

BAB II
LANDASAN TEORI

1.1 Penelitian Terdahulu

Tinjauan pustaka dari penelitian yang telah dilakukan akan dijadikan sumber referensi dan pendukung pada penelitian ini. Adapun daftar tinjauan pustaka dapat dilihat pada tabel 2.1.

Tabel 2. 1 Tinjauan Pustaka

Nomor Literatur	Penulis	Tahun	Judul
Literatur 1	<u>XIAO Yihan</u>	2021	<i>Radar Signal Modulation Type Recognition Based on Denoising Convolutional Neural Network</i>
Literatur 2	Anand Muni Mishra,dkk	2022	<i>A Deep Learning-Based Novel Approach for Weed Growth Estimation</i>
Literatur 3	K. Shankar, dkk	2020	<i>Hyperparameter Tuning Deep Learning for Diabetic Retinopathy Fundus Image Classification</i>

Tabel 2. 2 Tinjauan Pustaka (lanjutan)

Nomor Literatur	Penulis	Tahun	Judul
Literatur 4	Jiayao Chen a,dkk	2018	<i>Deep learning based classification of rock structure of tunnel face</i>
Literatur 5	Muhammad Islahfari Wahid, dkk	2021	Identifikasi Dan Klasifikasi Citra Penyakit Daun Tomat Menggunakan Arsitektur <i>InceptionV4</i>

1.1.1 Tinjauan Terhadap Literatur 1

(Mao, Ren and Yang, 2021) melakukan penelitian yang berjudul “*Radar Signal Modulation Type Recognition Based on Denoising Convolutional Neural Network*” yang bertujuan pada masalah pengenalan sinyal radar LPI, pada penelitian ini mengusulkan klasifikasi sinyal radar LPI dan sistem pengenalan berdasarkan jaringan saraf *convolutional denoising* dan jaringan *Inception-V4*. Sistem menggunakan transformasi waktu-frekuensi CWD untuk mengubah sinyal dalam domain waktu-frekuensi, menggunakan jaringan DnCNN untuk praproses gambar waktu-frekuensi, dan mengurangi kebisingan latar belakang gambar waktu-frekuensi sambil mempertahankan gambar waktu-frekuensi lengkap ekstraksi fitur gambar, yang memecahkan masalah kompleks dan

efisiensi rendah ekstraksi fitur manual, dan memberikan solusi baru untuk pengenalan sinyal radar LPI di bawah kondisi rasio *signal-to-noise* yang rendah

1.1.2 Tinjauan Terhadap Literatur 2

(Mishra *et al.*, 2022) melakukan penelitian dengan judul “*A Deep Learning-Based Novel Approach for Weed Growth Estimation*” Penelitian ini menyajikan teknik berbasis jaringan saraf untuk meningkatkan evaluasi gulma pertumbuhan karena pengamatan nutrisi dari tanah. Gambar dengan jenis tanah tertentu (subur, liat dan lempung) diambil dengan berbagai kamera instrumen digital dan kondisi cahaya dikumpulkan di dalam lapangan. Itu gambar disajikan dalam kondisi lapangan di mana daun gulma membusuk satu sama lain, jaringan saraf yang biasanya dapat membedakan antara mereka. Ilustrasi termasuk sesi rabi umum spesies gulma, yang meliputi gulma monokotil dan dikotil dalam tanaman musim rabi. Yang Efisien Arsitektur *Net B7* dan *InceptionV4* dari CNN digunakan sebagai mesin keputusan. Berbasis kamera digital citra gulma tampaknya menjadi alternatif yang layak untuk pengendalian gulma di dalam vegetasi rabi di Madhya Pradesh (India). *Inception V4* dan *Efficient Net B7* telah mencapai akurasi 94% dan 97% masing-masing untuk identifikasi pertumbuhan gulma pada tanaman Rabi untuk 10 spesies yang berbeda. Akurasi rata-rata pertumbuhan gulma di tiga lokasi berbeda untuk spesies ini meningkat menjadi 97% menggunakan *Net B7* yang Efisien, yang lebih tinggi dari arsitektur *Inception V4* model CNN. Semakin banyak kepadatan gulma dan daun gulma yang tumpang tindih merupakan faktor penting yang mempengaruhi produksi tanaman. Studi masa depan bias temukan pendekatan yang lebih akurat dengan teknik deteksi gabungan berdasarkan data deret waktu.

