

# BAB I

## PENDAHULUAN

### A. Latar Belakang

Pengelolaan perikanan adalah hal yang sangat penting bagi masyarakat, karena ikan merupakan sumber utama protein bagi jutaan orang di seluruh dunia (Stankus, 2021). Selain itu, perikanan juga menyediakan pekerjaan dan pendapatan bagi banyak masyarakat, terutama di daerah pedesaan dan pesisir. Namun, meskipun penting, perikanan juga memiliki beberapa tantangan, seperti *overfishing*, pencemaran lingkungan, dan perubahan iklim. Oleh karena itu, pengelolaan perikanan yang baik sangat penting untuk memastikan keberlangsungan sumber daya perikanan dan kelangsungan hidup masyarakat yang bergantung pada perikanan (Halim et al., 2020; Soemarmi et al., 2019).

Tanpa pengelolaan yang baik, dampak negatif ini dapat bertambah parah, dan dapat membahayakan sumber daya perikanan dan lingkungan secara keseluruhan (Lestari & Djanggih, 2019). Oleh karena itu, pengelolaan perikanan yang baik sangat penting untuk memastikan kualitas lingkungan. Salah satu upaya dalam pengelolaan perikanan secara lestari yaitu dengan cara identifikasi ikan. Salah satu cara identifikasi ikan adalah dengan observasi fisik: Tahap pertama dalam identifikasi ikan adalah melakukan observasi fisik pada spesimen. Ini termasuk memperhatikan warna, ukuran, bentuk, dan tanda-tanda khusus seperti sisi, ekor, dan sirip (Kusuma et al., 2021). Proses identifikasi ini diperlukan pada ikan *Leiognathidae* dan ikan *Sardinella* yang merupakan ikan tangkapan potensial (Simarmata et al., 2014; Sumiono et al., 2017; Laptah PPN Karangantu, 2021).

Beberapa penemuan baru terkait famili ikan *Leiognathidae* telah dilaporkan dalam beberapa penelitian selama 10 tahun terakhir. Salah satu penelitian yang menarik adalah tentang keberadaan spesies baru ikan dari famili *Leiognathidae* yang ditemukan di perairan Indonesia (Wedjatmiko et al. 2017). Di sisi lain, beberapa penelitian juga melaporkan adanya potensi invasif

beberapa famili *Leiognathidae* di beberapa wilayah, seperti *Leiognathus equulus* yang telah teridentifikasi sebagai spesies invasif di perairan Laut Tengah (Galil et al., 2017). Selain itu, *Sardinella* juga diperlukan untuk proses identifikasi dikarenakan ikan ini juga merupakan ikan tangkapan potensial (Laptah PPN Karangantu, 2021).

Studi tentang biomassa dan potensi perikanan beberapa spesies *Sardinella* juga telah dilakukan dalam beberapa tahun terakhir. Sebagai contoh, penelitian tentang biomassa *Sardinella lemuru* di perairan Indonesia dilaporkan dalam jurnal *Regional Studies in Marine Science* pada tahun 2019. Penelitian tersebut menyimpulkan bahwa *Sardinella lemuru* memiliki potensi perikanan yang besar di perairan Indonesia (Jatisworo et al., 2022). Di sisi lain, beberapa penelitian juga melaporkan masalah terkait perikanan *Sardinella*, seperti penurunan populasi dan pengelolaan yang tidak berkelanjutan. Penelitian tersebut menunjukkan bahwa pengelolaan perikanan *Sardinella* di pantai Ghana masih mengalami kendala dan diperlukan upaya yang lebih serius untuk menjaga keberlanjutan perikanan tersebut (Nunoo et al., 2015). Salah satu pendekatan yang dapat dilakukan untuk mengatasi permasalahan tersebut adalah dengan menggunakan Artificial Intelligence (AI).

Artificial Intelligence (AI) adalah salah satu bidang teknologi yang mengalami perkembangan yang sangat pesat dalam beberapa tahun terakhir (Confalonieri et al., 2021). AI merupakan suatu teknologi yang memungkinkan komputer untuk melakukan tugas yang biasanya dilakukan oleh manusia, seperti pemecahan masalah, pembelajaran, dan pengambilan keputusan (Eisenecker, 1995). Sejarah AI bermula pada tahun 1956, ketika John McCarthy, Marvin Minsky, Nathaniel Rochester, dan Claude Shannon menyelenggarakan konferensi AI pertama di Dartmouth College (Russell, 2021). Saat itu, mereka memiliki pandangan optimis tentang potensi AI dan berharap bahwa komputer dapat dikenali dan diprogram untuk melakukan tugas yang mirip dengan manusia dalam waktu singkat. Pada tahun 2010-an, muncul teknologi pembelajaran mesin profund (*deep learning*), yang memungkinkan komputer untuk mempelajari dan memahami data secara lebih dalam dan akurat.

CNN adalah algoritme yang diterapkan dalam bidang perikanan untuk memecahkan berbagai masalah (Cavieses-Núñez et al., 2021; Chang et al., 2021; Hasan et al., 2022). Ini adalah jenis jaringan saraf tiruan yang khusus dirancang untuk mengatasi masalah analisis citra (Cavieses Núñez et al., 2018; Yu et al., 2020). Dalam perikanan, CNN dapat digunakan untuk melakukan tugas-tugas seperti (Zhao et al, 2021; Han et al. 2020):

1. Identifikasi spesies ikan: CNN dapat digunakan untuk mengidentifikasi spesies ikan dari citra subsurface yang diambil oleh kapal perikanan. Ini membantu memastikan bahwa hanya spesies ikan yang memenuhi syarat untuk ditangkap, serta membantu dalam melakukan pemantauan dan pengendalian populasi ikan.
2. Analisis kualitas ikan: CNN dapat digunakan untuk mempercepat dan memperbaiki proses penilaian kualitas ikan, membantu memastikan bahwa hanya ikan yang memenuhi standar kualitas dan keamanan yang dipasarkan.
3. Pemodelan habitat ikan: CNN dapat digunakan untuk membuat pemodelan habitat ikan, membantu memahami bagaimana aktivitas perikanan mempengaruhi lingkungan dan ekosistem laut.
4. Dengan menggunakan teknologi AI seperti CNN, sektor perikanan dapat menjadi lebih efisien, berkelanjutan, dan merawat lingkungan dan ekosistem laut untuk masa depan.

Beberapa penelitian terkait implementasi AI secara spesifik adalah *deep learning* dalam identifikasi ikan sudah dilakukan. Studi Hridayami et al., (2019) menggunakan CNN untuk mengidentifikasi spesies ikan dari citra *subsurface* yang diambil oleh kapal perikanan, hasil menunjukkan bahwa teknik ini dapat mengidentifikasi spesies ikan dengan akurasi tinggi dengan nilai genuine acceptance rate (GAR) terbaik sebesar 96,4%. Studi Villon et al., (2018) menggunakan teknik deep learning untuk mengidentifikasi spesies ikan dari citra *subsurface*. Studi ini menunjukkan bahwa teknik ini dapat mengidentifikasi spesies ikan dengan akurasi tinggi sebesar 94.9%. Pada penelitian yang dilakukan oleh (Ariawan, 2022) menggunakan CNN untuk mengidentifikasi 3 genus ikan karang dengan hasil yang cukup memuaskan yaitu 85.3%. Berdasarkan penelitian-penelitian tersebut. Diperlukan analisis

terkait pada sub sampel yang berbeda. Penelitian ini mengidentifikasi jenis ikan yang kemudian untuk diklasifikasi dengan menggunakan *library* Tensorflow. Pengumpulan data citra menggunakan citra yang diperoleh dari *internet* dengan dilakukan pelabelan pada citra sebagai data *training* dan data *testing*. Model yang dihasilkan diharapkan dapat mampu mendapatkan akurasi yang baik sehingga penggunaannya dapat dipertimbangkan ke dalam tahapan implementasi.

## B. Rumusan Masalah

Berdasarkan latar belakang yang telah dijabarkan, maka permasalahan-permasalahan tersebut dapat dirumuskan sebagai berikut:

1. Bagaimana performa algoritme CNN dalam mengenali hingga mengklasifikasi citra ikan?
2. Apakah algoritme CNN dapat digunakan untuk mengklasifikasi dan evaluasi model memiliki kinerja yang baik?

## C. Tujuan Penelitian

### 1. Tujuan Umum

Adapun tujuan umum dari penelitian ini adalah untuk menganalisis performa algoritme CNN yang digunakan dalam mengklasifikasi citra ikan dengan baik.

### 2. Tujuan Khusus

Adapun tujuan khusus dari penelitian ini adalah untuk mengevaluasi akurasi algoritme CNN dalam mengenali hingga mengklasifikasi citra ikan.

## D. Manfaat Penelitian

Adapun manfaat dari penelitian ini yaitu :

### 1. Teoritis

Secara teori tugas akhir ini membahas tentang konsep-konsep penerapan algoritme CNN dalam mengenali citra ikan sehingga analisis performa algoritme CNN hingga menghasilkan performa yang diinginkan

yang nantinya diharapkan dapat menjadi acuan bahan rujukan melakukan penelitian lanjutan kedepan, hingga dapat memberikan manfaat secara langsung bagi sektor terkait.

