemudian setelah itu dilakukan *resize* menghasilkan output gambar yang berukuran 224 x 224 *pixels*.



Gambar 7. Ilustrasi *Resize* Citra

2) Augmentasi

Augmentasi data merupakan sebuah proses memodifikasi sebuah data gambar yang dirubah terbalik atau diperbesar, sehingga komputer dapat mendeteksi bahwa gambar tersebut adalah gambar yang berbeda, tetapi manusia masih dapat membedakan bahwa gambar tersebut sama (Perez & Wang, 2017).



Gambar 8. Contoh Augmentasi Data

3) Pembagian Data

Hasil gambar yang telah diaugmentasi kemudian dibagi, pada penelitian ini menggunakan rasio pembagian citra 9:1 atau 90% : 10%, dimana citra 90% untuk citra latih dan 10% untuk citra uji.

B. Pembangunn Model CNN

Dalam pembangunan model CNN peneliti menggunakan arsitektur VGG-16 dimana didalam arsitektur tersebut terdapat 2 bagian dalam pembangunan model CNN antara lain lapisan ekstraksi dan lapisan klasifikasi. Layer yang digunakan dalam perancangan Arsitektur VGG-16 ini sebanyak 16 layer yaitu 13 layer convolution dan 3 layer fully connected. Pada VGG-16 ini menggunakan konsep blok untuk membentuk convolution layer yang masing-masing memiliki ukuran 3x3 dan stride 1. Pada akhir blok, digunakan max pooling layer dengan ukuran 2x2 dan stride 2.

Tabel 1 Arsitektur CNN

Layer Type	kernel Size	Stride	Filters
input (244 x 244 x 3)			
convolution			
1	3x3	1	64
relu			
convolution			


Layer Type	kernel Size	Stride	Filters
2	3x3	1	64
relu			
maxpool 1	2x2	2	
convolution			
3	3x3	1	128
relu			
convolution			
4	3x3	1	128
relu			
maxpool 2	2x2	2	
convolution			
5	3x3	1	256
relu			
convolution			
6	3x3	1	256
relu			
convolution			
7	3x3	1	256
relu			
maxpool 3	2x2	2	
convolution			
8	3x3	1	512
relu			
convolution			
9	3x3	1	512
relu			
convolution			
10	3x3	1	512
relu			
maxpool 4	2x2	2	
convolution			
11	3x3	1	512
relu			
convolution			
12	3x3	1	512
relu			
convolution			
13	3x3	1	512
relu			
maxpool 5	2x2	2	
fully connected			4096
relu			

Layer Type	kernel Size	Stride	Filters
fully			
connected			4096
softmax			1000

C. Pengujian Model

Untuk mengetahui kinerja model CNN seperti, tingkat *accuracy*, *loss*, *sensitivity* dan *precision* model, Diperlukan tahapan pengujian.

Tahapan pengujian yang dilakukan pada penelitian menggunakan metode *K-Fold Cross Validation*, dimana fungsi utama dari metode *K-Fold Cross Validation* adalah untuk mengukur sebuah kinerja model algoritma yang akan menghitung varian kinerja dari K.



Gambar 9. K-Fold Cross Validation, K=10

4. HASIL DAN PEMBAHASAN

A. Hasil Pengujian K-Fold Cross Validation

Pada tahap pengujian ini dilakukan menggunakan *K-Fold cross validation*, dimana pada pengujian ini peneliti membagi kedalam 2 folder yang terdapat didalamnya 1920 data citra dan dibagi menjadi data *train* dan data *validation* yang diambil secara acak, secara keseluruhan data tersebut terbagi menjadi data train 1728 citra dan data validation 192 citra. Tabel 4.1 hasil dari pengujian *K-Fold Cros Validation*.

Tabel 2 Hasil Pengujian Menggunakan *K-Fold Validation*

	Percobaan ke-1 (%)	Percobaan ke-2 (%)	Akurasi Rata-Rata (%)
Fold 1	75,1	71	73,05
Fold 2	100	100	100,00
Fold 3	72,8	96,5	84,65
Fold 4	99,4	97,1	98,25
Fold 5	70,5	97,1	83,80
Fold 6	85,5	77,4	81,45
Fold 7	97,6	67,6	82,60
Fold 8	97,1	99,4	98,25
Fold 9	68,6	97,6	83,10
Fold 10	97,6	65,6	81,60

Dari tabel diatas membuat dua kali percobaan dimana pada *fold 2* mendapatkan rata rata nilai akurasi yang sangat tinggi dengan 100% dan rata-rata terendah dengan 73,05% pada *fold 1*.