1.1.3 Tinjauan Terhadap Literatur 3

(Shankar *et al.*, 2020) melakukan penelitian dengan judul “*Hyperparameter Tuning Deep Learning for Diabetic Retinopathy Fundus Image Classification*” Model diagnosis penyakit DR yang efisien yang disebut model HPTI-v4 telah disajikan. Model HPTI-v4 yang disajikan melibatkan proses segmentasi dengan proses ekstraksi ciri berdasarkan histogram dan Inception v4. Untuk mengatur *hyperparameters* di *Inception v4*, teknik optimasi Bayesian dilibatkan. Akhirnya, proses klasifikasi dilakukan dengan menggunakan MLP. Hasil eksperimen menyatakan bahwa model HPTI-v4 yang disajikan menunjukkan hasil yang luar biasa dengan akurasi, sensitivitas, dan spesifisitas maksimum masing-masing 99,49%, 98,83%, dan 99,68%. Oleh karena itu, model HPTI-v4 dapat digunakan sebagai alat diagnostik otomatis untuk klasifikasi gambar DR. Kedepannya, model yang diusulkan dapat lebih ditingkatkan dengan penerapan model klasifikasi.

1.1.4 Tinjauan Terhadap Literatur 4

(Chen *et al.*, 2021) melakukan penelitian yang berjudul “*Deep learning based classification of rock structure of tunnel face*”, dalam penelitian ini model kerangka berbasis visi yang dikenal sebagai jaringan *Inception-ResNet-V2* diusulkan untuk klasifikasi struktur massa batuan di muka terowongan. Untuk menangkap database secara teratur dan kuantitatif, sistem adaptif digital photography system (ADPS) yang terdiri dari kamera Canon 750D, tapeline, tripod, alat ukur dan sumber cahaya digunakan dalam proses akuisisi gambar. Jaringan *Inception-ResNetV2* dilatih oleh lebih dari 35.000 gambar yang diambil dari 150 permukaan terowongan di Mengzi-Pingbian Highway Tunnel (MPHT) di

Provinsi Yunnan, Cina, dan kemudian diuji dengan 7400 gambar tambahan. Dibandingkan dengan ResNet-50, ResNet-101, dan Inception-v4, jaringan yang diusulkan dapat mengurangi waktu validasi dan pengujian, meningkatkan akurasi klasifikasi struktur batuan, dan memfasilitasi penilaian kondisi di masa mendatang. Berdasarkan hasil yang diperoleh, waktu komputasi GPU jauh lebih rendah daripada CPU untuk keempat CNN eksperimental, baik dalam proses yang berjalan berbeda (seperti validasi dan pengujian) atau menggunakan model yang berbeda. Menggunakan prosesor GPU alih-alih CPU tradisional, *Inception-ResNetV2* menunjukkan kinerja terbaik dibandingkan tiga CNN lainnya. Selain itu, model yang dilatih oleh database besar dapat memperoleh fitur objek secara lebih komprehensif, sehingga menghasilkan akurasi yang lebih tinggi. Dibandingkan dengan metode klasifikasi citra asli, metode subcitra lebih mendekati kenyataan dengan mempertimbangkan akurasi dan perspektif divergensi kesalahan.

1.1.5 Tinjauan Terhadap Literatur 5

(Wahid, Mustamin and Lawi, 2021) melakukan penelitian dengan judul “Identifikasi Dan Klasifikasi Citra Penyakit Daun Tomat Menggunakan Arsitektur Inception V4” Berdasarkan dari alur kerja yang dilakukan, maka diperoleh hasil klasifikasi menggunakan arsitektur InceptionV4 Hasil penelitian ini diperoleh akurasi sebesar 90,00% dalam mengidentifikasi jenis penyakit daun tomat. Dalam penelitian ini validasi akurasi dari train model masih belum konsisten.

