

BAB II

LANDASAN TEORI

2.1 Penelitian Terkait

Dalam penelitian ini, penulis telah melakukan analisis terhadap referensi dari penelitian-penelitian sebelumnya yang relevan dengan topik yang dibahas dalam penelitian ini.

1. Menurut penelitian (Muchtar *et al.*, 2024).

Pada penelitian yang berjudul “Penerapan metode Naïve Bayes dalam klasifikasi kesegaran ikan berdasarkan analisis warna pada citra area mata”, ditemukan bahwa metode *Naïve Bayes* menunjukkan keunggulan dibandingkan dengan semua metode lainnya dalam hal akurasi dan presisi. Di sisi lain, metode *k-NN* dan *SVM* mencatatkan nilai recall terbaik di antara metode yang diuji. Hasil ini mengindikasikan bahwa dalam pengujian klasifikasi kesegaran ikan berdasarkan fitur entropi, metode *Naïve Bayes* memberikan kinerja terbaik. Kemampuan *Naïve Bayes* dalam mengelola data serta asumsi independensi antar fitur menjadikannya pilihan yang efektif untuk kasus ini.

Penerapan metode *Naïve Bayes* dalam klasifikasi kesegaran ikan berdasarkan analisis warna pada citra area mata menghasilkan kinerja yang sangat

baik, dengan tingkat akurasi mencapai 97,5%. Model ini juga mencatatkan nilai presisi sebesar 100% dan recall sebesar 95%. Keberhasilan ini menandakan bahwa metode *Naïve Bayes* memiliki potensi besar dalam membedakan tingkat kesegaran ikan. Penelitian ini dapat dijadikan solusi efektif untuk mendeteksi dan mengklasifikasikan ikan segar dan tidak segar secara otomatis.

2. Menurut penelitian (Cakra *et al.*, 2022).

Dalam penelitian yang berjudul “Analisis Kesegaran Ikan Mujair dan Ikan Nila dengan Metode *Convolutional Neural Network*”, kami melakukan eksperimen untuk mengklasifikasikan kesegaran ikan (segar dan tidak segar) berdasarkan citra mata ikan mujair dan ikan nila menggunakan transfer learning dari enam arsitektur CNN, yaitu ResNet, AlexNet, VGG-16, SqueezeNet, DenseNet, dan Inception. Berdasarkan hasil penelitian, untuk ikan mujair yang menggunakan 451 citra, arsitektur VGG-16 menunjukkan kinerja terbaik dengan tingkat akurasi klasifikasi mencapai 73%. Sedangkan untuk ikan nila yang menggunakan 574 citra, VGG-16 juga menunjukkan kinerja yang lebih baik dibandingkan arsitektur lainnya, dengan akurasi klasifikasi mencapai 57,9%. Penelitian ini bertujuan untuk mengidentifikasi kesegaran ikan mujair dan ikan nila menggunakan berbagai metode selain *Convolutional Neural Network* guna membandingkan tingkat akurasi dan keberhasilan setiap metode yang diterapkan.

3. Menurut penelitian (Christiawan, Santoso and Setiabudi, 2021).

Penelitian ini berjudul "Deteksi Tingkat Kesegaran Ikan Menggunakan Metode *Convolutional Neural Network* dengan Parameter Mata dan Warna Insang".

Berdasarkan hasil pengujian, model *Convolutional Neural Network* (CNN) yang dikembangkan menunjukkan kinerja yang sangat baik dalam membedakan jenis ikan. Dari total 20 gambar yang diuji, model ini berhasil mencapai tingkat akurasi sebesar 90%, dengan hanya 2 gambar ikan yang terdeteksi salah jenisnya.

Model juga berhasil mendeteksi tingkat kesegaran mata ikan dengan baik, meskipun terdapat beberapa kesalahan dalam mendeteksi tingkat kesegaran mata ikan kerapu. Kesalahan ini disebabkan oleh kesamaan warna hitam pada mata ikan untuk semua kategori kesegaran, yakni segar, cukup segar, dan tidak segar.

