

BAB II

TINJAUAN PUSTAKA

2.1 Tinjauan Pustaka

Penelitian ini akan memanfaatkan *Convolutional Neural Network* pada klasifikasi citra pisang Cavendish untuk mengklasifikasikan kematangan dan kualitasnya. Beberapa penelitian sebelumnya menggunakan metode dan dataset yang berbeda dan telah menghasilkan hasil yang positif. Berikut adalah beberapa penelitian terdahulu yang terkait dengan penelitian yang akan dilakukan oleh peneliti.

Penelitian sebelumnya mengklasifikasikan penyakit tanaman jagung menggunakan *Convolutional Neural Network* (CNN) untuk membedakan berbagai penyakit yang dapat menyerang tanaman jagung, hasilnya model dilatih selama 100 *epoch* akurasi mencapai 97,5%, validasi akurasi mencapai 100%, *loss* 0,0004 dan *loss* validasi 0,0001. Dataset yang digunakan sebanyak 2000 gambar, untuk pelatihan sebesar 1600 gambar dan 400 data untuk validasi, dataset terdiri dari dua jenis penyakit tanaman jagung, yaitu hawar daun dan karat daun [10].

Penelitian lainnya mengklasifikasikan penyakit tanaman padi menggunakan *Convolutional Neural Network* (CNN) untuk mendeteksi penyakit pada daun padi guna mengatasi serta mengobati penyakit, dengan harapan mengurangi kemungkinan terjadinya gagal panen, hasilnya model dilatih selama 100 *epoch* akurasi mencapai 100%, akurasi validasi mencapai 98,26%, *loss* sebesar 0.0525. Dataset yang digunakan mencakup 1440 data dengan pembagian 864 untuk pelatihan, 288 untuk validasi, dan 288 untuk pengujian, yang terbagi menjadi empat kelas, yakni blast, blight dan tungro [11].

Berikutnya penelitian mengklasifikasikan genus tanaman anggrek menggunakan *Convolutional Neural Network* (CNN) dengan tujuan mengetahui genus anggrek yang akan di budidayakan terlebih dahulu, karena setiap genus anggrek memiliki metode budidaya yang berbeda, hasilnya model dilatih selama 10 *epoch* akurasi mencapai 95,09%, akurasi validasi mencapai 99,50%, *loss* sebesar 0.1428 dan *loss* validasi sebesar 0,0158. Dataset yang digunakan mencakup

6685 data dengan pembagian 4000 untuk pelatihan, 2500 untuk validasi, dan 185 untuk pengujian yang berasal dari internet, yang terbagi menjadi lima kelas, yakni Cattleya, Dendrobium, Oncidium, Phalaenopsis dan Vanda [12].

Terdapat penelitian sebelumnya mengklasifikasikan pisang cavendish menggunakan model *Convolutional Neural Network* (CNN) VGG-19 untuk menentukan tingkat kematangan pisang berdasarkan warna dan ukurannya secara akurat agar mencegah kesalahan dalam pemilahan pisang, hasilnya model dilatih selama 32, 64, 96 *epoch* akurasi mencapai 97% dan *loss* mencapai 0.069. Dataset yang digunakan 80:10:10 dalam arti secara berurut yaitu pelatihan, validasi, pengujian sejumlah 9000 citra, mencakup tiga macam tingkatan kematangan antara lain, mentah, pra panen, dan matang masing-masing 3000 gambar[13].

Terakhir, penelitian sebelumnya mengklasifikasikan kualitas pisang menggunakan CNN dengan arsitektur MobileNetV2 untuk membantu pekerja mengotomatisasi dalam mengklasifikasi buah pisang berdasarkan kualitas sesuai dengan standar NTC 1190, hasilnya model dilatih selama 17 *epoch* akurasi mencapai 87%, *loss* sebesar 0,4%, spesifisitas 93,3%, presisi 87% dan *f1-score* 86,3%. Dataset terdiri dari 1164 foto, dengan 80% untuk pelatihan dan 20% untuk validasi. Dataset mencakup dua jenis kualitas pisang, yaitu *fresh* dan *roten*[14].

Tabel 2.1 Penelitian terdahulu

No	Judul	Penulis	Tahun	Masalah	Algoritma	Hasil
1	Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode Convolutional Neural Network (CNN)	Didit Iswanto dan Dewi Handayani UN	2022	Tanaman jagung di Indonesia sebagai salah satu tanaman pangan utama setelah padi, jagung memiliki peranan penting dalam ketahanan pangan dengan hasil yang tinggi dan berbagai kegunaan. Meski demikian, para petani masih menghadapi kesulitan dalam membedakan berbagai penyakit yang dapat menyerang tanaman jagung	CNN	Hasil penelitian menunjukkan bahwa mencapai tingkat akurasi <i>training</i> sebesar 97,5%, validasi akurasi mencapai 100%, <i>loss</i> 0,0004 dan <i>loss</i> validasi 0,0001.
2	Optimasi Hyperparameter Convolutional Neural Network Untuk Klasifikasi Penyakit Tanaman Padi	Afis Julianto, Andi Sunyoto, Ferry Wahyu Wibowo	2022	Tanaman padi menjadi tanaman utama di Indonesia karena beras adalah makanan pokok di sini. Salah satu alasan utama penurunan produksi padi adalah serangan penyakit yang merusak tanaman. Penyakit pada tanaman padi dapat mengurangi hasil panen secara signifikan, bahkan menyebabkan gagal panen dan kerugian besar bagi petani.	CNN	Hasil penelitian menunjukkan bahwa dengan 100 <i>epoch</i> di dapatkan akurasi sebesar 100%, akurasi validasi mencapai 98,26%, <i>loss</i> sebesar 0.0525.
3	Klasifikasi Genus Tanaman Anggrek Menggunakan Metode Convolutional Neural Network (CNN)	M. Raihan Rafiiful Allaam, dan Agung Toto Wibow	2021	Setiap genus anggrek membutuhkan metode budidaya yang berbeda, sehingga pemula perlu mengetahui genus anggrek yang akan dibudidayakan untuk mendapatkan informasi yang tepat. Namun, banyak pemula gagal karena kurangnya pengetahuan dan akses terbatas ke ahlinya. Penelitian ini bertujuan membangun sistem untuk mengklasifikasi citra genus anggrek.	CNN	Hasil penelitian yang dilakukan dengan 10 <i>epoch</i> dari penelitian ini mencapai akurasi sebesar 95,09%, akurasi validasi mencapai 99,50%, <i>loss</i> sebesar 0.1428 dan <i>loss</i> validasi sebesar 0,0158