B. Uji Coba Data Testing

Pada uji coba ini menggunakan foold 2 sebagai data latih dikarenakan pada fold 2 ini mempunyai nilai akurasi yang sempurna dibandingkan dengan fold lainnya. Selanjutnya pada percobaan yang terahir ini menggunakan data testing yang dimana tada tersebut belum pernah digunakan pada sistem atau data baru, data baru yang digunakan sebagai data testing sebanyak 32 citra yang terbagi dari dua kelas segar dan tidak segar. Hasil dari percobaan terhair ini dapat dilihat pada Tabel 3.

Tabel 3. Hasil Uji Coba Data Testing

	Prediksi Benar	Prediksi Salah	Akurasi (%)
Uji Coba	32	0	100

C. Uji Coba Efektivitas Model

Pada skenario uji coba efektivitas ini menguji model yang telah dibentuk apakah mengalami overfitting atau underfitting, model yang digunakan adalah fold ke-2 dimana pada model ini mendapatkan nilai akurasi yang sangat tinggi dibandingkan dengan nilai fold lainnya. Kemudian data yang digunkaan untuk uji coba efektivitas model ini adalah data yang belum pernah digunkan atau belum pernah digunakan sama sekali pada pelatihan maupun uji coba data testing. Pada pengujian ini menggunakan 192 citra yang mewakili kelas segar dan tidak segar.

1) Fold 2 Percobaan ke-1

Pada performa dari model fold 2 percobaan ke-1 ini dapat dilihat pada Tabel 4 mendapatkan nilai akurasi yang sangat baik dikarenakan mendapatkan nilai yang sangat baik yaitu 100%, dan dilihat dari nilai spesifisitas pada setiap kelas model fold 2 mampu memprediksi kelas sangat baik.

Pada uji coba efektivitas model, *fold 2* percobaan ke-1 diuji Kembali menggunakan citra data baru yang belum pernah digunakan sama sekali pada pelatihan maupun uji coba data testing.

Tabel 4. Confusion Matrix Fold 2 percobaan ke-1

Actual	Predict	
	0	1
0	87	0
1	3	10
		2

Tabel 5. Akurasi, Sensitivitas, dan Spesifisitas pada *fold 2* percobaan ke-1

Kelas	Akurasi (%)	Sensitivitas (%)	Spesifitas (%)
Segar	0,98438	1,0000	0,97143
Tidak Segar	0,98438	0,97143	1,0000

Hasil dari uji coba efektivitas model ini *fold 2* percobaan ke-1 mendapatkan nilai akurasi 98,4%, sensitivitas 98,5%, dan spesifisitas 98,5%. Dilihat dari performa setiap kelas terdapat kelas yang mendapatkan nilai sensitivitas lebih tinggi daripada nilai spesifitas begitu juga sebaliknya.

Sehingga dari pernyataan tersebut kesimpulannya adalah model *fold 2* pada percobaan ke-1 kurang baik efektivitas dalam mendeteksi kesegaran ikan, pada *fold 2* percobaan ke-1 ini mengalami *overfitting*, dikarenakan pada saat uji coba dengan dataset baru (citra mata ikan lemuru) mengalami perbandingan yang kurang baik dari pada kinerja saat pelatihan.

2) Fold 2 Percobaan ke-2

Selanjutnya pada performa dari model *fold 2* percobaan ke-2 ini dapat pada tabel 6 mendapatkan nilai akurasi yang sangat baik dikarenakan mendapatkan nilai yang sangat baik yaitu 100%, dan dilihat dari nilai spesifisitas pada setiap kelas model *fold 2* mampu memprediksi kelas sangat baik.

Pada uji coba efektivitas model, *fold 2* percobaan ke-2 ini diuji Kembali menggunakan citra data baru yang belum pernah digunakan sama sekali pada pelatihan maupun uji coba data testing.

Tabel 6. Confusion Matrix Fold 2 percobaan ke-2

		Predict	
		0	1
Actual	0	87	0
	1	0	105

Tabel 7. Akurasi, Sensitivitas, dan Spesifisitas pada *fold 2* percobaan ke-2

Kelas	Akurasi (%)	Sensitivitas (%)	Spesifitas (%)
Segar	1,0000	1,0000	1,0000
Tidak Segar	1,0000	1,0000	1,0000

Hasil dari uji coba efektivitas model ini *fold 2* percobaan ke-2 mendapatkan nilai akurasi 100%, sensitivitas 100%, dan spesifisitas 100%. Dilihat dari performa setiap kelas pada *fold 2* percobaan ke-2 ini mendapatkan nilai yang sangat bagus bisa juga dibbilang sempurna karena semua mendapatkan nilai 100%.

Jadi jika dibandingkan dengan uji coba efektivitas dari percobaan ke-1, percobaan ke-2 lah yang lebih baik dikarenakan nilai akurasi, sensitivitas, dan spesifitasnya mencapai nilai 100%.