Dalam hal deteksi tingkat kesegaran insang, model masih menunjukkan beberapa kesalahan. Perbedaan antara insang ikan segar, cukup segar, dan tidak segar memang sangat kecil. Namun, jika diberi toleransi kesalahan satu tingkat, seperti menganggap ikan yang seharusnya segar sebagai cukup segar, maka dapat disimpulkan bahwa model *Convolutional Neural Network* (CNN) sudah cukup baik dalam mendeteksi tingkat kesegaran insang ikan. Hasil pengujian menunjukkan bahwa perbedaan antara deteksi aplikasi dan deteksi manual hanya terpaut satu tingkat. Selain itu, faktor pencahayaan juga berpengaruh pada hasil deteksi tingkat kesegaran ikan. Sebagai contoh, insang ikan kerapu yang tampak merah muda karena pencahayaan dapat menyebabkan deteksi menjadi kurang akurat.

2.2 Ikan Mungkus

Ikan mungkus (*Sicyopterus stimpsoni*) adalah ikan air tawar yang hidup di aliran sungai dengan dasar pasir dan bebatuan, terutama di daerah yang memiliki arus deras dan air yang jernih. Ikan mungkus juga merupakan ikan maskot dari

Kabupaten Kaur, Provinsi Bengkulu. Selain ikan lainnya, ikan mungkus menjadi salah satu primadona ikan air tawar yang sangat disukai oleh masyarakat di Kaur dan Bengkulu Selatan.

Ikan mungkus merupakan pemakan lumut (*alga*) yang tumbuh di permukaan bebatuan. Di beberapa daerah di Indonesia, seperti Bengkulu Selatan dan Kaur, ikan mungkus diolah menjadi berbagai hidangan khas, salah satunya adalah gulai ikan mungkus, yang memiliki cita rasa manis dan gurih, sehingga menjadi favorit masyarakat untuk dikonsumsi. Meskipun semakin sulit ditemukan karena penurunan habitat alaminya, popularitas hidangan ini tetap tinggi di kalangan masyarakat.

Ikan mungkus (*Sicyopterus stimpsoni*) dikenal sebagai sumber nutrisi yang sangat bermanfaat bagi kesehatan. Beberapa kandungan gizi utama yang ada pada ikan mungkus meliputi protein, asam lemak omega-3, vitamin D, dan mineral. Selain itu, ikan ini juga memiliki kadar lemak yang rendah, yang memberikan manfaat baik bagi kesehatan tubuh.

2.3 Klasifikasi

Klasifikasi merupakan proses pengelompokan objek atau data ke dalam kategori atau kelas berdasarkan ciri-ciri tertentu. Tujuan utama dari klasifikasi adalah untuk mempermudah analisis dan pengolahan data, serta membantu dalam pengambilan keputusan. Sebagai contoh, dalam pengolahan citra, klasifikasi dapat digunakan untuk mengidentifikasi objek-objek spesifik yang terdapat dalam sebuah citra (Rosyani, Saprudin and Amalia, 2021).

Klasifikasi juga sering digunakan dalam bidang pembelajaran mesin (machine learning) atau kecerdasan buatan (AI) untuk membuat prediksi atau klasifikasi terhadap data berdasarkan data pelatihan (training data) yang telah tersedia sebelumnya.

Dalam pembelajaran mesin (machine learning), klasifikasi adalah metode yang digunakan untuk memprediksi label atau kategori dari data input berdasarkan data pelatihan yang sudah diberi label sebelumnya. Sebagai contoh, dalam klasifikasi kesegaran ikan, model pembelajaran mesin dapat dilatih untuk menentukan apakah ikan tersebut segar atau tidak, berdasarkan citra mata dan insang ikan.

Dalam klasifikasi, terdapat dua tahap utama, yaitu pelatihan dan pengujian. Pada tahap pelatihan, model klasifikasi dikembangkan menggunakan dataset yang sudah dilabeli, di mana setiap contoh dalam dataset memiliki kelas yang sudah diketahui. Model ini kemudian dilatih untuk mengidentifikasi pola dan hubungan antara fitur-fitur yang ada dengan kelas yang ditentukan. Setelah model selesai dilatih, tahap pengujian dilakukan untuk menilai seberapa baik model tersebut dalam mengklasifikasikan data baru yang belum pernah dilihat sebelumnya (Hidayat *et al.*, 2024).

Klasifikasi memiliki berbagai penerapan di berbagai bidang, seperti pengolahan bahasa alami, pengenalan citra, dan diagnosis medis. Sebagai contoh, dalam pengenalan citra, klasifikasi digunakan untuk mengidentifikasi objek dalam gambar, seperti membedakan antara ikan segar dan tidak segar. Di dunia bisnis, klasifikasi juga dapat diterapkan untuk segmentasi pelanggan, di mana pelanggan

dikelompokkan berdasarkan perilaku atau preferensi mereka. Dengan demikian, klasifikasi menjadi alat yang sangat penting untuk memahami dan menganalisis data dalam berbagai konteks.