No	Judul	Penulis	Tahun	Masalah	Algoritma	Hasil
4	Klasifikasi Tingkat Kematangan Buah Pisang Cavendish Menggunakan Algoritma <i>Convolutional Neural Network Model Vgg-19</i>	Aditya Dwi Putro Wicaksono dan Arif Amrulloh	2023	Kesalahan penentuan kematangan pisang dapat disebabkan oleh kurangnya tingkat ketelitian dan pemahaman yang mumpuni dari pihak produsen atau petani. Salah satu solusinya adalah dengan berupa pengembangan aplikasi, sistem, atau perangkat otomatis yang mampu menentukan tingkat kematangan pisang secara akurat berdasarkan warna dan ukurannya.	CNN (Model VGG-19)	Hasil penelitian ini menunjukkan akurasi mencapai 97% dan <i>loss</i> mencapai 0.069
5	<i>Automatic Identification of banana quality with Deep Neural Network Classification (DNN)</i>	Deyner Julian Navarro Ortiz, Silvia Alejandra Martínez López	2022	Industrialisasi pertanian secara bertahap terjadi di Kolombia karena kebutuhan untuk mengoptimalkan waktu dan upaya yang diperlukan dalam proses mulai dari menanam buah dan sayuran hingga distribusi dan komersialisasi mereka, baik untuk ekspor maupun untuk komersialisasi di dalam negeri. Klasifikasi buah adalah proses yang sangat penting sebelum mereka dijadikan produk akhir, Tujuan dari penelitian ini adalah untuk mengembangkan prototipe yang dapat mengurangi waktu pemilihan dan klasifikasi pisang berdasarkan kualitas sesuai standar NTC 1190.	CNN (Model MobileNet V2)	Hasil penelitian yang dilakukan dengan 17 <i>epoch</i> dari penelitian ini mencapai akurasi sebesar 87%, <i>loss</i> sebesar 0,4%.

2.2 Landasan Teori

Berikut ini adalah teori-teori yang mendukung penelitian klasifikasi kualitas dan kematangan pisang Cavendish yang akan dilaksanakan.

2.2.1 *Pisang cavendish*

Pisang adalah buah tropis yang sangat terkenal di seluruh dunia. Buah ini termasuk dalam komoditas hortikultura dan berasal dari wilayah Asia Tenggara dan Pasifik Barat, termasuk Indonesia. Salah satu varietas pisang yang sangat populer adalah pisang Cavendish. Buah pisang Cavendish memiliki karakteristik yang menarik, dengan kulit berwarna kuning cerah, daging buah berwarna putih hingga kekuningan, tekstur yang pulen, rasa manis, dan serat buah yang halus. Pisang Cavendish juga kaya akan nutrisi, termasuk riboflavin, mangan, vitamin A, vitamin B3 (niacin), vitamin B6, vitamin C, serat, protein, besi, kalium, folat, dan magnesium[15]. Warna buah pisang juga memiliki dampak pada nilai gizinya. Buah pisang dengan kulit hijau memiliki manfaat dalam mengontrol kadar gula darah. Buah dengan kulit kuning muda baik untuk diet, sedangkan buah dengan kulit kuning mengandung antioksidan tinggi dan baik untuk pencernaan. Buah pisang dengan kulit kuning yang memiliki bintik-bintik coklat dapat membantu sistem kekebalan tubuh dan mencegah kanker. Namun, buah pisang dengan kulit kuning yang sudah coklat umumnya memiliki dampak pada peningkatan kadar gula darah dan kemampuan melawan peradangan[16].

Ada beberapa cara untuk menentukan waktu panen pisang, biasanya berkisar antara 80-100 hari. Salah satunya adalah dengan mengamati jumlah hari setelah jantung pisang dipotong, jumlah hari dari mekarnya bunga hingga siap panen, atau melalui pengamatan bentuk buah. Warna kulit pisang adalah penanda utama yang paling mudah diamati selama proses pematangan. Selama proses pematangan, kulit pisang mengalami perubahan warna dari hijau menjadi kuning karena terjadi penurunan kandungan klorofil dan peningkatan pigmen karotenoid serta flavonoid di dalamnya. Warna kulit pisang adalah indikator non-destruktif yang sangat umum digunakan untuk menentukan tingkat kematangan. Ada tujuh tahap pematangan pisang yang didasarkan pada perubahan warna kulitnya: tahap 1 (hijau), tahap 2 (hijau dengan sedikit warna kuning), tahap 3 (lebih dominan hijau

daripada kuning), tahap 4 (lebih kuning daripada hijau), tahap 5 (kuning dengan ujung yang masih hijau), tahap 6 (sepenuhnya kuning), dan tahap 7 (kuning dengan bintik-bintik coklat)[17].