## 2. Praktis

Secara praktis penelitian ini diharapkan mampu memberikan ide baru dalam melakukan pengenalan citra ikan dalam konteks mendukung sektor kelautan secara baru terutama pendekatan yang bersifat komprehensif. Selain itu, penelitian ini juga diharapkan dapat memberikan acuan secara langsung bagaimana pendekatan *image recognition* menggunakan algoritme CNN mulai dari proses *data collection* hingga *model evaluation* diharapkan nantinya model yang telah dibuat bisa menjadi model yang dapat dijadikan acuan pre-train model untuk melakukan identifikasi objek lainnya.

## E. Ruang Lingkup Peneliti

Ruang lingkup dari penelitian ini adalah menerapkan algoritme CNN dalam mengenali citra ikan. Mekanisme pengenalan data citra ikan menggunakan CNN dibatasi dengan dua ikan, yaitu famili *Leiognathidae* dan genus *Sardinella*. Diharapkan dengan menggunakan dataset yang sesuai dapat ditemukan pola yang dapat digunakan algoritma dalam membangun model yang memiliki korelasi kuat antar kelas data dalam label yang ditentukan.

## **BAB II**

### **TINJAUAN PUSTAKA**

#### **A. Image Recognition**

*Image recognition* adalah proses pengenalan suatu objek atau citra melalui analisis digital dan identifikasi yang dilakukan oleh sistem komputer (Duta et al. 2021; He et al., 2016). Hal ini bertujuan untuk membedakan satu objek atau citra dari yang lain dan memberikan informasi yang berguna mengenai objek tersebut. Image recognition adalah bagian dari bidang teknologi pengolahan citra dan memainkan peran penting dalam berbagai aplikasi, seperti pengenalan wajah, deteksi objek, dan banyak lagi (Li, 2020). Teknologi image recognition menggunakan algoritme pembelajaran mesin dan deep learning untuk mengenali objek dalam citra. Algoritme ini mempelajari ciri-ciri unik dan karakteristik dari objek dan membandingkannya dengan basis data yang ada untuk membuat identifikasi (Goodfellow et al. 2016; He et al., 2016). Proses ini membutuhkan banyak data latih dan validasi untuk memastikan akurasi yang baik dalam mengidentifikasi objek.

Image recognition memiliki banyak aplikasi dalam berbagai bidang, seperti retail, manufaktur, medis, perikanan, dan masih banyak lagi (Altaf et al., 2019; Lieber, 2018; Villon et al., 2018). Dalam bidang retail, image recognition digunakan untuk membantu pelanggan menemukan produk yang mereka cari dengan mengambil foto produk atau memindai barcode (Lieber, 2018). Dalam bidang manufaktur, image recognition digunakan untuk memastikan kualitas produk dengan memindai citra produk dan membandingkannya dengan spesifikasi yang ditentukan (Zhao et al., 2019). Dalam bidang medis, image recognition digunakan untuk membantu dokter dalam diagnosis dan memastikan akurasi dalam pengobatan (Altaf et al., 2019).

Beberapa teknologi image recognition yang populer saat ini adalah Convolutional Neural Networks (CNN) dan Deep Learning. CNN adalah teknik

pembelajaran mesin yang memfokuskan pada analisis citra dan digunakan dalam aplikasi image recognition (I, 2021). Deep learning adalah cabang dari pembelajaran mesin yang memfokuskan pada pemrosesan data yang sangat kompleks dan memiliki potensi yang sangat besar dalam aplikasi image recognition.

## **B. Perikanan**

Perikanan adalah sektor ekonomi yang sangat penting bagi kelangsungan hidup umat manusia, karena ikan dan produk perikanan lainnya memberikan sumber protein penting bagi diet manusia (Ramadona et al., 2019). Selain itu, perikanan juga memainkan peran penting dalam pembangunan ekonomi dan pemerataan kesejahteraan sosial (Gumilang & Susilawati, 2020). Oleh karena itu, penting bagi pemerintah dan masyarakat untuk mengelola dan memantau kondisi perikanan secara efektif dan bertanggung jawab (Mardiyani & Yulianti, 2020; Rengi & Ramadona, 2018). Salah satu cara untuk memastikan pengelolaan perikanan yang efektif adalah melalui identifikasi ikan (Pramono et al., 2017). Identifikasi ikan membantu pihak berwenang dan pengelola perikanan untuk memahami jenis ikan yang terdapat di suatu daerah, populasi ikan, dan pola migrasi ikan (Sholihin, 2021). Hal ini memungkinkan mereka untuk mengambil tindakan yang tepat untuk memastikan konservasi populasi ikan dan pemulihan lingkungan perairan (Muthiadin et al., 2018).

Teknologi baru, seperti Artificial Intelligence (AI) dan Image Recognition, kini membantu dalam proses identifikasi ikan (Cavieses Núñez et al., 2018; Cavieses-Núñez et al., 2021; Hridayami et al., 2019). Algoritme AI dapat membantu mengidentifikasi ikan berdasarkan ciri-ciri fisik mereka, seperti bentuk, warna, dan pola (Sholihin, 2021). Image recognition juga dapat membantu dalam pengenalan ikan, dengan menganalisis citra ikan dan membandingkannya dengan basis data yang ada untuk membuat identifikasi. Selain membantu dalam identifikasi ikan, teknologi AI juga dapat membantu dalam memantau dan mengelola perikanan. Misalnya, algoritme AI dapat membantu dalam pengamatan dan pemantauan perikanan ilegal, membantu

dalam pengaturan kuota tangkap ikan, dan membantu dalam memastikan bahwa praktik perikanan berkelanjutan dilakukan.

Penting bagi pemerintah dan masyarakat untuk terus mempertimbangkan peran teknologi AI dalam pengelolaan perikanan dan identifikasi ikan (Barbedo 2022; Villon et al., 2018). Melalui penerapan teknologi yang tepat, kita dapat memastikan bahwa perikanan tetap merupakan sumber yang dapat diandalkan bagi kelangsungan hidup manusia dan lingkungan perairan di masa depan.

### **C. Artificial Intelligence (AI)**

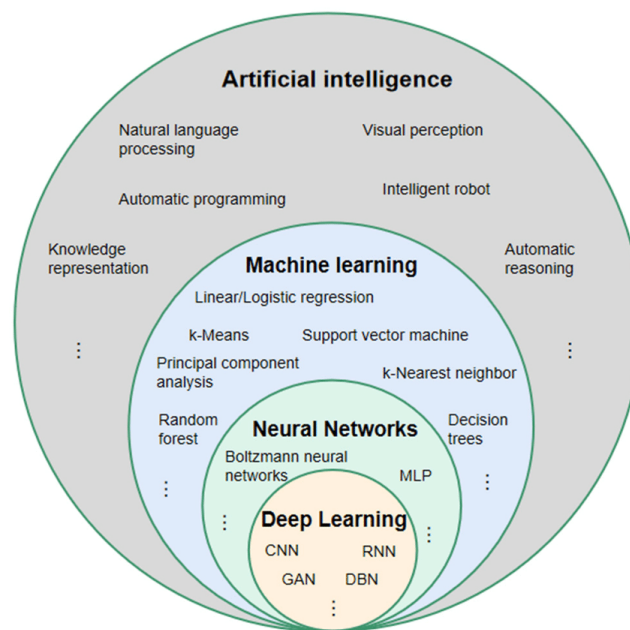
Artificial Intelligence (AI) adalah teknologi yang memungkinkan mesin untuk melakukan tugas yang biasanya hanya bisa dilakukan oleh manusia, seperti pengenalan suara, pemahaman bahasa, dan pemecahan masalah (Rattan et al., 2022). Dalam beberapa tahun terakhir, AI telah mengalami perkembangan pesat dan sekarang digunakan dalam berbagai bidang, seperti perikanan, kesehatan, dan bisnis. Machine Learning (ML) adalah bagian dari AI yang memungkinkan mesin untuk belajar dari data dan membuat keputusan berdasarkan pembelajaran tersebut (Jin et al., 2021).

Proses ML, mesin diberikan data dan tugas untuk mempelajari dari data dan membuat keputusan yang tepat. Mesin mempelajari dari data melalui algoritme ML, seperti regresi linier, k-nearest neighbor, dan decision tree (Alom et al., 2019). Deep Learning (DL) adalah bentuk ML yang menggunakan jaringan syaraf tiruan untuk mempelajari dari data. Jaringan saraf tiruan ini menyerupai jaringan saraf manusia dan dapat mempelajari kompleksitas dan variasi dalam data (Voulodimos et al., 2018). DL digunakan dalam aplikasi seperti pengenalan wajah, pengenalan suara, dan pengenalan bahasa. Pada Gambar 1 adalah gambaran dari AI, ML, dan DL beririsan. Pada skala yang besar AI meng-cover seluruh dari ML dan DL. AI memegang peran seperti pemrograman otomatis, persepsi visual, representasi pengetahuan.