1.2 Kecerdasan Buatan

Artificial Intelligence merupakan ilmu dan teknik pembuatan mesin cerdas, khususnya program komputer cerdas. Hal ini terkait dengan tugas yang sama dengan menggunakan komputer untuk memahami kecerdasan manusia, tetapi Artificial Intelligence tidak harus membatasi dirinya terhadap metode yang diamati secara biologis (Kurzweil, 1985). Menurut pengertian Dobrev (2004:2) yang mengatakan bahwa Artificial Intelligence sebagai pembelajaran bagaimana membuat komputer melakukan hal-hal yang dimana saat ini masih lebih baik dilakukan oleh manusia.

1.3 *Computer Vision*

Computer Vision merupakan salah satu cabang ilmu pengetahuan yang bertujuan untuk membuat suatu keputusan yang berguna untuk mengenali objek fisik nyata dan keadaan berdasarkan sebuah gambar atau citra (Wakaf and Jalab, 2018) *Computer Vision* menjadikan komputer “*acts like human sight*”, sehingga mendekati kemampuan manusia dalam menangkap informasi visual. Kemampuan itu diantaranya adalah:

- a. *Object Detection*: Mengenali sebuah objek ada pada scene dan mengetahui dimana batasannya.
- b. *Recognition*: Menempatkan label pada objek.
- c. *Description*: Menugaskan properti kepada objek.
- d. *3D Inference*: Menafsirkan adegan 3D dari 2D yang dilihat.
- e. *Interpreting motion*: Menafsirkan gerakan.

1.4 Deteksi

Deteksi ialah penentuan ada atau tidaknya suatu objek pada citra, dan tahap awal dalam interpretasi citra. Keterangan yang diperoleh pada tahap deteksi bersifat global. Keterangan yang diperoleh pada tahap interpretasi selanjutnya, yaitu pada tahap identifikasi, bersifat setengah rinci. Keterangan rinci diperoleh dari tahap akhir interpretasi, yaitu tahap analisis (PUTRA, 2017). Image /Citra ialah data digital yang dihasilkan oleh sistem sensor berupa kamera. Dalam pengolahan data, image direpresentasikan sebagai matriks yang memiliki jumlah baris dan kolom sesuai dengan resolusi image yang diwakilinya. Perpotongan baris dan kolom disebut *pixel*, *pixel* berisi gabungan nilai matrik yang mewakili warna dari image. Contohnya untuk *image* 8 bit, berisi nilai pada *range* 0-255 yang membentuk warna, contohnya 0 untuk hitam dan 255 untuk putih (Arthaya, Sadiyoko, & Wiejaya, 2007).

1.5 Deep Learning

Deep learning merupakan salah satu bidang dari machine learning yang memanfaatkan jaringan syaraf tiruan untuk implementasi permasalahan dengan dataset yang besar. Teknik *deep learning* memberikan arsitektur yang sangat kuat untuk *Supervised Learning*, pembelajaran tersebut bisa mewakili data citra berlabel dengan baik. Machine learning dapat didefinisikan sebagai metode komputasi berdasarkan pengalaman untuk meningkatkan performa atau membuat prediksi yang akurat. Definisi pengalaman disini ialah informasi sebelumnya yang telah 10 tersedia dan bisa dijadikan data pembelajar (NURHIKMAT, 2018). Dalam pembelajaran *machine learning*, terdapat beberapa skenario-skenario seperti:

1. *Supervised Learning* Pembelajaran menggunakan masukan data pembelajaran yang telah diberi label. Setelah itu membuat prediksi dari data yang telah diberi label.
2. *Unsupervised Learning* Pembelajaran menggunakan masukan data pembelajaran yang tidak diberi label. Setelah itu mencoba untuk mengelompokan data berdasarkan karakteristik-karakteristik yang ditemui.
3. *Reinforcement Learning* Pada skenario reinforcement learning fase pembelajaran dan tes saling dicampur. Untuk mengumpulkan informasi pembelajar secara aktif dengan berinteraksi ke lingkungan sehingga untuk mendapatkan balasan untuk setiap aksi dari pembelajar.