Saat melakukan panen, tingkat kematangan buah harus diperhatikan karena hal ini mempengaruhi kualitas buah pisang. Buah yang dipanen terlalu muda mungkin sudah matang, tetapi kualitasnya tidak optimal dalam hal rasa dan aroma. Sebaliknya, buah yang dipanen terlalu tua mungkin memiliki rasa manis yang kuat dan aroma yang khas, tetapi daya simpannya lebih pendek, buah sebaiknya dipanen pada tingkat kematangan $\frac{3}{4}$ penuh. Menurut standar kriteria kualitas yang ditetapkan oleh Badan Standarisasi Nasional (BSN) Indonesia tahun 2009 nomor 7422:2009, buah pisang harus memenuhi beberapa syarat. Mereka harus utuh, memiliki tekstur yang tidak terlalu keras atau lembut, serta tampak segar dengan kulit yang bersinar dan tidak ada tanda-tanda kebusukan atau kerusakan fisik. Selain itu, buah harus memiliki bentuk yang lurus dan simetris dengan sedikit lengkungan, warna yang merata dan kuning cerah, rasa manis dengan sedikit keasaman, serta tekstur yang lembut. Kulitnya harus bebas dari bintik-bintik coklat. Selain itu, buah harus bersih, tidak terkontaminasi, bebas dari kerusakan fisik, hama, penyakit[18].



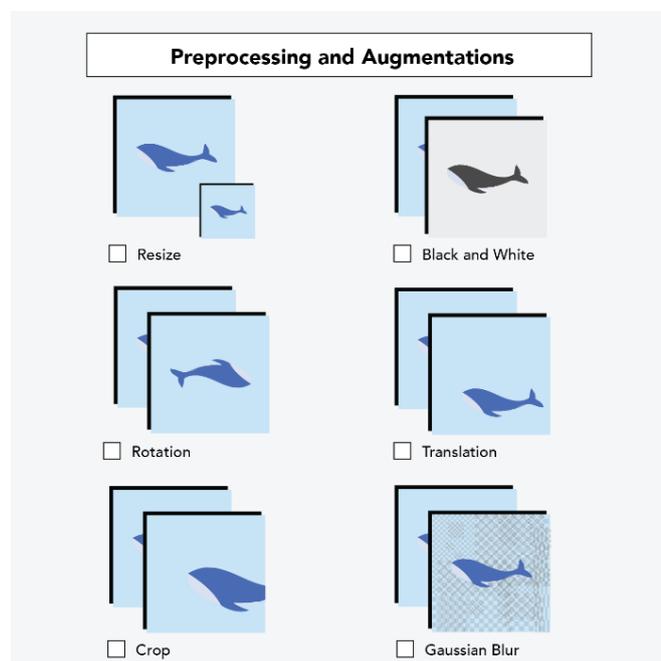
Gambar 2.1 Pisang Cavendish

Sumber: Dokumen Pribadi

2.2.2 Preprocessing

Proses *preprocessing* gambar adalah langkah yang sangat penting dalam upaya untuk mendapatkan fitur yang optimal dan meningkatkan akurasi klasifikasi.

Salah satu tahap yang sangat krusial dalam proses ini adalah melakukan penyesuaian ukuran gambar (*resizing*), yang kemudian diikuti dengan normalisasi data. Tujuan utamanya adalah untuk menghasilkan konsistensi dalam rentang nilai variabel, biasanya dalam skala antara 0 hingga 1[19]. Selanjutnya dilakukan Augmentasi data untuk menambah variasi bentuk dari gambar yang akan dilatih. Augmentasi data adalah teknik untuk memperbanyak jumlah dataset pelatihan dengan mengubah data, seperti perubahan warna, memutar, membalik, *color jitter*, dan *random erasing* data yang sudah ada tanpa mengubah labelnya, dengan tujuan untuk mengatasi masalah *overfitting* dengan asumsi bahwa informasi tambahan dapat diekstraksi dari dataset asli melalui augmentasi dan memperkaya dataset pelatihan [27]. *Preprocessing* data dilakukan untuk mengubah data ke format yang diinginkan, dan ini dapat menghasilkan dataset yang lebih besar dan bervariasi, yang pada akhirnya dapat meningkatkan kinerja model yang digunakan dalam analisis gambar[20].

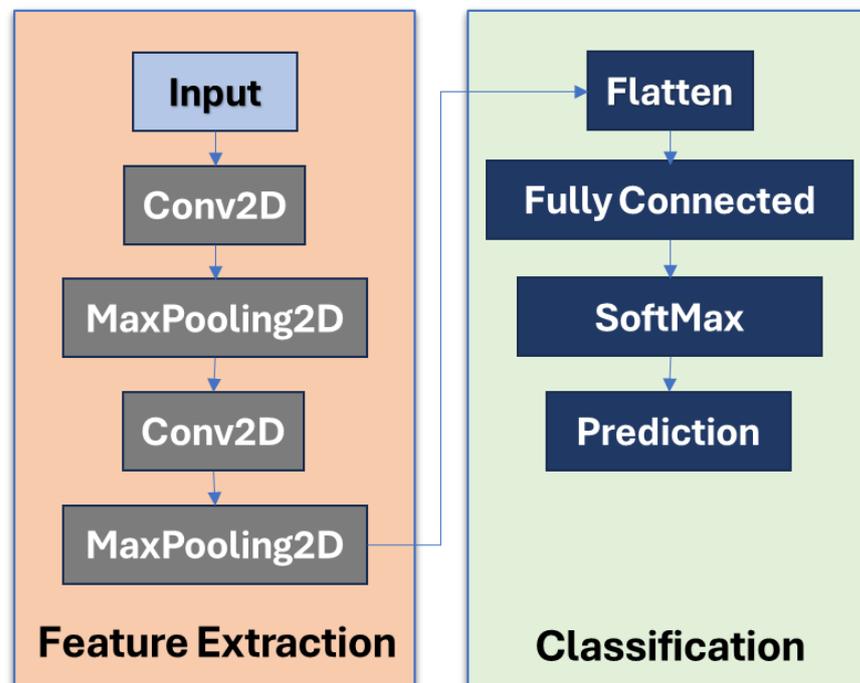


Gambar 2.2 *Preprocessing Data*

Sumber: Imam Cholissodin dkk., 2019, hal 307 [21]