Perkembangan AI terus berlanjut hingga saat ini, dan diharapkan akan terus mengalami perkembangan yang lebih pesat dalam beberapa tahun ke depan. AI sekarang sudah diterapkan dalam berbagai bidang, seperti pengenalan



wajah, pengenalan suara, dan pengenalan objek. Artificial Intelligence (AI) memiliki peran yang semakin penting dalam sektor perikanan, membantu mengatasi masalah-masalah kritis seperti overfishing, pencemaran lingkungan, dan konservasi sumber daya perikanan (Chukkapalli et al., 2021; Ebrahimi et al., 2021; Siskandar et al., 2022). Salah satu pendekatan berbasis AI untuk identifikasi ikan adalah menggunakan salah satu algoritme *deep learning*, yaitu Convolutional Neural Network (CNN).



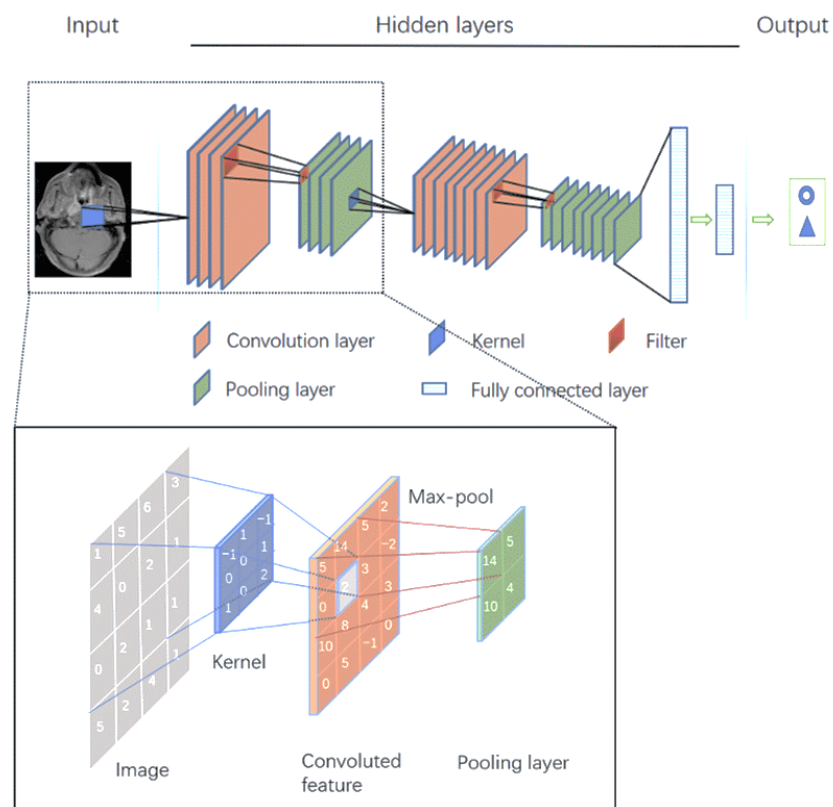
*Gambar 1. AI, Machine Learning, dan Deep Learning (Li et al., 2021)*

AI, ML, dan DL memiliki potensi untuk membuat perubahan besar dalam berbagai bidang dan memberikan solusi untuk masalah-masalah yang sulit untuk diselesaikan dengan metode tradisional. Meskipun AI, ML, dan DL memiliki potensi yang besar, perlu dilakukan penelitian dan pengembangan lebih lanjut untuk memastikan bahwa teknologi ini digunakan secara bertanggung jawab dan memberikan hasil yang positif bagi masyarakat (Nadimpalli, 2017; Win & Yin, 2019).

#### **D. Algoritma Convolutional Neural Network (CNN)**

Algoritme Convolutional Neural Network (CNN) adalah jenis jaringan saraf tiruan yang digunakan dalam pengolahan citra. CNN memiliki beberapa

keunggulan dibandingkan jaringan saraf tiruan lainnya dan sangat berguna dalam aplikasi seperti pengenalan wajah, pengenalan suara, dan pengenalan bahasa (Tian, 2020). CNN terdiri dari beberapa lapisan, termasuk lapisan konvolusi, pooling, dan fully connected (Voulodimos et al., 2018). Lapisan konvolusi melakukan operasi konvolusi pada citra dengan menggunakan filter untuk menemukan fitur dalam citra. Lapisan pooling memperkecil ukuran citra dengan mengambil maksimum dari beberapa titik. Lapisan fully connected menyatukan semua fitur yang ditemukan oleh lapisan sebelumnya dan membuat keputusan akhir (Yu et al., 2021). Pada Gambar 2 adalah gambaran dari arsitektur CNN.



*Gambar 2. Arsitektur CNN (Li et al., 2021)*

CNN memiliki beberapa keuntungan yang besar, seperti kemampuan untuk mempelajari fitur dan karakteristik dalam citra, mampu mengatasi masalah translasi dan rotasi, dan memiliki arsitektur yang efisien (Liu, 2018; Simonyan & Zisserman, 2015). Dalam pengenalan wajah, CNN mampu mengenali wajah dalam citra meskipun ada beberapa transformasi seperti rotasi, skala, atau pencahayaan yang berbeda. Dalam pengenalan suara, CNN mampu

membedakan suara dalam lingkungan yang rumit dan bising. Dalam pengenalan bahasa, CNN mampu membedakan bahasa yang berbeda dan mengenali tipe bahasa dalam teks (Tian, 2020).

Walaupun CNN memiliki keuntungan yang besar, masih ada beberapa hal yang perlu dikembangkan. Salah satu hal ini adalah ketergantungan pada jumlah data latih yang besar dan keterbatasan dalam mengatasi masalah citra yang tidak biasa (Tian, 2020). Oleh karena itu, perlu adanya penelitian lanjutan untuk mengatasi masalah ini dan memperbaiki kinerja CNN.

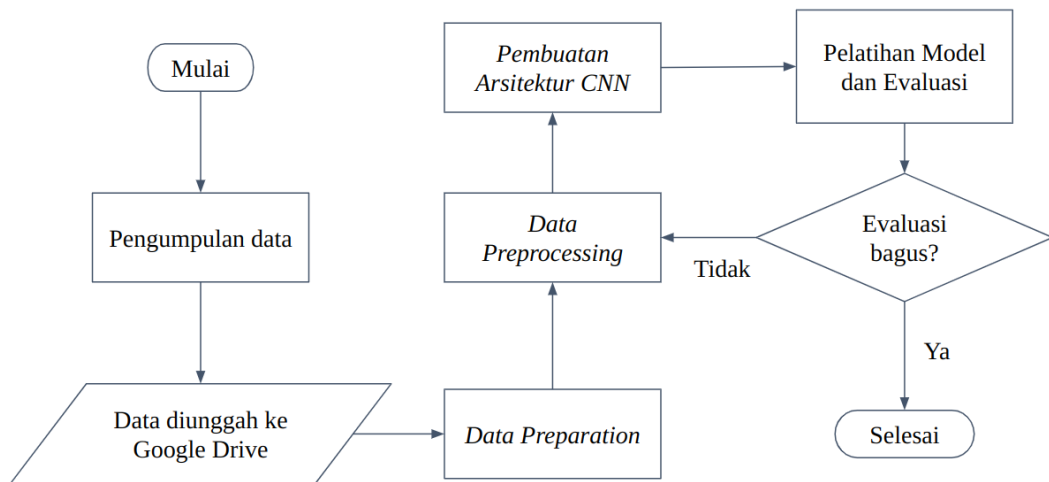
### **E. Penelitian-penelitian Terkait**

Pustaka Beberapa penelitian-penelitian terkait penggunaan *deep learning* dalam identifikasi ikan telah dilakukan. Dalam penelitian yang dilakukan oleh (Iqbal et al., 2021), penulis menunjukkan bahwa deep learning, khususnya Convolutional Neural Networks (CNN), dapat digunakan untuk mengidentifikasi spesies ikan dengan akurasi tinggi, hasilnya menunjukkan bahwa model AlexNet yang diusulkan dan dimodifikasi dengan jumlah lapisan yang lebih sedikit telah mencapai akurasi pengujian sebesar 90,48% sedangkan model AlexNet asli mencapai 86,65%. Pada penelitian yang dilakukan oleh (Allken et al., 2019), mengembangkan dan menerapkan jaringan syaraf tiruan untuk mengotomatiskan klasifikasi spesies yang ada dalam citra yang digabungkan dengan alat tangkap, akurasi yang diperoleh sebesar 94%. Kemudian, pada penelitian yang dilakukan oleh (Lu et al., 2020), menunjukkan bahwa deep learning, khususnya Convolutional Neural Networks (CNN), dapat digunakan untuk mengidentifikasi spesies ikan dengan akurasi tinggi dengan capaian akurasi 96.24%. Pada penelitian yang dilakukan oleh (Rathi et al., 2018), menunjukkan bahwa CNN dapat digunakan untuk mengidentifikasi spesies ikan dengan akurasi tinggi yaitu sebesar 96.29%.

## BAB III METODOLOGI PENELITIAN

### A. Pendekatan/ Desain Penelitian

Pendekatan yang dilakukan dalam penelitian ini adalah pendekatan kuantitatif. Pendekatan kuantitatif artinya informasi atau data yang disajikan berupa angka hasil analisis numerik yang dilakukan dengan metode tertentu. Secara garis besar desain dari penelitian ini adalah menghitung karakteristik citra ikan menggunakan metode *deep learning* untuk kemudian diklasifikasi. Berdasarkan uraian yang telah dikemukakan diatas dapat disimpulkan bahwa penelitian ini menggunakan pendekatan kuantitatif karena semua data yang diperoleh dalam bentuk citra yang kemudian di ekstrak ke dalam format numerik atau matriks. Penelitian ini merupakan jenis penelitian berdasarkan studi kasus. Langkah-langkah pendekatan atau desain penelitian ini digambarkan secara keseluruhan dalam Gambar 3.