2.4 Naïve Bayes

Menurut (Muchtar *et al.*, 2024) Naive Bayes Classifier merupakan salah satu teknik klasifikasi yang berlandaskan pada prinsip Teorema Bayes. Metode ini disebut "naive" karena menganggap adanya asumsi independensi yang sangat kuat antar fitur, yaitu setiap fitur pada data dianggap tidak saling bergantung satu sama lain, meskipun dalam kenyataannya asumsi tersebut tidak selalu terpenuhi.

Naive Bayes melakukan prediksi terhadap kelas kesegaran dengan mengandalkan nilai probabilitas yang berasal dari ciri-ciri mata dan insang, berdasarkan informasi yang diperoleh dari data. Pendekatan ini sangat bermanfaat karena algoritma ini tetap bekerja secara efisien meskipun menggunakan jumlah data yang terbatas, serta mampu menyesuaikan diri dengan baik jika terjadi perubahan pada data pelatihan (Yulianto, Hana and Prihandono, 2025).

Selain itu, algoritma Naive Bayes dikenal karena kesederhanaannya serta kecepatan dalam melakukan proses klasifikasi. Berdasarkan hasil pengujian awal, metode ini mampu memberikan tingkat akurasi yang tinggi dalam mengidentifikasi tingkat kesegaran ikan jika dibandingkan dengan algoritma lain seperti kNN atau C4.5. Temuan ini menjadikan Naive Bayes sebagai pilihan yang tepat untuk diterapkan dalam sektor makanan atau perikanan, di mana diperlukan evaluasi kualitas produk secara cepat dan akurat.

Metode Naïve Bayes dipilih karena memiliki kemampuan yang cepat dan akurat dalam melakukan proses klasifikasi. Salah satu keunggulan dari metode ini adalah kemampuannya untuk bekerja dengan jumlah data latih yang relatif sedikit, serta tetap efektif meskipun terdapat banyak fitur. Selain itu, metode ini tergolong fleksibel karena apabila terdapat kesalahan pada data pelatihan dan perlu dilakukan perbaikan, perubahan yang dibutuhkan tidak terlalu besar (Sandi, Syauqy and Maulana, 2020).

2.4.1 Konsep Naïve Bayes

Naive Bayes merupakan kelompok algoritma klasifikasi yang berlandaskan pada Teorema Bayes, dengan asumsi bahwa setiap fitur dalam model tidak saling bergantung. Algoritma ini banyak digunakan dalam berbagai bidang, terutama dalam pengolahan bahasa alami serta klasifikasi dokumen teks. Walaupun dalam praktiknya asumsi independensi antar fitur sering kali tidak terpenuhi, metode Naive Bayes tetap mampu memberikan hasil yang sangat memuaskan, khususnya ketika digunakan pada dataset berukuran besar.

Teorema Bayes menyediakan pendekatan untuk menghitung kemungkinan suatu hipotesis dengan mempertimbangkan informasi baru yang tersedia. Dalam konteks klasifikasi, hipotesis ini merujuk pada kelas atau kategori yang ingin diprediksi. Metode Naïve Bayes menghitung probabilitas posterior untuk setiap kelas dengan menggabungkan probabilitas prior dari kelas tersebut dan probabilitas likelihood dari fitur yang diamati. Melalui penerapan rumus Bayes, kita dapat menentukan kelas yang paling mungkin sesuai dengan data yang ada.

Salah satu kelebihan utama dari algoritma Naïve Bayes adalah kemampuannya dalam bekerja dengan cepat dan efisien. Algoritma ini dapat diterapkan secara sederhana dan tidak memerlukan banyak sumber daya komputasi. Hal tersebut menjadikannya sebagai alternatif yang tepat untuk digunakan dalam aplikasi berskala besar atau ketika dibutuhkan waktu pemrosesan yang singkat. Selain itu, Naïve Bayes juga memiliki interpretasi yang mudah dipahami, sehingga sering dijadikan acuan awal atau baseline dalam berbagai studi klasifikasi.