2.2.3 Convolutional neural network (CNN)

Convolutional Neural Networks (CNN) adalah algoritma *deep learning* yang digunakan luas untuk mengklasifikasi dan memprediksi gambar. CNN memiliki kemampuan untuk mengekstrak fitur dari gambar secara otomatis tanpa perlu perancangan manual[22]. Arsitektur CNN terdiri dari tiga jenis *layer*: *convolutional layer*, *pooling layer*, dan *fully connected layer*. *Convolutional layer* dan *pooling layer* berperan dalam ekstraksi fitur seperti tepi, warna, bentuk, atau bagian-bagian objek, sedangkan *fully connected layer* digunakan untuk memetakan fitur hasil ekstraksi ke output klasifikasi[19].



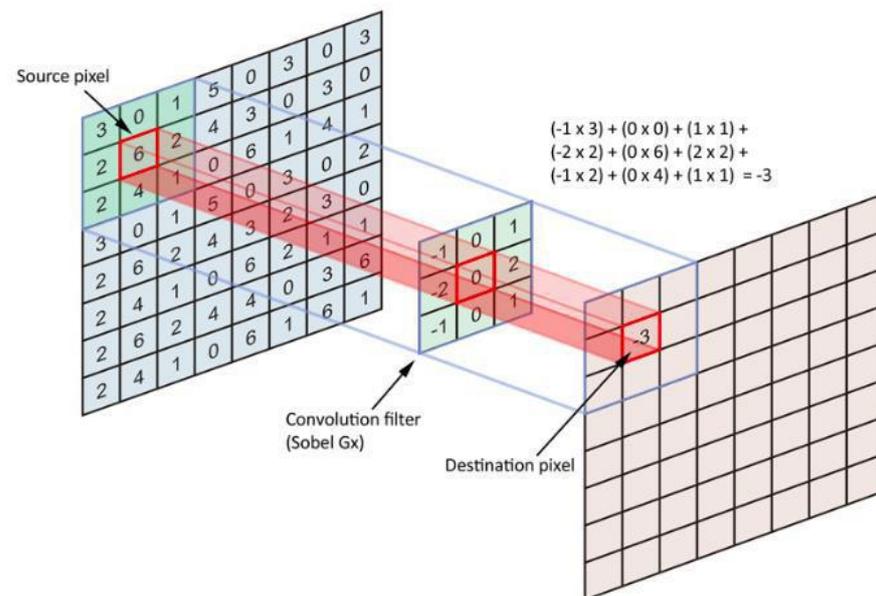
Gambar 2.3 Arsitektur CNN

Sumber: Dokumen Pribadi

1. Convolutional Layer

Convolutional Layer merupakan komponen inti dalam arsitektur *Convolutional Neural Network* (CNN), yang terdiri dari sekelompok filter atau kernel yang dapat belajar. Setiap kernel memiliki dimensi panjang dan lebar, umumnya dalam bentuk 3x3, 5x5, atau 7x7. Dimensi kernel juga melibatkan kedalaman volume sebagai dimensi ketiga, yang sesuai dengan jumlah saluran dalam input. Misalnya, untuk citra abu-abu

(*grayscale*), kedalaman volumenya adalah 1, sementara untuk citra warna (RGB), kedalaman volumenya adalah 3. Ukuran kernel, seperti $7 \times 7 \times 3$, menunjukkan panjang dan lebar masing-masing 7, serta kedalaman 3 sesuai dengan saluran warna. Filter dalam kernel ini bergeser secara menyeluruh di seluruh gambar. Hasilnya adalah output yang disebut *feature map* atau *activation map*[23].



Gambar 2.4 Ilustrasi *Convolutional Layer*

Sumber: L. Alzubaidi dkk., 2021, hal 16 [23]

Kotak hijau pada gambar 2.7 menunjukkan filter 3×3 yang digunakan untuk mengekstrak fitur dari citra. Kotak biru menggambarkan citra input yang akan dikenakan konvolusi, sedangkan kotak merah adalah matriks baru yang merupakan hasil dari proses konvolusi tersebut. Filter konvolusi bergerak dari kiri ke kanan, menutupi seluruh bagian matriks. Saat setiap filter melewati bagian dari matriks, fitur diekstraksi melalui proses konvolusi, di mana secara matematis hasil konvolusi diperoleh dari perkalian elemen matriks [24].

2. Fungsi Aktivasi

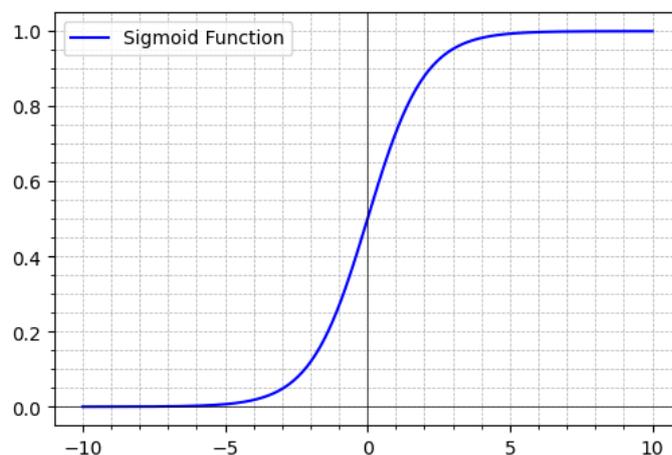
Fungsi aktivasi adalah fungsi yang menghitung jumlah dari bobot input dan bias, yang kemudian menentukan apakah neuron tersebut akan aktif atau tidak [23]. Fungsi aktivasi terbagi menjadi dua jenis: linier dan non-

linier. Setiap jenis fungsi aktivasi memiliki variasi, masing-masing dengan kelebihan dan kekurangan. Beberapa fungsi aktivasi yang umum digunakan antara lain:

a. *Sigmoid Function*

Fungsi Sigmoid adalah fungsi *non-linier* yang umumnya digunakan dalam *feed forward neural network*. Dalam arsitektur *Deep Learning*, fungsi sigmoid sering diterapkan pada *output layer* untuk memprediksi probabilitas berdasarkan output [25].