*Gambar 3. Pendekatan penelitian*

### B. Metode Penelitian

Metode yang digunakan dalam Metode penelitian kuantitatif adalah suatu pendekatan yang menggunakan data yang dapat diukur dan dianalisis secara statistik untuk memperoleh informasi tentang suatu fenomena (Caroline, 2019). Oleh karena itu, metode penelitian kuantitatif memiliki beberapa

keunggulan, seperti memiliki validitas dan reliabilitas yang tinggi, serta dapat digunakan untuk menguji hipotesis dan memperoleh hasil yang dapat diterima secara umum (Firmansyah dan Masrun, 2021).

Penggunaan CNN untuk identifikasi ikan adalah metode penelitian kuantitatif, hal ini menjadi pilihan yang sangat tepat karena memiliki beberapa keunggulan. Beberapa hal yang menjadi keunggulan dalam hal ini adalah:


1. Pengumpulan data yang valid dan reliabel: Dalam metode penelitian kuantitatif, data yang diperoleh dapat diukur dan dianalisis secara statistik, sehingga memiliki validitas dan reliabilitas yang tinggi.
2. Analisis data yang tepat: Metode penelitian kuantitatif menggunakan analisis data statistik yang tepat untuk memperoleh informasi tentang fenomena yang diteliti.
3. Penentuan model yang tepat: Dalam hal ini, penentuan model yang tepat akan membantu dalam menentukan tingkat akurasi dalam identifikasi ikan.
4. Pengumpulan data yang cepat dan efisien: Dalam metode penelitian kuantitatif, pengumpulan data dapat dilakukan dengan cepat dan efisien, sehingga mempercepat proses identifikasi ikan.
5. Hasil yang dapat diterima secara umum: Hasil yang diperoleh dari metode penelitian kuantitatif memiliki validitas yang tinggi, sehingga dapat diterima secara umum oleh masyarakat.

## C. Teknik Penelitian

### 1. Teknik Pengumpulan Data

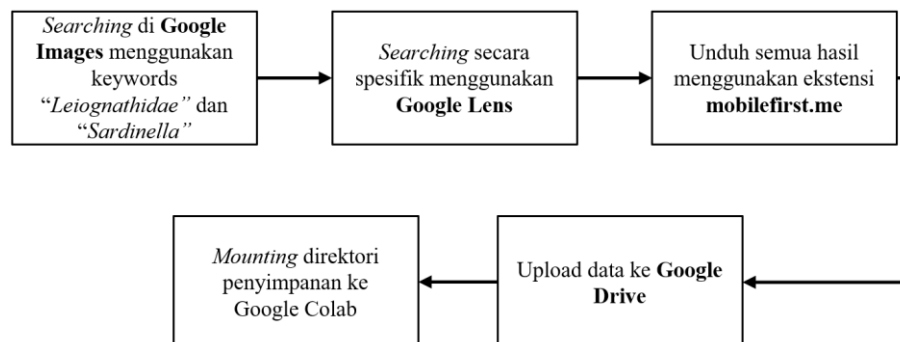
Jadi Teknik pengumpulan data dalam penelitian menggunakan CNN untuk identifikasi ikan melibatkan beberapa langkah sebagai berikut:

1. Pemilihan dataset ikan: Dataset yang dipilih harus representatif dan memenuhi syarat seperti jumlah ikan yang bervariasi, posisi, ukuran, dan warna. Dataset yang digunakan dalam penelitian ini adalah data citra ikan *Leiognathidae* dan *Sardinella*. Dataset ini akan digunakan sebagai data latih dan uji untuk membuat dan menguji model CNN. Pada Gambar 4. kelas data *Leiognathidae* dilabelkan dengan 0 dan kelas data *Sardinella* dilabelkan dengan 1.



Gambar 4. Dataset yang digunakan (Sumber: Peneliti, 2023)


2. Pengumpulan citra: Citra ikan harus diambil dengan kualitas yang baik, seperti tingkat kecerahan dan detail yang baik. Dataset yang dikumpulkan dalam penelitian ini adalah citra ikan *Leiognathidae* dan *Sardinella* dari Google Image, untuk mendapatkan jenis ikan secara spesifik digunakan Google Lens agar citra tidak tercampur dengan citra-citra lain yang tidak berkaitan kuat. Kemudian seluruh data diunduh menggunakan ekstensi Google Chrome yaitu *mobilefirst.me* yang bertujuan untuk *scraping* citra. Data yang sudah diunduh kemudian diupload ke Google Drive dan dilakukan *mounting* atau mengkoneksikan data dari Google Drive ke Google Colab. Jumlah data per kelas adalah 150 citra.



Gambar 5. Proses pengumpulan citra

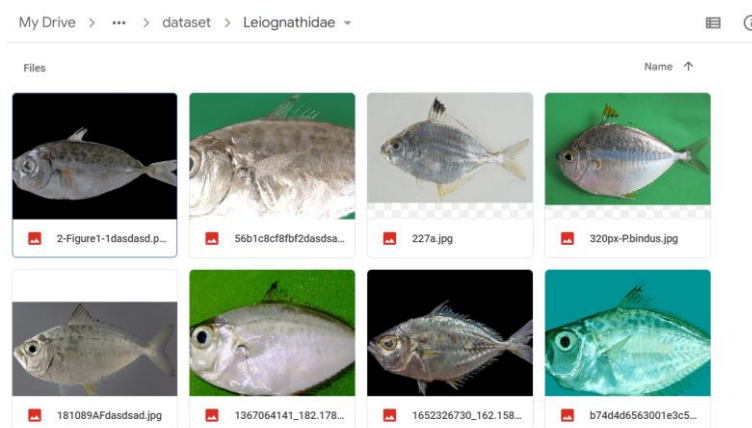
3. *Pre-processing* citra: Setelah citra diambil, proses selanjutnya adalah *preprocessing* citra. *Pre-processing* melibatkan beberapa langkah seperti pengurangan noise, normalisasi, dan *resizing* citra agar sesuai dengan ukuran yang diinginkan. Pada penelitian ini, *Pre-processing* citra dilakukan dengan cara *resizing* citra menjadi 255 x 255 piksel. Contoh

pada Gambar 6, ukuran awal citra adalah 640 x 480 piksel, kemudian di-*resizing* menjadi 255 x 255 piksel. Tujuan dari *resizing* adalah untuk menormalisasi citra agar seragam dan memudah komputasi.

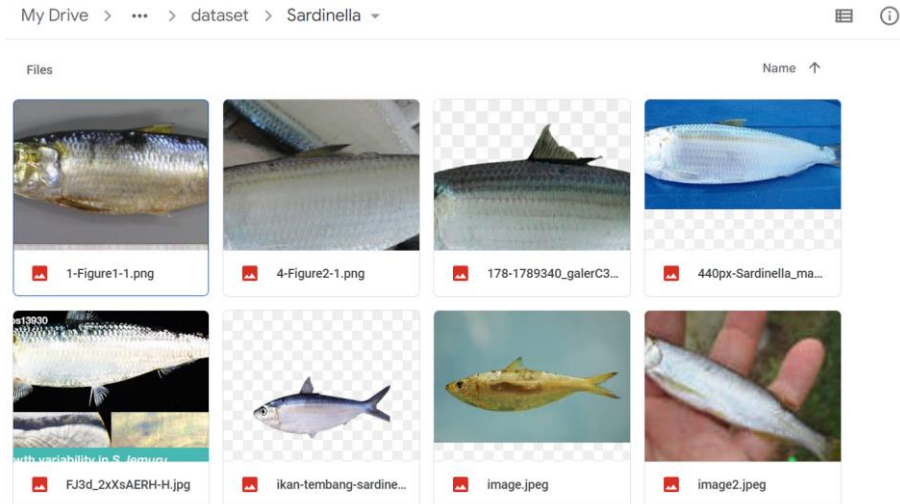


*Gambar 6. Sampel dataset yang digunakan (Sumber: Peneliti, 2023)*

4. Pengelompokan dataset: Setelah pre-processing citra selesai, dataset citra ikan akan dibagi menjadi data latih, validasi, dan uji. Dataset latih digunakan untuk membuat model CNN, dataset validasi digunakan untuk memvalidasi data terhadap model, sedangkan dataset uji digunakan untuk melakukan pengujian yang dalam hal ini adalah data yang tidak disentuh sama sekali oleh model ketika proses latih. Komposisi pembagian dataset adalah 70% data latih, 20% data validasi, 10% data uji. Sample dataset dapat dilihat pada Gambar 7 dan Gambar 8.