Meskipun Naïve Bayes memiliki berbagai kelebihan, algoritma ini juga memiliki sejumlah keterbatasan. Asumsi bahwa setiap fitur saling bebas atau independen sering kali tidak sesuai dengan kondisi nyata. Jika terdapat keterkaitan antar fitur dalam data, maka performa dari Naïve Bayes dapat mengalami penurunan. Oleh karena itu, sangat penting untuk memperhatikan konteks serta karakteristik dari dataset yang digunakan sebelum memutuskan untuk menerapkan Naïve Bayes sebagai metode klasifikasi.

$$P(A|B) = \frac{P(B|A) \times P(A)}{P(B)}$$

dimana $P(A|B)$ adalah probabilitas bahwa suatu data B termasuk dalam kelas A. $P(B|A)$ merupakan probabilitas likelihood bahwa data B akan muncul jika kelasnya adalah A. $P(A)$ adalah probabilitas prior dari kelas A. Sedangkan $P(B)$ adalah probabilitas marginal dari data B

2.4.2 Arsitektur Naïve Bayes

Struktur dari algoritma Naïve Bayes merupakan metode klasifikasi berbasis probabilistik dalam bidang pembelajaran mesin. Pendekatan ini mengandalkan Teorema Bayes untuk menghitung probabilitas posterior dari sebuah kelas dengan mempertimbangkan informasi dari fitur yang tersedia, serta menggunakan asumsi adanya independensi bersyarat antara fitur-fitur tersebut. Walaupun dalam praktiknya asumsi tersebut tidak selalu berlaku, Naïve Bayes tetap menjadi solusi yang sederhana dan efisien untuk digunakan dalam berbagai jenis permasalahan klasifikasi.

Salah satu ciri khas dari metode Naive Bayes adalah adanya asumsi independensi bersyarat antar fitur. Dalam hal ini, algoritma menganggap bahwa keberadaan suatu fitur tidak dipengaruhi oleh keberadaan fitur lainnya. Walaupun dalam praktiknya asumsi tersebut kerap tidak sepenuhnya sesuai dengan kondisi nyata, metode Naive Bayes tetap mampu memberikan performa yang baik pada banyak situasi. Keunggulan ini berasal dari kemampuannya dalam melakukan generalisasi serta menangani kerumitan data secara efisien, sehingga metode ini menjadi salah satu yang sering dipilih oleh para praktisi dalam bidang machine learning.

Naive Bayes memiliki beberapa varian yang dirancang untuk disesuaikan dengan jenis data yang digunakan. Sebagai contoh, Gaussian Naive Bayes cocok untuk data kontinu yang mengikuti distribusi normal, sementara Multinomial Naive Bayes lebih tepat digunakan untuk data diskrit, seperti klasifikasi teks berdasarkan frekuensi kata. Sementara itu, Bernoulli Naive Bayes lebih cocok untuk data biner,

di mana fitur dinyatakan dalam bentuk keberadaan atau ketidakberadaan. Dengan adanya berbagai varian ini, Naive Bayes dapat diterapkan pada beragam masalah klasifikasi.

Keunggulan utama dari metode Naive Bayes adalah kesederhanaan dan kecepatan dalam pelatihan serta prediksi. Model ini sangat efisien secara komputasi, sehingga cocok untuk diterapkan pada dataset besar dan kompleks. Selain itu, Naive Bayes juga dapat menangani data yang hilang dengan efektif, menjadikannya pilihan yang andal dalam berbagai aplikasi. Meskipun terdapat beberapa keterbatasan, seperti asumsi independensi antar fitur yang bisa menurunkan akurasi pada beberapa kondisi, model ini tetap banyak digunakan karena kelebihan yang signifikan.

2.4.3 Teorema Bayes

Teorema Bayes merupakan dasar utama dalam teori peluang yang digunakan untuk menghitung kemungkinan suatu peristiwa berdasarkan informasi yang telah diketahui. Diperkenalkan oleh Thomas Bayes, konsep ini menyediakan pendekatan terstruktur untuk memperbarui keyakinan terhadap suatu hipotesis ketika data baru diperoleh. Dalam penggunaannya, teorema Bayes mengaitkan antara probabilitas awal (prior), kemungkinan kemunculan data (likelihood), dan probabilitas akhir (posterior), sehingga memudahkan dalam melakukan estimasi ulang seiring bertambahnya informasi.

Secara matematis, Teorema Bayes dinyatakan sebagai berikut:

$$P(C|X) = \frac{P(X|C) \cdot P(C)}{P(X)}$$

di mana:

$P(C|X)$ adalah probabilitas posterior dari kelas C. diberikan fitur X.