Fungsi ini menghasilkan keluaran dalam rentang $[0,1]$, mengubah nilai *input* menjadi kisaran antara 0 dan 1. Jika input sangat negatif, fungsi akan mendekati nol, dan jika input sangat positif, fungsi akan mendekati satu. Fungsi sigmoid jarang digunakan karena keluaran fungsinya tidak terpusat pada nol, yang dapat menyebabkan jenuh selama pelatihan ketika $f(x) = 0$ atau 1, sehingga gradien menjadi nol [25]. Berikut merupakan grafik fungsi sigmoid di bawah ini.



Gambar 2. 5 Grafik fungsi *Sigmoid*

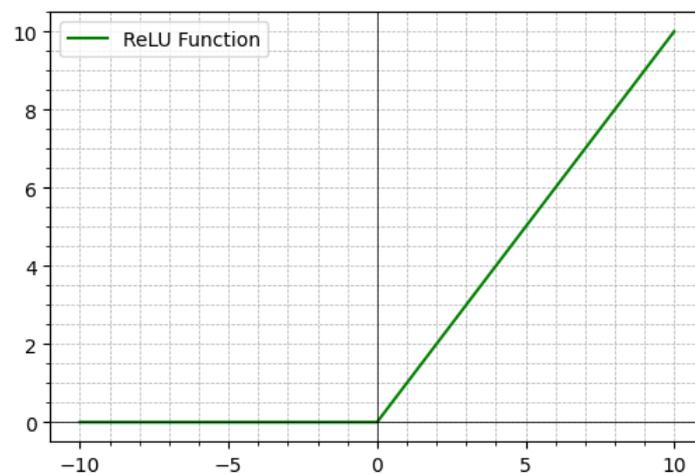
Sumber: Dokumentasi Pribadi

b. *Rectified Linear Unit (ReLU) Function*

Rectified Linear Unit (ReLU) adalah fungsi aktivasi terbaik dan tercepat dibandingkan fungsi aktivasi lainnya. Cara kerjanya adalah, jika nilai input kurang dari nol maka hasilnya adalah nol, tetapi jika

nilai input lebih dari nol maka hasilnya adalah nilai input itu sendiri [25].

Meskipun ReLU memiliki keunggulan seperti kecepatan proses dan performa yang lebih baik dibandingkan fungsi aktivasi lainnya, ReLU juga memiliki kekurangan, yaitu rentan terhadap *overfitting* dan terkadang beberapa *gradien* bisa mati atau menjadi tidak aktif. Hal ini disebabkan oleh batasan signifikan yang dimiliki oleh ReLU [25]. Berikut merupakan grafik fungsi ReLU di bawah ini.



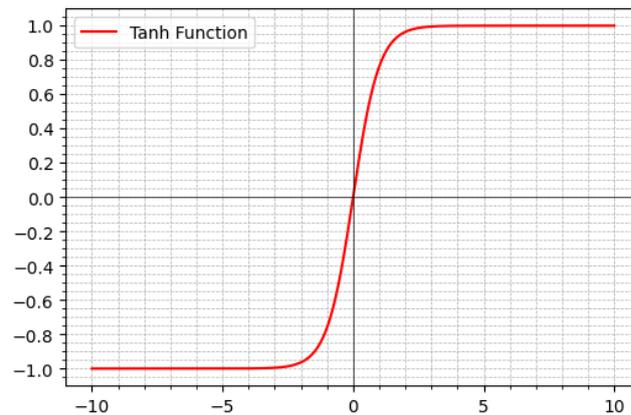
Gambar 2. 6 Grafik fungsi ReLU

Sumber: Dokumen Pribadi

c. *Hyperbolic Tangent Function* (Tanh)

Fungsi *Hyperbolic Tangent*, atau biasa dikenal sebagai Tanh, adalah fungsi aktivasi dengan titik pusat di nol dan memiliki rentang antara -1 dan 1 [25].

Fungsi Tanh memiliki performa yang baik dalam jaringan saraf *multi-layer* dan dapat meningkatkan proses *back-propagation*. Namun, fungsi ini tetap tidak mampu mengatasi masalah hilangnya gradien [25]. Berikut merupakan grafik fungsi Tanh di bawah ini.