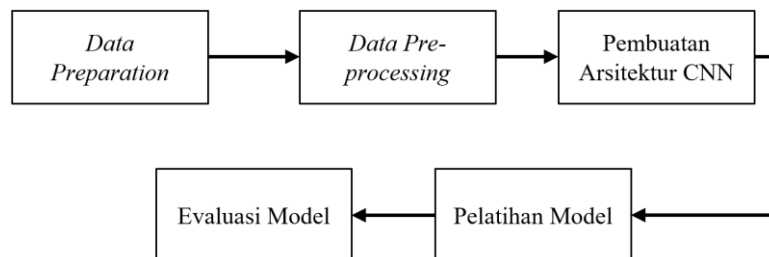
*Gambar 7. Pengelompokan dataset Leiognathidae (Sumber: Peneliti, 2023)*



*Gambar 8. Pengelompokan dataset Sardinella (Sumber: Peneliti, 2023)*

## 2. Teknik Analisis Data

Teknik analisis data dimulai dari persiapan alat dan bahan. Alat yang digunakan dalam penelitian ini adalah sebuah laptop dengan merk Dell dengan spesifikasi Intel Core Core i5 5300 dengan GPU Intel HD Graphics 5500, dengan penyimpanan 256 GB SSD dan 8 GB RAM. Selain itu, *tools* yang yang digunakan dalam penelitian ini adalah Google Colab dengan bahasa pemrograman Python. *Library* yang pendukung yang digunakan dalam penelitian ini adalah seperti TensorFlow, NumPy, dan Matplotlib. Teknik analisis data dilakukan dengan berbagai tahapan, tahapan-tahapan penelitian untuk proses analisis data dapat dilihat pada gambar 9.



*Gambar 9. Tahapan penelitian*

### a. Data Preparation

Langkah ini adalah mengumpulkan data gambar ikan dari berbagai sumber, seperti basis data ikan, situs web, atau melalui



pengambilan gambar langsung. Data harus berkualitas tinggi dan representatif dari spesies ikan yang ingin dikenali.

**b. Data Pre-processing**

Tahap ini adalah melakukan *preprocessing* pada data yang telah dikumpulkan, seperti penyesuaian ukuran gambar, pengurangan noise, dan normalisasi intensitas gambar.

**c. Pembuatan Arsitektur CNN**

Langkah ini adalah menentukan arsitektur jaringan CNN yang akan digunakan untuk memodelkan data ikan (Gambar 10). Ini bisa dilakukan dengan memodifikasi arsitektur jaringan yang sudah ada atau membuat arsitektur baru sesuai dengan kebutuhan.

```
Model: "sequential"
```

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 254, 254, 16)	448
max_pooling2d (MaxPooling2D)	(None, 127, 127, 16)	0
conv2d_1 (Conv2D)	(None, 125, 125, 32)	4640
max_pooling2d_1 (MaxPooling2D)	(None, 62, 62, 32)	0
conv2d_2 (Conv2D)	(None, 60, 60, 16)	4624
max_pooling2d_2 (MaxPooling2D)	(None, 30, 30, 16)	0
flatten (Flatten)	(None, 14400)	0
dense (Dense)	(None, 256)	3686656
dense_1 (Dense)	(None, 1)	257

```

Total params: 3,696,625
Trainable params: 3,696,625
Non-trainable params: 0

```

*Gambar 10. Arsitektur CNN (Sumber: Peneliti, 2023)*

Pada tahap ini, arsitektur Convolutional Neural Network (CNN) adalah salah satu jenis arsitektur neural network yang diterapkan dalam pemrosesan citra. CNN dapat mempelajari fitur dan pola dalam citra dengan cara menggunakan *convolution layer*, *pooling layer*, *flatten layer*, dan *dense layer* (Bhatt et al. 2021). *Convolution layer* adalah layer

yang memiliki tugas melakukan operasi convolution pada setiap piksel dalam citra. Operasi convolution dilakukan dengan cara menggunakan filter atau kernel yang bergerak secara bergeser dan menghitung nilai baru pada setiap piksel dengan membobotkan nilai-nilai piksel di sekitarnya (Ding et al. 2019). Proses ini memungkinkan CNN untuk mempelajari fitur dan pola dalam citra. *Convolution layer* digunakan untuk klasifikasi citra dengan diterapkan ketentuan ukuran awal pada penelitian ini adalah  $254 \times 254 \times 16$ , sehingga gambar dapat dipecah agar mempermudah proses komputasi.

*Pooling layer* adalah layer yang memiliki tugas untuk mengurangi dimensi dari citra setelah dilakukan convolution (Bhatt et al. 2021). Pooling layer biasanya menggunakan operasi max pooling atau average pooling untuk menentukan nilai tertinggi atau rata-rata dari setiap grup piksel. Proses ini membantu mengurangi overfitting dan membuat model lebih robust terhadap perubahan sedikit pada citra. *Pooling layer* merupakan tahapan *dimension reduction* dari *feature map*, sehingga proses komputasi menjadi lebih cepat (Akhtar dan Ragavendran, 2020), hal ini dikarenakan karena ukuran gambar akan dipecah lagi menjadi 2 setelah melewati tahap *convolution layer* sebelumnya, sehingga ukurannya menjadi (127, 127, 16). Metode *pooling layer* yang digunakan pada penelitian ini adalah *max-pooling* yang mengambil nilai terbesar dalam satu bagian.

*Convolution layer* dan *pooling layer* dijadikan satu tahap atau lapisan, karena pada penelitian ini akan diterapkan 3 lapisan (*convolution layer* dan *pooling layer*). Ukuran piksel gambar akan semakin kecil sejalan dengan banyaknya lapisan yang diterapkan. *Flatten layer* adalah layer yang memiliki tugas untuk mengubah bentuk tensor menjadi vector (Akhtar dan Ragavendran, 2020). Proses ini dilakukan sebelum menghubungkan layer *convolutional* dengan layer *fully connected*. *Flatten layer* merupakan layer yang meratakan nilai pada konvolusi. *Flatten* perlu dilakukan sehingga data dapat dijadikan

*input* untuk *layer* selanjutnya yaitu *dense layer (Fully Connected)* (Bhatt et al. 2021).

*Dense layer* adalah *layer* yang memiliki tugas untuk melakukan klasifikasi atau regresi pada citra yang telah diproses oleh *layer-layer* sebelumnya (Akhtar dan Ragavendran, 2020). *Layer* ini memiliki neuron-neuron terhubung secara *fully connected* yang menerima masukan dari *flatten layer* dan memproduksi *output* berupa prediksi kelas atau nilai regresi. Penerapan aktivasi dilakukan pada beberapa *layer* diantaranya aktivasi Relu diterapkan pada *convolution layer* dan *dense layer* pertama, sedangkan aktivasi sigmoid diterapkan pada *dense layer* kedua. Aktivasi relu memungkinkan untuk mempertahankan nilai positif dan merubah nilai negatif menjadi 0, hal ini memungkinkan untuk memperhitungkan pola non-linear (Joshua et al. 2021). Aktivasi sigmoid memungkinkan mengambil *output* dengan rentang nilai 0 hingga 1.

#### d. Pelatihan Model

Tahap ini adalah melatih model CNN dengan data ikan yang telah diolah dan di-*preprocessing* sebelumnya. Dalam tahap ini, model akan menyesuaikan bobot dan bias sehingga dapat membedakan antara spesies ikan yang berbeda.

#### e. Evaluasi Model

Langkah ini adalah mengevaluasi model yang telah dilatih dengan data pengujian. Evaluasi dilakukan dengan mengukur akurasi model dalam memprediksi spesies ikan yang benar. Confusion Matrix adalah tabel yang menunjukkan jumlah prediksi yang benar dan salah yang dilakukan oleh model untuk setiap kelas (Raschka et al., 2020). Confusion matrix biasanya digunakan dalam klasifikasi untuk mengukur performa model dan mengidentifikasi masalah yang ada pada model. Confusion matrix menggambarkan empat jenis hasil yang mungkin dari model klasifikasi: true positive (TP), false positive (FP), true negative (TN), dan false negative (FN).

Berikut adalah penjelasan dari masing-masing elemen dalam confusion matrix (Ketkar & Moolayil, 2021):

- 1) True Positive (TP): jumlah prediksi benar untuk kelas positif, yaitu data yang sebenarnya termasuk ke dalam kelas positif dan juga diprediksikan oleh model sebagai kelas positif.
- 2) False Positive (FP): jumlah prediksi salah untuk kelas positif, yaitu data yang sebenarnya bukan termasuk ke dalam kelas positif, tetapi diprediksikan oleh model sebagai kelas positif.
- 3) True Negative (TN): jumlah prediksi benar untuk kelas negatif, yaitu data yang sebenarnya bukan termasuk ke dalam kelas positif dan juga diprediksikan oleh model sebagai kelas negatif.
- 4) False Negative (FN): jumlah prediksi salah untuk kelas negatif, yaitu data yang sebenarnya termasuk ke dalam kelas positif, tetapi diprediksikan oleh model sebagai kelas negatif.
- 5) *Confusion matrix* bisa memberikan informasi yang berguna untuk mengukur performa model dan mengidentifikasi masalah yang ada pada model, seperti misclassification, imbalanced class, dll. Beberapa metrik yang biasa digunakan untuk mengevaluasi performa model berdasarkan confusion matrix antara lain accuracy, precision, recall, dan F1 score. Pengukuran *accuracy* dapat dilakukan dengan Persamaan (1), *precision* dapat dilakukan dengan Persamaan (2), dan *recall* dilakukan dengan Persamaan (3) (Juba & Le, 2019):

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \times 100 \quad (1)$$

$$Precision = \frac{TP}{TP+FP} \times 100 \quad (2)$$

$$Recall = \frac{TP}{TP+FN} \times 100 \quad (3)$$

## D. Latar/ Setting Penelitian

### 1. Waktu Penelitian

Penelitian ini dilaksanakan selama kurang lebih empat bulan untuk pengumpulan data, olah data, hingga penulisan artikel dimulai dari bulan Januari sampai dengan bulan April tahun 2023.