$P(X|C)$ adalah probabilitas likelihood fitur X diberikan kelas C.

$P(C)$ adalah probabilitas prior dari kelas C.

$P(X)$ adalah probabilitas total dari fitur X.

Salah satu peran penting dari Teorema Bayes terdapat pada bidang machine learning, khususnya dalam proses klasifikasi dan inferensi statistik. Dalam penerapan klasifikasi, algoritma seperti Naive Bayes memanfaatkan prinsip ini untuk menentukan kemungkinan suatu kelas berdasarkan fitur yang tersedia. Dengan mengandalkan asumsi bahwa antar fitur bersifat independen, pendekatan ini mampu menghasilkan prediksi yang cepat dan efisien. Oleh karena itu, Teorema Bayes menjadi salah satu instrumen yang sangat berguna dalam pengolahan data dan pengambilan keputusan yang didasarkan pada probabilitas.

2.4.4 Asumsi Independen

Asumsi ini mengartikan bahwa setiap fitur dalam dataset dianggap tidak saling bergantung satu sama lain jika telah diketahui kelasnya. Walaupun asumsi tersebut sering kali tidak sepenuhnya akurat dalam praktik, metode Naive Bayes tetap mampu memberikan performa yang baik di berbagai situasi.

$$P(A \cap B) = P(A) \cdot P(B)$$

Dengan kata lain, peluang terjadinya dua kejadian secara bersamaan dapat diperoleh dari hasil kali probabilitas masing-masing kejadian. Asumsi mengenai independensi ini kerap diterapkan dalam berbagai analisis statistik, termasuk saat merancang model-model yang lebih kompleks.

Pada berbagai penerapan machine learning, seperti pada metode Naive Bayes, asumsi independensi memiliki peranan penting dalam mempermudah proses perhitungan probabilitas. Dengan menganggap bahwa setiap fitur dalam data tidak saling bergantung, model dapat menghitung nilai likelihood masing-masing fitur secara terpisah tanpa harus memperhitungkan hubungan antar fitur. Walaupun asumsi ini sering tidak sepenuhnya sesuai dengan kenyataan, kesederhanaan yang ditawarkannya membuat model tetap dapat bekerja secara efektif dalam berbagai kondisi.

Meski demikian, asumsi independensi juga memiliki sejumlah kelemahan. Pada praktiknya, banyak fitur dalam sebuah dataset yang saling berkaitan dan memengaruhi satu sama lain. Jika asumsi ini tidak terpenuhi, model yang dibangun dapat memberikan hasil prediksi yang kurang tepat. Oleh karena itu, sangat penting untuk melakukan evaluasi data secara menyeluruh dan memahami keterkaitan antar fitur sebelum menggunakan asumsi independen dalam proses pengembangan model.

Walaupun memiliki keterbatasan, asumsi independensi tetap menjadi pendekatan yang bermanfaat dalam berbagai bidang. Sebagai contoh, dalam pemrosesan bahasa alami, pendekatan ini diterapkan untuk mengelompokkan teks

berdasarkan seberapa sering suatu kata muncul, tanpa memperhatikan susunan atau keterkaitan antar kata. Meskipun model yang dihasilkan mungkin tidak sepenuhnya akurat, pendekatan ini tetap mampu memberikan pemahaman yang berguna serta menjadi solusi praktis dalam menangani permasalahan klasifikasi yang kompleks.

2.5 Convolutional Neural Network (CNN)

Menurut (Pujiarini, 2023) Convolutional Neural Network (CNN) merupakan salah satu pendekatan deep learning yang sering diterapkan dalam analisis citra dan telah terbukti handal dalam melakukan klasifikasi tingkat kesegaran ikan. CNN beroperasi dengan mengenali pola-pola tertentu dalam gambar, yang memungkinkan sistem untuk membedakan fitur visual spesifik pada ikan yang masih segar dengan ikan yang sudah tidak segar.

Convolutional Neural Network (CNN) merupakan bentuk lanjutan dari Multilayer Perceptron (MLP) yang dirancang secara khusus untuk memproses data dalam format dua dimensi. CNN dikategorikan sebagai salah satu jenis Deep Neural Network karena memiliki struktur jaringan yang dalam, serta sering digunakan dalam pengolahan data citra.