5. KESIMPULAN

A. Kesimpulan

Berdasarkan hasil dan pembahasan dari penelitian ini, dapat disimpulkan sebagai berikut:

- 1) Pada kesimpulan yang pertama pengujian menggunakan *fold cross validation* dengan nilai $k=10$ mendapatkan nilai sempurna 100%. Oleh sebab itu kesimpulan yang didapat adalah metode *Convolutional Neural Network* (CNN) dapat atau telah mampu mengidentifikasi kelas tingkat kesegaran ikan lemuru berdasarkan citra mata. hasil dari klasifikasi tersebut menggunakan data citra baru sebanyak 32 citra yang sudah terbagi 2 kelas berhasil mengidentifikasi semua citra dengan baik dan benar, dan mencapai akurasi 100%.
- 2) Pada uji coba keefektivan model, pada model *fold 2* percobaan ke-1 mendapatkan nilai akurasi sebesar 98,4%, sensitivitas 98,5%, dan spesifisitas 98,5%, pada *fold 2* percobaan ke-1 ini

mengalami *overfitting*, dikarenakan pada saat uji coba dengan dataset baru (citra mata ikan lemuru) mengalami perbandingan yang kurang baik dari pada kinerja saat pelatihan. dan pada model *fold 2* percobaan ke-2 mendapatkan nilai akurasi yang sangat tinggi yaitu akurasi sebesar 100%, sensitivitas 100%, dan spesifisitas 100%. Pada percobaan ke-2 ini sangat sangat efektif untuk mengidentifikasi tingkat kesegaran ikan berdasarkan citra mata.

B. Saran

Pada penelitian ini masih belum optimal oleh sebab itu dapat disempurnakan dikemudian hari, Adapun beberapa saran untuk penelitian ini sebagai berikut:

- 1) Menerapkan augmentasi data atau menambahkan data citra yang lebih banyak lagi dengan cara *offline* untuk memperbanyak citra.
- 2) Pada penelitian ini dapat digunakan sebagai acuan untuk para peneliti selanjutnya.
- 3) Penelitian ini dapat dikembangkan kedalam sebuah aplikasi yang terhubung dengan *smartphone*

6. DAFTAR PUSTAKA

- Anugerah, A. G. (2018). *Klasifikasi Tingkat Keganasan Kanker Paru-Paru Pada Citra Computed Tomography (CT) Scan Menggunakan Metode Convolutional Neural Network*. Surabaya : Institut Teknologi Sepuluh Nopember.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Handbook of approximation algorithms and metaheuristics. *Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1*, 1097–1105.
- Kusumaningrum, T. F. (2018). *Implementasi Convolution Neural Network (Cnn) Untuk Klasifikasi Jamur Konsumsi Di Indonesia Menggunakan Keras*. Yogyakarta: Universitas Islam Indonesia.
- Nielsen, M. (2015). *Neural Networks and Deep Learning*. Determination Press.
- Novianto, T. D., & Erawan, I. M. S. (2020). Perbandingan Metode Klasifikasi pada Pengolahan Citra Mata Ikan Tuna. *Prosiding SNFA (Seminar Nasional Fisika dan Aplikasinya)*, 5, 216–223.
- Nurfita, R. D., & Ariyanto, G. (2020). Implementasi Deep Learning Berbasis Tensorflow Untuk Pengenalan Sidik Jari. *Emitor: Jurnal Teknik Elektro*, 18(01), 22–27.
- Perez, L., & Wang, J. (2017). The Effectiveness of Data Augmentation in Image Classification using Deep Learning. *Computer Science*.
- Prasetyo, E., Purbaningtyas, R., Adityo, R. D., 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.
- Pujoseno, J. (2018). *Implementasi Deep Learning Menggunakan Convolutional Neural Network Untuk Klasifikasi Alat Tulis*. Yogyakarta: Universitas Islam Indonesia.
- Putra, I. W. S. E., Wijaya, A. Y., & Soelaiman, R. (2016). Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) Pada Caltech 101. *Jurnal Teknik ITS*, 5(1), 76.
- Ramachandran, P., Zoph, B., & Le, Q. V. (2018). Searching for activation functions. *6th International Conference on Learning Representations, ICLR 2018 - Workshop Track Proceedings, 1*, 1–12.
- Saputra, R., Matulatan, T., & Hayaty, N. (2021). *PENGELOMPOKAN KESEGARAN IKAN MELALUI CITRA MATA IKAN MENGGUNAKAN METODE CNN (Convolution Neural Network)*. Tanjung Pinang: Universitas Maritim Raja Ali Haji.
- Sholihin, M., Zamroni, M. R., & Burhanuddin. (2021). Identifikasi Kesegaran Ikan Berdasarkan Citra Insang dengan Metode Convolution Neural Network. *JATISI (Jurnal Teknik Informatika dan Sistem Informasi)*, 8(3), 1352–1360.
- Uchida, K., Tanaka, M., & Okutomi, M. (2018). Coupled convolution layer for convolutional neural network. *Neural Networks*, 105(September), 197–205.