## 2. Tempat Penelitian

Lokasi penelitian ini dilakukan di Laboratorium Komputer Universitas Pendidikan Indonesia Kampus Serang dalam kurun waktu yang telah ditentukan

## E. Subyek Penelitian

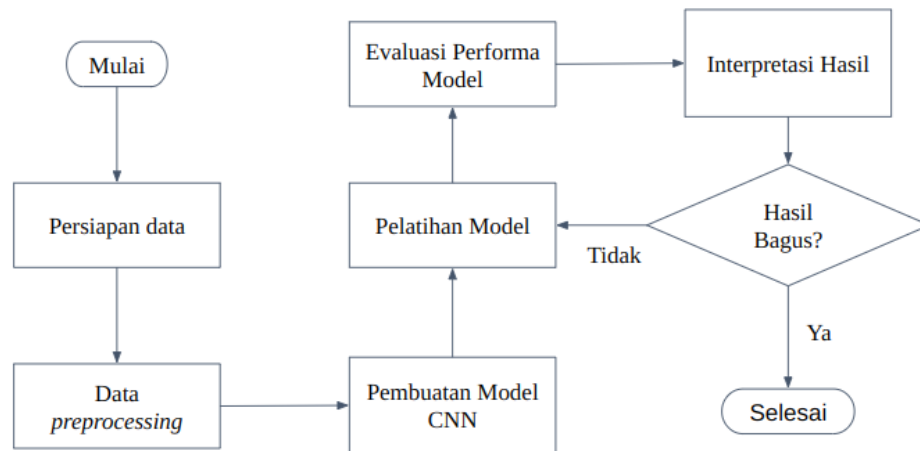
Subjek dari penelitian CNN untuk identifikasi ikan adalah penerapan teknik *deep learning* untuk memecahkan masalah identifikasi spesies ikan. Tujuannya adalah untuk membangun model yang mampu mengidentifikasi spesies ikan berdasarkan citra yang telah ditentukan. Penelitian ini melibatkan beberapa tahap, seperti pre-processing data, pembuatan model CNN, pelatihan model, evaluasi performa model, dan interpretasi hasil. Subjek penelitian ini memiliki dampak penting bagi berbagai bidang, seperti biologi, industri perikanan, konservasi lingkungan, dll. Hasil dari penelitian ini dapat digunakan untuk mempermudah identifikasi spesies ikan dan membantu pengambilan keputusan dalam berbagai bidang.

## F. Prosedur Penelitian

Berikut adalah prosedur dalam penelitian penggunaan CNN untuk identifikasi ikan adalah sebagai berikut (Gambar 11):

1. **Persiapan Data:** Ini melibatkan pengumpulan dataset gambar ikan dari sumber yang terpercaya. Data biasanya dibagi menjadi beberapa bagian seperti data latih, data validasi, dan data uji.
2. **Preprocessing Data:** Ini melibatkan beberapa tahap untuk mempersiapkan data sebelum diteruskan ke model CNN. Beberapa tahap meliputi resizing gambar, normalisasi data, dan pengubahan format data menjadi tensor.
3. **Pembuatan Model CNN:** Ini melibatkan pemilihan arsitektur CNN yang sesuai, penambahan layer-layer yang diperlukan, dan konfigurasi hyperparameter model.
4. **Pelatihan Model:** Ini melibatkan menggunakan data latih untuk melatih model agar dapat memprediksi spesies ikan dengan baik. Pelatihan dilakukan dengan menggunakan algoritme optimasi seperti stochastic gradient descent (SGD) atau adaptive moment estimation (Adam).

5. Evaluasi Performa Model: Ini melibatkan menguji performa model dengan menggunakan data uji. Beberapa metrik yang digunakan untuk menilai performa model antara lain akurasi, precision, recall, dan F1-score.
6. Interpretasi Hasil: Ini melibatkan menganalisis hasil dan menarik kesimpulan dari hasil evaluasi performa model. Beberapa hal yang dapat dianalisis antara lain kelebihan dan kekurangan dari model, faktor yang mempengaruhi performa model, dan rekomendasi untuk pengembangan model selanjutnya.



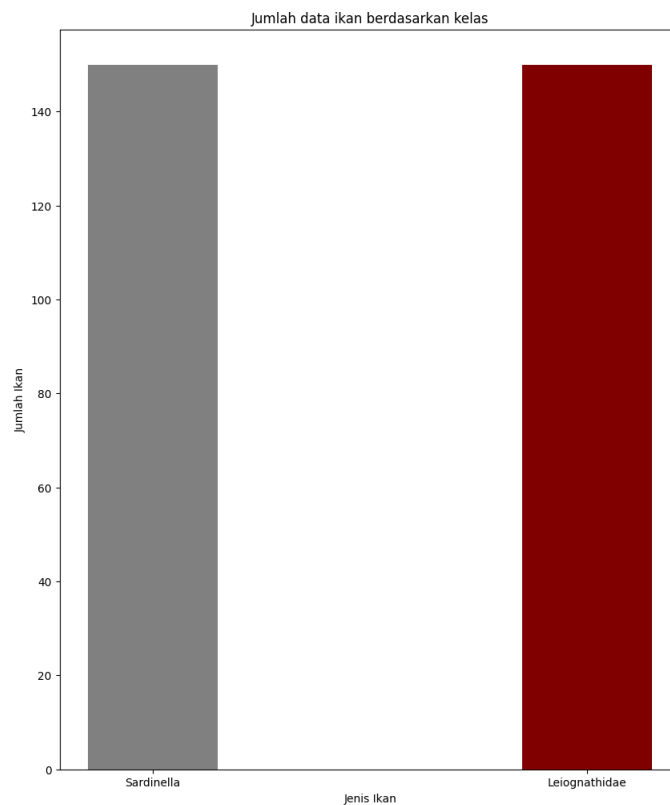
*Gambar 11. Prosedur penelitian*

## BAB IV

### HASIL DAN PEMBAHASAN

#### A. *Data Preparation dan Data Preprocessing*

Tahapan *data preparation* meliputi berbagai proses seperti pengumpulan data, *preprocessing data*, pembagian data menjadi *training* dan *validation set*, augmentasi data, dan labeling data. Tujuan dari tahapan ini adalah untuk memastikan data yang digunakan dalam analisis atau prediksi sudah bersih, terstruktur, dan dapat digunakan oleh model atau algoritma yang akan digunakan. Proses pengumpulan data pada penelitian ini telah dilakukan dengan mengumpulkan citra ikan *Leiognathidae* dan *Sardinella*. Distribusi jumlah data yang telah dikumpulkan dalam penelitian ini dapat dilihat pada Gambar 12.



*Gambar 12. Jumlah data ikan berdasarkan jenis ikan (Sumber: Peneliti, 2023)*

Pada Gambar 12 dapat dilihat bahwa distribusi data adalah balance, hal ini menyesuaikan dengan hasil pencarian *dataset* menggunakan Google Lens