Convolutional Neural Network (CNN) merupakan salah satu jenis jaringan saraf tiruan yang sering digunakan dalam pengolahan citra. CNN terdiri dari neuron-neuron yang memiliki bobot, bias, dan fungsi aktivasi. Dalam CNN, terdapat dua bagian utama, yaitu layer untuk ekstraksi fitur dan layer yang terhubung sepenuhnya. Proses pengolahan citra menggunakan CNN melibatkan


empat jenis lapisan, yaitu Convolution Layer, Pooling Layer, Dropout Layer, dan Fully Connected Layer (Luthfirana, Nafi and Hidayatullah, 2024).

Dasar ide dari algoritma Convolutional Neural Network (CNN) adalah meniru cara kerja struktur algoritma neural network yang melakukan pembelajaran melalui beberapa lapisan. Oleh karena itu, kemampuan CNN untuk mempelajari data secara mendalam sangat cocok diterapkan dalam algoritma neural network. Meskipun demikian, secara struktural, CNN memiliki perbedaan signifikan dengan algoritma neural network tradisional. Neural network hanya digunakan pada bagian klasifikasinya, sementara untuk proses pembelajaran fitur, algoritma ini memanfaatkan teori konvolusi dalam melakukan ekstraksi fitur.

Dalam klasifikasi kesegaran ikan, CNN diterapkan untuk mengenali ciri-ciri fisik tertentu seperti warna mata, tekstur kulit, dan tingkat kecerahan tubuh ikan, yang cenderung berubah seiring dengan penurunan kesegaran ikan. Proses ini melibatkan pelatihan CNN menggunakan gambar ikan segar dan tidak segar, sehingga model dapat belajar untuk membedakan keduanya. Setelah proses pelatihan selesai, model dapat memprediksi kondisi kesegaran ikan berdasarkan pola yang telah dipelajari dari gambar yang belum pernah dilihat sebelumnya, dan menghasilkan klasifikasi apakah ikan tersebut segar atau tidak segar.

2.5.1 Konsep CNN


Cara kerja CNN mirip dengan MLP, tetapi dalam CNN setiap neuron direpresentasikan dalam bentuk dua dimensi, berbeda dengan MLP yang hanya memiliki ukuran satu dimensi untuk setiap neuronnya.



Gambar 2.1 Arsitektur MLP Sederhana

Sebuah MLP, seperti yang ditunjukkan pada Gambar 2.1, memiliki lapisan i (kotak merah dan biru) yang masing-masing berisi j_i neuron (lingkaran putih). MLP menerima data input satu dimensi dan mengalirkannya melalui jaringan untuk menghasilkan output. Setiap hubungan antar neuron pada dua lapisan berturut-turut memiliki parameter bobot satu dimensi yang mempengaruhi kualitas hasil. Setiap input pada lapisan akan menjalani operasi linier dengan bobot yang ada, lalu hasilnya akan diproses lebih lanjut menggunakan fungsi aktivasi yang bersifat non-linier.

Data yang diproses dalam CNN adalah data dua dimensi, sehingga operasi linier dan parameter bobot pada CNN berbeda. Pada CNN, operasi linier dilakukan dengan menggunakan konvolusi, di mana bobot yang digunakan tidak lagi berbentuk satu dimensi, melainkan berupa empat dimensi yang terdiri dari kumpulan kernel konvolusi, seperti yang ditunjukkan pada Gambar 2.2. Dimensi bobot pada CNN adalah:



Gambar 2.2 Proses Konvolusi pada CNN

CNN terdiri dari beberapa layer, terdapat empat layer utama pada sebuah CNN namun yang diterapkan pada penelitian ini hanya tiga macam lapisan antara lain:

2.5.2 Arsitektur Jaringan CNN

Arsitektur Convolutional Neural Network (CNN) adalah jenis model deep learning yang dirancang khusus untuk memproses data dalam bentuk grid, seperti gambar. CNN terdiri dari beberapa lapisan yang terhubung, di antaranya lapisan konvolusi, lapisan aktivasi, lapisan pooling, dan lapisan fully connected. Lapisan konvolusi berfungsi untuk mengekstraksi fitur dari input menggunakan filter yang bergerak di atas gambar, sementara lapisan pooling bertujuan untuk mengurangi dimensi peta fitur, mempertahankan fitur yang penting, dan mengurangi

kemungkinan terjadinya overfitting. Dengan desain seperti ini, CNN dapat mengidentifikasi pola-pola kompleks dalam data visual, menjadikannya sangat efektif dalam tugas-tugas seperti pengenalan wajah, deteksi objek, dan klasifikasi gambar.