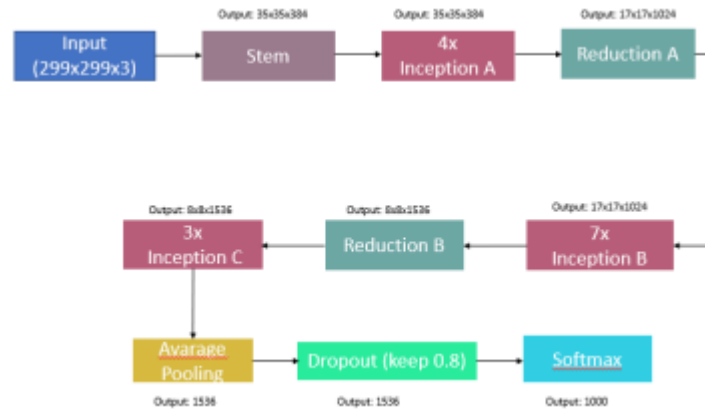
1.6 Inception

Inception adalah pengembangan dari *convolutional neural network* (CNN) yang pertama kali diperkenalkan oleh Szegedy, dan kawan-kawan pada tahun 2014 dalam judul “*Going Deeper with Convolutions*”. *Very deep convolutional networks* menjadi pusat pengembangan dalam performa *image recognition* belakangan ini. Contohnya adalah arsitektur *inception* yang menghasilkan performa yang sangat baik dengan komputasi yang relatif rendah (Istiqomah, 2020).

1.6.1 Inception V4

Membuat modul lebih seragam. Diperhatikan bahwa beberapa modul lebih rumit dari yang diperlukan. Sehingga kinerja perlu ditingkatkan yaitu dengan menambahkan lebih banyak lagi modul-modul seragam (*uniform modules*) tersebut. Skema Jaringan *inception*


V4 dapat dilihat pada gambar 2.1 berikut :



Gambar 2. 1 Arsitektur Inception V4

1.7 Neural Network


Neural Network merupakan suatu metode *artificial intelligence* yang konsepnya meniru sistem jaringan saraf yang ada pada tubuh manusia, dimana dibangun node-node yang saling berhubungan satu dengan yang lainnya. Node tersebut terhubung melalui suatu link yang biasa disebut dengan istilah *weight* atau bobot. *Neural network* pertama kali dirancang oleh Warren McCulloch dan Walter Pitts 11 pada tahun 1943 yang dikenal dengan McCulloch-Pitts *neurons* tentang dua *neuron* aktif secara bersamaan kemudian kekuatan tersebut terkoneksi antara neuron yang seharusnya bertambah. Kemudian pada tahun 1957, Frank Rosenblatt mengenalkan dan mengembangkan sekumpulan besar jaringan saraf tiruan yang disebut *perceptrons* (DEWI, 2018).



Gambar 2. 2 *Neural Network*

1.8 *Convolutional Neural Network (CNN)*

Convolutional network atau yang dikenal dengan *convolutional neural network* (CNN) merupakan tipe khusus dari *neural network* untuk memproses data yang mempunyai topologi jala atau grid-like topology. Pemberian nama *convolutional neural network* mengindikasikan bahwa jaringan tersebut menggunakan operasi matematika yang disebut konvolusi. Konvolusi sendiri adalah sebuah operasi *linear*. Jadi *convolutional network* adalah *neural network* yang menggunakan konvolusi minimal pada salah satu lapisannya (LeCun et al., 2015). *Convolutional neural network* (ConvNets) merupakan *special case* dari *artificial neural network* (ANN) yang saat ini diklaim sebagai model terbaik untuk memecahkan masalah *object recognition dan detection*.



Gambar 2. 3 *Convolutional Neural Network*

1.8.1 Convolution Layer

Convolutional Layer merupakan *layer* pertama yang menerima *input* gambar langsung pada arsitektur. Operasi pada *layer* ini sama dengan operasi konvolusi yaitu melakukan operasi kombinasi linier filter terhadap daerah lokal. Filter merupakan representasi bidang reseptif dari *neuron* yang terhubung ke dalam daerah lokal pada input gambar. *Convolutional layer* melakukan operasi konvolusi pada *output* dari *layer* sebelumnya. Layer tersebut adalah proses utama yang mendasari sebuah CNN. Tujuan dilakukannya konvolusi pada data citra adalah untuk mengekstraksi fitur dari citra *input*. Secara umum operasi konvolusi dapat ditulis dengan rumus berikut:

$$s(t) = (x * w)(t)$$

Pada fungsi $s(t)$ menghasilkan output tunggal yaitu Feature Map, argumen pertama berupa input yang merupakan x dan argument kedua yang merupakan w sebagai kernel atau filter. Jika melihat input sebagai citra dua dimensi, maka (t) bisa diasumsikan sebagai sebuah piksel dan menggantinya dengan i dan j . Oleh karena itu, untuk operasi konvolusi dengan lebih dari satu dimensi dapat digunakan rumus berikut:


$$S(i,j) = (K * I)(i,j) = \sum \sum I(i-m,j-n)K(m,n)$$

Pada persamaan diatas merupakan perhitungan dalam operasi konvolusi dengan i dan j sebagai piksel dari sebuah citra. Perhitungannya bersifat komutatif dan muncul ketika K sebagai kernelnya serta I sebagai input dan kernel yang dapat dibalik relative terhadap input. Operasi konvolusi dapat dilihat sebagai perkalian

matriks antara citra input dan filter dimana outputnya dapat dihitung dengan dot product (Rismiyati, 2016).

1.8.2 Pooling Layer

Pooling atau subsampling merupakan pengurangan ukuran matriks dengan menggunakan operasi *pooling*. *Pooling layer* biasanya dilakukan setelah *conv. Layer*. Terdapat dua macam *pooling* yang sering dipakai yaitu *average pooling* dan *max pooling*. Dalam *average pooling*, nilai yang diambil adalah nilai rata-rata, sementara pada *max pooling*, nilai yang diambil adalah nilai maksimal.



Gambar 2. 4 Pooling Layer

Pada Gambar 2.3 menunjukkan adanya operasi *max-pooling* untuk citra berukuran 4x4 dengan *pooling mask* yang berukuran 2x2. Output dari proses *pooling* adalah matriks dengan dimensi yang lebih kecil dibanding dengan matrik awal. Proses konvolusi dan *pooling* dilakukan beberapa kali sehingga didapatkan peta fitur dengan ukuran yang dikehendaki. Peta fitur tersebut akan menjadi input bagi *fully connected neural network* (sumber: medium.com).

1.8.3 *Fully Connected Layer*

Lapisan *Fully-Connected* adalah lapisan di mana semua *neuron* aktivasi dari lapisan sebelumnya terhubung semua dengan neuron di lapisan selanjutnya seperti halnya jaringan saraf tiruan biasa. Setiap aktivasi dari lapisan sebelumnya perlu diubah menjadi data satu dimensi sebelum dapat dihubungkan ke semua neuron di lapisan. Lapisan *Fully-Connected* biasanya digunakan pada metode *Multi Layer Perceptron* untuk mengolah data sehingga bisa diklasifikasikan. Perbedaan antara lapisan *Fully-Connected* dan lapisan konvolusi biasa adalah neuron di lapisan konvolusi terhubung hanya ke daerah tertentu pada input, sementara lapisan *Fully Connected* memiliki *neuron* yang secara keseluruhan terhubung. Namun, kedua lapisan tersebut masih mengoperasikan produk dot, sehingga fungsinya tidak begitu berbeda (Danukusumo, 2017).

1.9 *Tensorflow*

Tensorflow merupakan perpustakaan perangkat lunak yang dikembangkan oleh Tim Google Brain dalam organisasi penelitian Mesin Cerdas Google, untuk tujuan melakukan pembelajaran mesin dan penelitian jaringan syaraf dalam. *Tensorflow* menggabungkan aljabar komputasi teknik pengoptimalan kompilasi, mempermudah penghitungan banyak ekspresi matematis dimana masalahnya adalah waktu yang dibutuhkan untuk melakukan perhitungan. Fitur utamanya meliputi:

1. Mendefinisikan, mengoptimalkan, dan menghitung secara efisien ekspresi matematis yang melibatkan *array multidimension (tensors)*.
2. Pemrograman pendukung jaringan syaraf dalam dan teknik pembelajaran mesin.

3. Penggunaan GPU yang transparan, mengotomatisasi manajemen dan optimalisasi memori yang sama dan data yang digunakan. *Tensorflow* bisa menulis kode yang sama dan menjalankannya baik di CPU atau GPU. Lebih khususnya lagi, *Tensorflow* akan mengetahui bagian perhitungan yang harus dipindahkan ke GPU.
4. Skalabilitas komputasi yang tinggi di seluruh mesin dan kumpulan data yang besar.