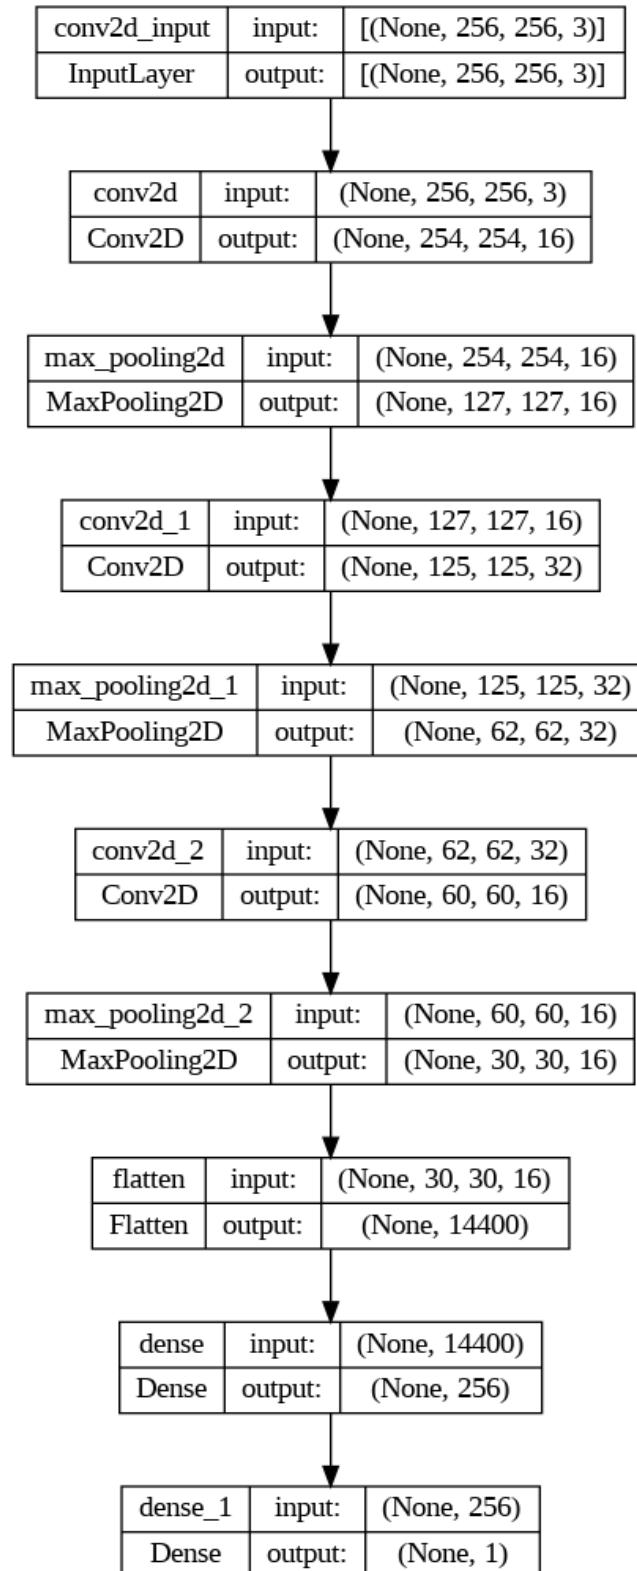
yang kemudian diunduh menggunakan ekstensi pada browser Chrome, jumlah data ini disesuaikan melalui proses filter secara manual.

## B. Pendefinisian Arsitektur

Pendefinisian arsitektur pada penelitian ini adalah proses merancang struktur atau model CNN (*Convolutional Neural Network*) dengan menentukan berapa banyak layer konvolusi, max pooling, dan fully connected yang akan digunakan, serta ukuran filter, fungsi aktivasi, dan parameter lainnya (Bhatt et al. 2021). Arsitektur CNN dalam penelitian ini dapat mempengaruhi kinerja dan akurasi model secara baik dalam melakukan tugas klasifikasi objek pada gambar.

Pendefinisian arsitektur CNN dapat dilakukan dengan menggunakan berbagai metode seperti *trial and error*, *transfer learning*, atau menggunakan arsitektur yang telah terbukti berhasil dalam tugas serupa. Beberapa faktor yang perlu dipertimbangkan dalam pendefinisian arsitektur CNN antara lain kompleksitas model, ukuran filter dan kernel, jumlah layer, jumlah neuron, dan parameter lainnya (Bhat et al. 2021). Pendefinisian arsitektur CNN dalam penelitian ini dilakukan menggunakan *library* atau *framework* seperti Keras, TensorFlow, atau PyTorch. Selain itu, untuk meningkatkan akurasi dan mengurangi *overfitting*, beberapa teknik seperti *dropout*, *batch normalization*, dan *data augmentation* juga dapat diterapkan pada arsitektur CNN. Arsitektur yang digunakan dalam penelitian ini dapat dilihat pada Gambar 13.






Gambar 13. Arsitektur CNN (Sumber: Peneliti, 2023)

Arsitektur yang didefinisikan Gambar 13 memiliki 3 layer konvolusi dan 3 layer max pooling, serta 2 layer fully connected. Berikut adalah penjelasan arsitektur per *layer*:

1. Layer konvolusi pertama memiliki 16 filter dengan ukuran (3,3) (Gambar 14) dan menggunakan fungsi aktivasi ReLU. Input shape yang digunakan adalah (256,256,3), artinya gambar input berukuran 256x256 dengan 3 *channel* (RGB). Filter dengan ukuran (3,3) akan digeser pada seluruh gambar *input* dan menghasilkan *feature map* yang baru (Gambar 15).



Gambar 14. Filter 3x3 (Sumber: Peneliti, 2023)


1	1	1	0	0	<table border="1"> <tbody> <tr> <td>4</td><td>3</td><td>4</td> </tr> <tr> <td>2</td><td>4</td><td>3</td> </tr> <tr> <td>2</td><td>3</td><td>4</td> </tr> </tbody> </table>	4	3	4	2	4	3	2	3	4
4	3	4												
2	4	3												
2	3	4												
0	1	1	1	0										
0	0	1 <sub>x1</sub>	1 <sub>x0</sub>	1 <sub>x1</sub>										
0	0	1 <sub>x0</sub>	1 <sub>x1</sub>	0 <sub>x0</sub>										
0	1	1 <sub>x1</sub>	0 <sub>x0</sub>	0 <sub>x1</sub>										

Image

Convolved Feature

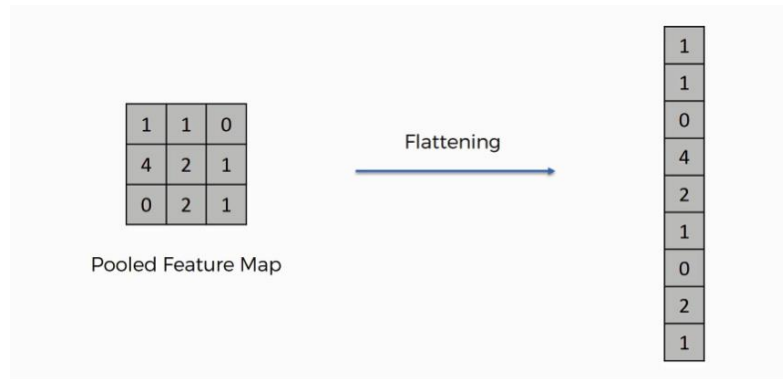
Gambar 15. Gambaran hasil konvolusi filter 3 x 3 (Sumber: Peneliti, 2023)

2. Layer *max pooling* pada Gambar 16, pertama mengambil nilai maksimum dari setiap blok dengan ukuran (2,2) pada setiap feature map yang dihasilkan oleh layer konvolusi pertama.



Gambar 16. Pooling (Sumber: Peneliti, 2023)

3. Layer konvolusi kedua memiliki 32 filter dengan ukuran (3,3) dan menggunakan fungsi aktivasi ReLU. Layer konvolusi kedua akan mengambil feature map dari layer max pooling pertama sebagai input dan menghasilkan feature map baru.
4. Layer max pooling kedua melakukan operasi *max pooling* yang sama seperti layer *max pooling* pertama pada *feature map* yang dihasilkan oleh layer konvolusi kedua.
5. Layer konvolusi ketiga memiliki 16 filter dengan ukuran (3,3) dan menggunakan fungsi aktivasi ReLU. Layer konvolusi ketiga akan mengambil *feature map* dari layer *max pooling* kedua sebagai *input* dan menghasilkan *feature map* baru.
6. Layer *max pooling* ketiga melakukan operasi *max pooling* yang sama seperti layer *max pooling* pertama dan kedua pada *feature map* yang dihasilkan oleh layer konvolusi ketiga.
7. Layer *flatten* (Gambar 17) mengubah *output* dari layer max pooling ketiga menjadi bentuk vektor untuk dijadikan input untuk layer fully connected.



*Gambar 17. Flatten proses (Sumber: Peneliti, 2023)*

8. Layer *fully connected* pertama memiliki 256 neuron dan menggunakan fungsi aktivasi ReLU.
9. Layer *fully connected* kedua memiliki 1 neuron dan menggunakan fungsi aktivasi sigmoid. Layer ini merupakan output layer yang menghasilkan nilai prediksi (0 atau 1) untuk klasifikasi biner.

Jadi, arsitektur CNN yang digunakan pada penelitian ini merupakan model klasifikasi biner dengan 3 layer konvolusi, 3 layer max pooling, dan 2 layer *fully connected*.

### C. Model Training dan Evaluasi

Model training dalam penelitian ini adalah proses melatih sebuah model *deep learning* yaitu dengan menggunakan dataset yang telah dipersiapkan sebelumnya. Tujuannya adalah untuk membuat model tersebut dapat mempelajari pola atau relasi antar data dalam dataset yaitu citra ikan sehingga mampu melakukan tugas klasifikasi citra ikan.

Pada proses training, model diberikan data latih yang terdiri dari input dan output yang diharapkan. Model akan mencoba untuk mempelajari pola atau relasi antara input dan output tersebut dengan melakukan iterasi melalui dataset sebanyak beberapa kali (*epoch*). Setiap iterasi tersebut, model akan memperbaiki nilai parameter yang ada pada modelnya, sehingga semakin lama model dilatih, semakin akurat pula hasil prediksinya.

Proses training model memerlukan beberapa parameter seperti *optimizer* dan *loss function* (Kan et al. 2021). *Optimizer* digunakan untuk mengatur cara update parameter model pada setiap iterasi, *optimizer* yang digunakan dalam

penelitian ini adalah *adam*. *Loss function* digunakan untuk mengukur seberapa baik model memetakan input ke output yang diharapkan, *loss function* yang digunakan dalam penelitian ini adalah *Binary Cross entropy* (Kan et al. 2021). Hasil *training* dan evaluasi model dapat dilihat pada Tabel 1.