Salah satu keunggulan utama dari arsitektur CNN adalah kemampuannya dalam mempelajari hierarki fitur secara otomatis. Pada lapisan pertama, CNN dapat mengenali fitur-fitur dasar seperti garis dan tekstur, sementara lapisan yang lebih dalam dapat menggabungkan fitur-fitur ini untuk mengenali objek yang lebih kompleks. Pelatihan CNN dilakukan menggunakan algoritma backpropagation, di mana perbedaan antara output dan nilai yang sebenarnya digunakan untuk memperbarui bobot di seluruh jaringan. Dengan metode ini, CNN telah menjadi standar di banyak aplikasi visi komputer dan berhasil mengimplementasikan teknik-teknik baru yang meningkatkan akurasi serta efisiensi dalam pengolahan citra.

CNN terdiri dari beberapa layer, terdapat empat layer utama pada sebuah CNN namun yang diterapkan pada penelitian ini hanya tiga macam lapisan antara lain:


a. Convolution Layer

Lapisan konvolusi melakukan operasi konvolusi pada output yang dihasilkan oleh lapisan sebelumnya. Proses ini merupakan tahap inti yang mendasari jaringan saraf konvolusional (CNN). Konvolusi itu sendiri adalah istilah matematis yang merujuk pada penerapan suatu fungsi terhadap hasil dari fungsi lainnya secara berulang.

Dalam pengolahan citra, konvolusi mengacu pada penerapan kernel (kotak berwarna kuning) ke gambar pada berbagai posisi atau pergeseran tertentu. Proses ini memungkinkan terjadinya operasi yang serupa dengan yang ditunjukkan dalam Gambar 2.3. Gambar yang akan dikonvolusi diwakili secara keseluruhan oleh kotak hijau, sementara kernel bergerak dari satu posisi ke posisi lainnya dalam gambar tersebut.

Kernel bergerak mulai dari sudut kiri atas dan melanjutkan ke arah kanan bawah. Oleh karena itu, hasil dari proses konvolusi pada citra tersebut dapat dilihat pada gambar yang terletak di sebelah kanan.

Proses konvolusi pada citra bertujuan untuk mengidentifikasi dan mengekstrak fitur-fitur penting dari gambar input. Transformasi linier yang dihasilkan bergantung pada informasi spasial yang ada dalam data. Bobot pada lapisan konvolusi menentukan konfigurasi kernel yang digunakan, dan kernel tersebut dapat disesuaikan serta dilatih dengan menggunakan data input dalam jaringan CNN.




Gambar 2.3 Lapisan Operasi Konvolusi

b. Subsampling Layer

Subsampling adalah teknik yang digunakan untuk mengurangi ukuran data citra. Dalam pengolahan citra, metode ini juga berfungsi untuk meningkatkan ketahanan terhadap perubahan posisi fitur. Banyak jaringan CNN yang menggunakan teknik subsampling yang dikenal dengan sebutan max pooling.

Max pooling berfungsi dengan membagi hasil dari lapisan konvolusi menjadi beberapa grid kecil, kemudian memilih nilai maksimum dari setiap grid untuk menghasilkan matriks citra yang lebih kecil. Hal ini dapat dilihat pada Gambar 2.4, di mana grid yang berwarna merah, hijau, kuning, dan biru mewakili kelompok grid yang dipilih berdasarkan nilai maksimum. Hasil dari proses ini terlihat pada kumpulan grid di sisi kanan. Teknik ini memastikan bahwa fitur yang diperoleh tetap konsisten meskipun objek dalam citra mengalami pergeseran.



Gambar 2.4 Operasi Max Pooling

c. Fully Connected Layer

Layer ini biasanya diterapkan dalam implementasi Multi-Layer Perceptron (MLP) dan berfungsi untuk mengubah dimensi data sehingga data dapat diklasifikasikan secara linier. Setiap neuron pada lapisan konvolusi harus diubah menjadi data satu dimensi sebelum dimasukkan ke dalam lapisan fully connected.

Proses ini mengakibatkan hilangnya informasi spasial dari data, yang tidak bisa dikembalikan ke bentuk semula, sehingga lapisan fully connected hanya bisa diterapkan di bagian akhir jaringan.