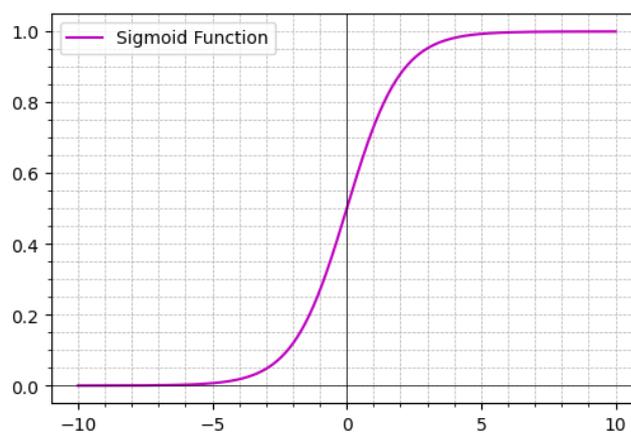


Gambar 2. 7 Grafik fungsi Tanh

Sumber: Dokumen Pribadi

d. *Softmax Function*

Softmax sering digunakan sebagai fungsi aktivasi terakhir dalam jaringan saraf. Dalam praktiknya, *Softmax* menormalkan output jaringan menjadi distribusi probabilitas di atas kelas-kelas output yang diprediksi[26]. Penggunaan *Softmax* bertujuan untuk menghitung probabilitas dari setiap kelas target (kategori) di antara semua kelas target yang memungkinkan, sehingga membantu menentukan kelas target untuk input citra yang diberikan. Kelebihan menggunakan *Softmax* adalah rentang probabilitas output yang berada antara 0 hingga 1, dengan jumlah semua probabilitas yang dihasilkan sama dengan satu[12].

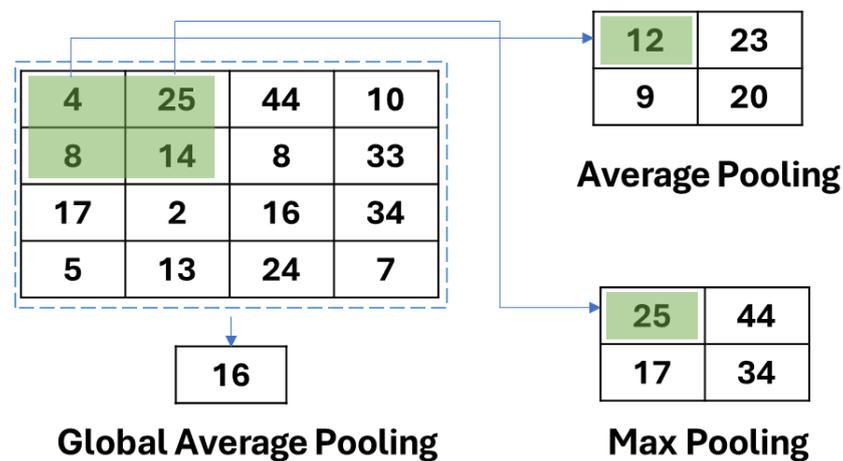


Gambar 2. 8 Grafik fungsi *Softmax*

Sumber: Dokumen Pribadi

3. Pooling Layer

Lapisan *pooling* memiliki peran penting dalam mengurangi kompleksitas *output* yang dihasilkan oleh lapisan konvolusi, sehingga menghasilkan data yang lebih kecil dan lebih mudah untuk dikelola. Pada lapisan *pooling*, input dibagi menjadi *grid*, di mana setiap *grid* berisi neuron. Operasi *pooling* kemudian diterapkan pada setiap sel di dalam *grid* tersebut. Terdapat berbagai jenis lapisan *pooling* antara lain *tree pooling*, *gated pooling*, *average pooling*, *min pooling*, *max pooling*, *global average pooling* (GAP), dan *global max pooling* [23]. Ilustrasi cara kerja *pooling layer* tersebut seperti pada gambar 2.8 di bawah.



Gambar 2.9 Cara kerja MIN, MAX dan GAP *Pooling Layer*

Sumber: Dokumen Pribadi

Berikut penjelasan macam – macam tipe *pooling layer* antara lain sebagai berikut.

a. Max Pooling

Max pooling bekerja dengan cara mengambil nilai aktivasi terbesar dari neuron dalam setiap *grid*. Dengan demikian, nilai yang paling dominan atau signifikan dalam setiap wilayah *grid* menjadi representatif dari wilayah tersebut. Hal ini membantu dalam mempertahankan fitur-fitur utama dari data, secara signifikan mengurangi dimensi data, membuatnya lebih efisien untuk diproses. Secara keseluruhan, lapisan *pooling*, berfungsi untuk mengurangi

dimensi *feature map* yang dihasilkan dari lapisan konvolusi, memungkinkan pengelolaan data yang lebih efisien tanpa kehilangan informasi yang signifikan[23].

b. *Global Average Pooling*

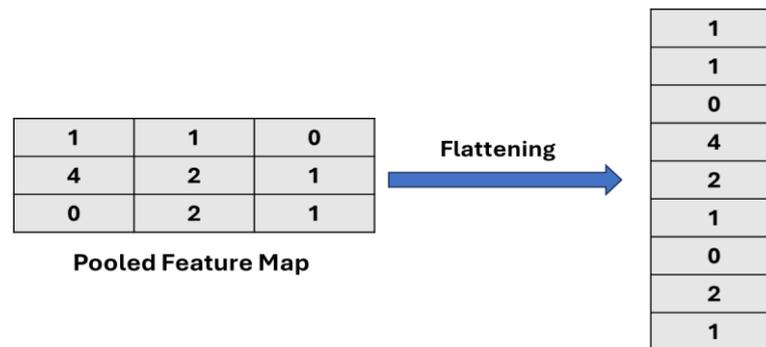
Global average pooling adalah teknik di dalam jaringan saraf konvolusional di mana nilai rata-rata dari setiap fitur di seluruh map fitur dihitung. Dengan kata lain, setiap fitur map direduksi menjadi satu nilai rata-rata tunggal. Hal ini membantu mengurangi dimensi fitur secara global sehingga memungkinkan jaringan untuk fokus pada fitur-fitur yang paling penting dari gambar secara keseluruhan, tanpa memperhatikan posisi spesifik dari fitur tersebut [27].

c. *Average Pooling*

Average pooling adalah teknik umum dalam jaringan saraf konvolusional yang membantu mengekstrak fitur dari gambar dengan mengurangi dimensi spasialnya. Ini dilakukan dengan menghitung nilai rata-rata dalam setiap jendela kecil atau wilayah dari gambar. Dengan cara ini, fitur-fitur yang tidak terlalu mencolok atau signifikan dalam wilayah tertentu dapat diabaikan. Meskipun metode ini menggunakan operasi rata-rata, tetapi tidak selalu efektif dalam menangani variasi fitur yang kompleks [27].