*Tabel 1. Hasil training dan evaluasi model*

Epoch	Accuracy	Loss	Val. Accuracy	Val. Loss
1	0.513	0.879	0.563	0.672
2	0.643	0.638	0.672	0.563
3	0.674	0.571	0.828	0.463
4	0.763	0.486	0.875	0.389
5	0.862	0.369	0.844	0.318
6	0.848	0.295	0.875	0.311
7	0.929	0.235	0.922	0.205
8	0.929	0.163	0.984	0.082
9	0.920	0.173	0.922	0.114
10	0.973	0.109	0.953	0.077
11	0.973	0.081	0.922	0.150
12	0.982	0.081	0.969	0.079
13	0.982	0.051	1.000	0.034
14	0.969	0.078	0.984	0.083
15	0.987	0.065	0.984	0.037
16	0.982	0.055	1.000	0.016
17	0.996	0.022	1.000	0.012
18	0.987	0.030	1.000	0.017
19	1.000	0.013	1.000	0.013
20	1.000	0.011	1.000	0.009

Tabel 1 menunjukkan performa model pada setiap epoch selama proses training dan validasi. Berikut adalah penjelasan detail dari setiap kolom pada tabel:

1. *Epoch*: *Epoch* adalah satu iterasi lengkap pada seluruh dataset yang digunakan untuk training model. Pada tabel ini, kita melihat hasil model pada setiap epoch yang berjalan.
2. *Accuracy*: Akurasi adalah ukuran seberapa banyak model yang memberikan prediksi yang benar dibandingkan dengan keseluruhan data. Pada tabel ini, accuracy menunjukkan seberapa baik model dalam melakukan klasifikasi data pada setiap epoch.


3. *Loss*: *Loss* adalah ukuran seberapa buruk atau baik model dalam melakukan prediksi. Pada tabel ini, *loss* menunjukkan seberapa besar perbedaan antara prediksi model dan nilai sebenarnya pada setiap epoch.
4. *Val. Accuracy*: *Validation accuracy* adalah akurasi model pada dataset validasi. Pada tabel ini, *val. accuracy* menunjukkan seberapa baik model dalam melakukan klasifikasi pada dataset validasi pada setiap epoch.
5. *Val. Loss*: *Validation loss* adalah nilai *loss* pada dataset validasi. Pada tabel ini, *val. loss* menunjukkan seberapa besar perbedaan antara prediksi model dan nilai sebenarnya pada dataset validasi pada setiap epoch.

Berdasarkan Tabel 1, dapat dilihat bahwa pada epoch pertama, model memiliki akurasi sebesar 0.513 dan *loss* sebesar 0.879. Pada setiap epoch selanjutnya, akurasi meningkat dan *loss* menurun, menunjukkan bahwa model semakin baik dalam melakukan prediksi dan semakin mendekati nilai yang benar. Pada epoch ke-19 dan ke-20, akurasi mencapai 1.0 (100%) pada training dan validasi, yang menunjukkan bahwa model sudah sangat baik dalam melakukan klasifikasi.


Akurasi yang mendekati sempurna hal ini dikarenakan oleh penggunaan arsitektur model CNN yang efektif, proses pelatihan yang optimal (*tuning parameter*), dan kualitas data dan preprocessing yang baik (Kubo et al. 2022). Akurasi yang tinggi diperoleh pada beberapa penelitian. Pada penelitian yang dilakukan oleh Ariawan et al. (2021), penelitian ini menggunakan random forest untuk mengidentifikasi mangrove dan memperoleh akurasi sempurna yaitu 100%. Pada penelitian yang dilakukan oleh Ariawan et al. (2022), menggunakan satu layer CNN memperoleh akurasi sebesar 85% untuk identifikasi genus ikan karang. Namun hal ini dapat diperhatikan dan dapat dibandingkan dengan penelitian ini memperoleh akurasi sebesar 100% dikarenakan menggunakan CNN dengan tiga layer. Pada yang dilakukan oleh Sahu et al. (2023), memperoleh akurasi sebesar 99.17% untuk mengklasifikasi kanker payudara menggunakan CNN dengan teknik hybrid yaitu dengan skema ShuffleNet-ResNet yaitu dengan skema randomisasi layer CNN pada dataset..

Hal ini dapat disimpulkan bahwa dengan pendekatan yang sesuai dapat diperoleh akurasi yang tinggi.

Grafik akurasi dan loss model dapat dilihat pada Gambar 18 dan Gambar 19.



*Gambar 18. Grafik akurasi model*



*Gambar 19. Grafik loss model*

Dari tabel tersebut, terlihat bahwa model yang dibangun mampu belajar dengan baik selama proses pelatihan. Setiap epoch menunjukkan akurasi dan

loss pada data pelatihan (train) dan data validasi (validation). Pada awal pelatihan (epoch 1), akurasi pada data pelatihan hanya sekitar 51% dan loss yang cukup tinggi (0.879). Namun, setelah beberapa epoch, akurasi dan loss pada data pelatihan terus meningkat dan menurun, menunjukkan model tersebut semakin belajar.

Pada epoch ke-8, model mencapai akurasi tertinggi pada data pelatihan, yaitu 0.929, dengan loss sebesar 0.163. Pada epoch yang sama, akurasi pada data validasi juga sangat tinggi (0.984) dengan loss yang rendah (0.082), menunjukkan bahwa model tersebut tidak hanya mampu melakukan generalisasi pada data pelatihan, tetapi juga dapat mengklasifikasikan data yang belum pernah dilihat sebelumnya dengan sangat baik. Meskipun ada fluktuasi dalam akurasi dan loss pada beberapa epoch, terlihat bahwa model tersebut stabil dalam mencapai akurasi dan loss yang baik pada data pelatihan dan data validasi. Pada akhir pelatihan (epoch ke-20), model mencapai akurasi dan loss yang sempurna pada data pelatihan (1.000 dan 0.011) dan data validasi (1.000 dan 0.009), menunjukkan bahwa model tersebut telah belajar sepenuhnya dan dapat digunakan untuk mengklasifikasikan citra ikan dengan sangat baik. Namun, perlu diingat bahwa terdapat kemungkinan overfitting jika model terlalu difokuskan pada data pelatihan, sehingga perlu dilakukan evaluasi lebih lanjut pada data yang belum pernah dilihat sebelumnya (Ying, 2019).

Grafik akurasi semakin tinggi dan loss semakin turun pada Convolutional Neural Network (CNN) menunjukkan bahwa model CNN yang dibuat semakin baik dalam melakukan klasifikasi citra (Firmansyah, 2020). Loss pada CNN mengukur seberapa besar perbedaan antara nilai prediksi dan nilai sebenarnya, sedangkan akurasi mengukur seberapa akurat model dalam memprediksi kelas citra. Semakin kecil nilai loss, semakin baik model dalam memprediksi kelas citra, dan semakin tinggi nilai akurasi, semakin akurat model dalam memprediksi kelas citra (Firmansyah, 2020).

Terdapat beberapa penelitian terkait dengan Convolutional Neural Network (CNN) yang bertujuan untuk mengklasifikasikan gambar menggunakan metode CNN. Pada penelitian Latupono (2018), berhasil mencapai akurasi sebesar 95,83% dengan loss sebesar 0,146. Selain itu, terdapat



juga penelitian yang menggunakan metode CNN untuk menganalisis kesegaran ikan mujair dan ikan nila oleh Sianturi (2021), penelitian mencapai akurasi sebesar 95,83% dengan loss sebesar 0,146. Hal ini menunjukkan bahwa semakin tinggi akurasi akan diikuti dengan penurunan loss.

## **BAB V**

### **SIMPULAN DAN SARAN**

#### **A. Simpulan**

Kesimpulan yang dapat diambil dari penelitian ini adalah sebagai berikut:

1. Arsitektur CNN yang dibangun melalui proses pelatihan dan validasi menggunakan dataset yang disiapkan, model CNN berhasil mencapai akurasi 100% pada tahap training dan validasi. Hasil ini menunjukkan bahwa algoritme CNN memiliki performa dalam mengenali dan mengklasifikasikan citra ikan dengan sangat baik.
2. Hasil evaluasi akurasi model meningkat dan loss menurun seiring bertambahnya epoch, menunjukkan peningkatan dalam prediksi model. Pada epoch ke-19 dan ke-20, model mencapai akurasi 100% pada training dan validasi.

Melalui hasil yang dicapai dalam penelitian ini, dapat disimpulkan bahwa algoritme CNN memiliki potensi yang besar dalam memberikan kontribusi dalam bidang perikanan. Dengan kemampuannya dalam mengenali dan mengklasifikasikan citra ikan, algoritme CNN dapat digunakan dalam berbagai aplikasi seperti identifikasi spesies ikan, pemantauan ekosistem laut, dan konservasi sumber daya kelautan.

#### **B. Saran**

Saran dari penelitian ini adalah, perlu dilakukan evaluasi lebih lanjut untuk menghindari overfitting dan memastikan generalisasi yang baik dengan kapasitas jumlah data yang lebih banyak untuk memastikan model dapat menggeneralisasi dengan baik lagi. Saran untuk penelitian selanjutnya adalah dapat menggunakan dataset yang berbeda dengan arsitektur model yang berbeda.