4. *Flatten*

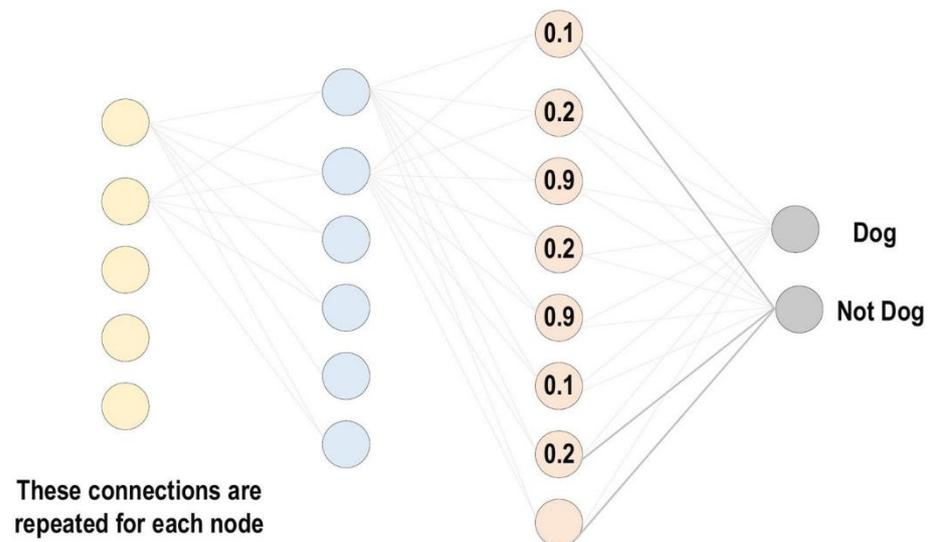
Flattening merupakan proses transformasi data *pooling* yang awalnya berbentuk *array 2D* menjadi sebuah vektor tunggal berdimensi 1D. Dalam konteks ini, *flattening* dapat dijelaskan sebagai perubahan bentuk *feature map* menjadi vektor yang kemudian dapat digunakan sebagai *input* untuk *fully connected layer*. Fungsi dari *flatten layer* adalah mengonversi citra dua dimensi ke dalam format satu dimensi, sekaligus menghilangkan beberapa bias yang dapat memperlambat proses pembelajaran (*training*)[23].

Gambar 2.10 Ilustrasi *Flattening*

Sumber: Dokumen Pribadi

5. *Fully Connected Layer*

Layer yang *Fully Connected Layer* atau *FC Layer* berperan sebagai elemen klasifikasi dalam arsitektur, dengan jumlah neuron pada lapisan ini sesuai dengan jumlah kategori kelas yang diinginkan. Pemilihan jumlah lapisan yang padat (*dense layer*) harus dilakukan dengan hati-hati, mempertimbangkan keseimbangan antara kompleksitas model dan kinerjanya[28]. *FC Layer* biasanya ditempatkan di bagian akhir arsitektur CNN, menerima input berupa vektor hasil dari lapisan *pooling* atau lapisan konvolusi terakhir, dan menghasilkan output akhir dari arsitektur CNN[23].

Gambar 2.11 Ilustrasi *Fully Connected Layer*

Sumber: L. Alzubaidi dkk., 2021, hal 19 [23]

2.2.4 Ciri Citra

Dalam pengolahan citra untuk mengidentifikasi objek, langkah pentingnya adalah ekstraksi ciri. Proses ini melibatkan mengukur ciri bentuk seperti kebulatan, kerampingan, luas, perimeter, panjang, dan lebar objek. Selain itu, ekstraksi ciri juga mencakup penilaian ciri tekstur dan warna, yang melibatkan rata-rata warna dalam model RGB dan standar deviasi dari komponen RGB objek[15], [29]. Kombinasi informasi bentuk, tekstur, dan warna ini membantu dalam identifikasi objek. Ekstraksi ciri adalah tahap kunci yang memengaruhi tingkat akurasi dalam klasifikasi citra, di mana ciri-ciri yang diekstraksi digunakan untuk membedakan karakteristik objek dalam citra[30].

Di bawah ini akan dijelaskan secara lebih detail tentang masing-masing jenis ciri tersebut:

1. Tekstur

Tekstur dalam citra digital merujuk pada pola-pola tertentu yang terbentuk oleh susunan piksel-piksel. Informasi tentang tekstur ini sangat berharga karena memungkinkan untuk membedakan karakteristik permukaan suatu objek, seperti kekasaran dan kehalusan, yang tidak hanya terkait dengan warna permukaannya. Salah satu teknik statistik yang digunakan untuk mengekstraksi informasi tekstur adalah matriks *gray level co-occurrence* (GLCM)[31].

A. *Gray level co-occurrence matrix* (GLCM)

Matriks ko-okurensi, yang sering disebut sebagai *Gray Level Co-occurrence Matrix* (GLCM), adalah alat statistik yang berguna untuk menganalisis tekstur dalam citra. GLCM adalah representasi matriks dari hubungan ketetanggaan antar intensitas piksel dalam citra, yang mencatat frekuensi kemunculan intensitas piksel dalam berbagai arah orientasi dan jarak tertentu. GLCM merupakan metode statistik yang terbagi menjadi dua kategori, yaitu metode statistik orde pertama dan metode statistik orde kedua. Sebelum melanjutkan proses *Gray Level Co-occurrence Matrix* (GLCM), langkah awalnya adalah mengonversi citra dari format RGB ke citra

Grayscale. Citra *Grayscale* adalah citra digital yang setiap pikselnya memiliki satu nilai tunggal, yang artinya nilai merah (*red*), hijau (*green*), dan biru (*blue*) pada setiap piksel sama. Nilai tunggal ini merepresentasikan tingkat intensitas warna. Warna yang terdapat dalam citra *Grayscale* terdiri dari hitam, abu-abu, dan putih. Tingkat abu-abu mencakup variasi warna abu-abu dari hitam hingga hampir putih. Citra *Grayscale* memiliki kedalaman warna 8-bit, yang berarti terdapat 256 kombinasi warna abu-abu yang berbeda [32].

a. Ekstraksi Ciri Orde Pertama

Ekstraksi ciri orde pertama adalah pendekatan untuk mengambil ciri yang bergantung pada distribusi piksel dalam histogram citra. Biasanya, ciri orde pertama digunakan untuk membedakan tekstur makrostruktur, yaitu pola lokal yang berulang secara periodik. Beberapa contoh ciri orde pertama termasuk rata-rata, varians, kemiringan (*skewness*), kurtosis, dan entropi[33].

b. Ekstraksi Ciri Orde Kedua

Salah satu cara untuk mendapatkan ciri statistik orde kedua adalah dengan menghitung probabilitas hubungan antara dua piksel yang berdekatan pada jarak dan orientasi tertentu. Pendekatan ini melibatkan pembentukan matriks ko-okurensi dari data citra, yang kemudian digunakan untuk mengekstraksi ciri sebagai fungsi dari matriks tersebut. Ciri orde kedua umumnya berguna untuk membedakan tekstur mikrostruktur, yaitu pola lokal dan perulangan yang tidak terlalu jelas. Beberapa contoh ciri orde kedua meliputi Moment Kedua Sudut, Kontras, Korelasi, Varians, Moment Kedua Berbeda Terbalik, dan Entropi[33].

2. Warna

Meskipun sistem visual manusia memiliki kemampuan untuk membedakan ratusan ribu variasi warna dan intensitas, keterbatasan terjadi pada pengenalan hanya sekitar 100 variasi warna abu-abu. Oleh

karena itu, dalam analisis citra, informasi warna masih menjadi sumber daya penting yang dapat dimanfaatkan untuk berbagai tujuan seperti identifikasi objek dan ekstraksi warna. Sebelum menggunakan model warna *Hue*, *Saturation*, dan *Value* (HSV), langkah awal yang dilakukan adalah normalisasi pada matriks warna RGB [34].

Untuk memperoleh informasi tentang variasi warna, pencahayaan, dan intensitas warna pada suatu citra, citra dalam format RGB dikonversi ke dalam model warna *Hue*, *Saturation*, *Value* (HSV, yaitu [35]:

1. *Hue* (H) menunjukkan jenis atau corak warna, merepresentasikan letak warna dalam spektrum warna dengan nilai sudut antara 0 hingga 360 derajat.
2. *Saturation* (S) menggambarkan kecerahan warna dengan mengindikasikan seberapa murni warna tersebut, biasanya dinyatakan dalam rentang 0 hingga 1 atau 0% hingga 100%. Nilai rendah menunjukkan warna yang lebih abu-abu dan nilai tinggi menunjukkan warna yang lebih murni.
3. *Value* (V) berkaitan dengan intensitas warna, mengukur seberapa terang warna tersebut atau seberapa banyak cahaya yang dipancarkan oleh warna tersebut, dengan nilai antara 0% hingga 100%.

2.2.5 *Confusion Matrix*

Confusion matrix adalah alat evaluasi yang digunakan untuk mengukur kinerja model dengan memperhitungkan *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Ini melibatkan empat parameter utama: *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN) [36]. Pada dasarnya, *confusion matrix* digunakan untuk membandingkan hasil klasifikasi model dengan hasil klasifikasi yang seharusnya. Dengan menganalisis kombinasi nilai dalam tabel *confusion matrix*, dapat dihitung berbagai matrik evaluasi model yang berbeda, seperti akurasi, presisi, *recall*, dan *f1-score*. Akurasi adalah matrik yang mengukur sejauh mana model mampu melakukan klasifikasi yang benar. Sementara itu, presisi menggambarkan tingkat akurasi dalam memprediksi kasus positif,

khususnya sejauh mana hasil *True Positive* (TP) sesuai dengan data yang sebenarnya. *Recall* mengukur kemampuan model dalam mengidentifikasi kembali informasi atau proporsi kasus positif yang sebenarnya diprediksi dengan benar. *F1-score* adalah matrik yang menggabungkan *precision* dan *recall* secara seimbang[3]. Perhitungan *Confusion Matrix* ditunjukkan pada tabel 2.2.

Tabel 2.2 Confusion Matrix

Klasifikasi		Prediksi	
		Positif	Negatif
Aktual	Positif	True Positif (TP)	True Negatif (TN)
	Negatif	False Positif (FP)	False Negatif (FN)

Dari tabel 2.2 dapat dihitung dapat diperoleh hasil *accuracy*, *precision*, *recall* dan *F1-score* menggunakan persamaan (2,1), (2,2), (2,3), dan (2,4).

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2,1)$$

$$\text{Precision} = \frac{TP}{FP+TP} \quad (2,2)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (2,3)$$

$$\text{F1-Score} = \frac{2 \times \text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \quad (2,4)$$

Keterangan:

True Positive (TP) = prediksi positif dan nilai sebenarnya positif

False Positive (FP) = prediksi positif dan nilai sebenarnya negatif

True Negative (TN) = prediksi negatif dan nilai sebenarnya negatif

False Negative (FN) = prediksi negatif dan nilai sebenarnya positif