

BAB II KERANGKA TEORITIS

A. Landasan Teori

1. Artificial Intelligence Secara Umum

Artificial Intelligence menurut Ardiansyah (2024, pp. 1), merupakan bagian dari ilmu komputer yang memiliki tujuan untuk menciptakan sistem yang dapat memahami pola dari data yang dipelajari, sehingga sistem tersebut dapat menunjukkan kecerdasan mirip manusia, seperti kemampuan untuk mengenali suara, wajah, membuat keputusan, dan memahami bahasa secara alami. AI pada tahun 1950-an diperkenalkan oleh seorang ilmuwan matematika asal Inggris yang bernama Alan Turing, yang menciptakan sebuah alat yang bisa meniru kecerdasan manusia (Ardiansyah, 2024, hlm. 6). Di tahun 2020-an, terlihat kebangkitan kembali ketertarikan terhadap AI, karena ketersediaan perangkat keras komputer dan data yang sangat besar, yang menghasilkan kemajuan signifikan dalam bidang seperti pembelajaran mesin dan pemrosesan bahasa alami (Mahendra dkk., 2024, hlm. 16–17)

Menurut Ardiansyah, (2024, pp. 7) kecerdasan buatan pada bidang kesehatan telah berkembang sejak tahun 2015. Pada tahun itu, hadir sebuah Pharmabot yang menggunakan Pemrosesan Bahasa Alami untuk mendukung pengobatan berbasis chatbot untuk membantu pengobatan berbasis chatbot. 2 tahun kemudian, yaitu pada tahun 2017, muncul AI yang serupa yaitu Maudy chatbot. Namun, Maudy memiliki fokus yang berbeda, yaitu untuk membantu proses penerimaan pasien dalam praktik layanan kesehatan primer.

Menurut beberapa ahli Ardiansyah (2024, pp. 10) penerapan AI dalam bidang kesehatan masih menjadi isu yang diperdebatkan. AI dianggap mampu mempercepat proses diagnosis, meningkatkan efisiensi pengobatan, dan mengurangi kemungkinan kesalahan manusia. Meski begitu, terdapat kekhawatiran mengenai pengurangan peran tenaga medis, privasi informasi pasien, biaya, serta kualitas data yang digunakan. Salah satu penerapan AI yang sering dibahas adalah pengenalan objek melalui Deep Learning (DL), termasuk algoritma seperti CNN, Fast R-CNN, dan YOLO, yang unggul dalam kecepatan dan akurasi pengenalan objek

2. Pengertian Machine Learning dan Deep Learning


Menurut Putro dkk. (2020, hlm. 20), machine learning merupakan cabang aplikasi dari Artificial Intelligence yang berfokus pada pengembangan sistem yang dapat belajar “secara mandiri” tanpa harus diprogram berulang kali oleh manusia. Putro dkk. (2020, hlm. 20) juga menyatakan bahwa metode

pembelajaran mesin memerlukan data sebagai bahan pembelajaran (training) sebelum menghasilkan keluaran atau output. Proses pembelajarannya dilakukan dengan cara mengamati data, baik melalui pengalaman langsung maupun instruksi tertentu, untuk menemukan pola-pola pada data dan membuat keputusan yang lebih baik di masa mendatang. Tujuan utamanya adalah memungkinkan komputer untuk secara otomatis belajar dan menyesuaikan aktivitasnya, tanpa memerlukan campur tangan atau masukan manusia.

Machine learning dapat mempelajari dengan sejumlah data (*learn from data*) sehingga dapat menghasilkan suatu model untuk melakukan proses input dan output tanpa harus membuat kode program yang eksplisit (Putro dkk., 2020, hlm. 21). Salah satu jenis model dari machine learning adalah supervised learning dimana cara pembelajarannya dilakukan menggunakan data yang telah diberi label untuk melatih model dalam mengklasifikasikan data, sehingga sistem mampu memprediksi keluaran berdasarkan masukan baru (Putro dkk., 2020, hlm. 24–25). Beberapa algoritma yang termasuk dalam supervised learning di antaranya Artificial Neural Network (ANN), Support Vector Machine (SVM), Naive Bayes Classifier, Decision Tree, Random Forest, Convolutional Neural Network (Setiawan, 2021a, hlm. 2).

Sedangkan deep learning menurut Mahendra dkk. (2024a, hlm. 194) merupakan cabang dari machine learning yang menggunakan metode pembelajaran yang sangat kompleks dan mendalam sehingga perangkat lunak dapat memahami data yang ada. Deep learning memanfaatkan struktur deep neural networks yang memiliki banyak lapisan (layer) untuk mengidentifikasi fitur data yang kompleks dan abstrak. Dan menurut (Ardiansyah, 2024, hlm. 3) penggunaan Deep learning diaplikasikan pada teknik klasifikasi, clustering, segmentasi ataupun recognition dan cocok untuk data yang tidak teratur seperti text, suara dan citra.

Menurut Setiawan (2021b, hlm. 3–4) terdapat perbedaan antara machine learning dan gambar pada saat ekstraksi fitur. Ekstraksi fitur pada machine learning dilakukan manual dengan cara menentukan terlebih dahulu jenis fitur yang akan digunakan lalu setelah fitur didapatkan selanjutnya akan diproses menggunakan algoritma machine learning. Sedangkan deep learning pada ekstraksi fitur dan klasifikasi dilakukan secara otomatis seperti digambarkan pada Gambar 2.1



Gambar 2. 1 Machine Learning Vs Deep Learning

Sumber: (Setiawan, 2021b, hlm. 3–4)

3. Pengertian Penyakit Kulit Campak

Menurut (Hulu dkk., 2020, hlm. 3) penyakit kulit menular merupakan penyakit yang disebabkan oleh virus, bakteri atau parasit tertentu yang timbul melalui orang yang terinfeksi, hewan kepada orang yang rentan baik secara langsung maupun tidak langsung melalui perantara lain seperti udara, air ataupun melalui tanaman. Contohnya seperti campak, penyakit campak dikenal juga sebagai *Morbili* atau *Measles*, merupakan penyakit menular (*infeksius*) dari orang ke orang dengan cara terkena percikan pernapasan sehingga mudah menular kepada orang lain melalui udara. Penyakit campak ini akan menyerang saluran pernapasan dan sistem imunitas, sehingga rentan terkena penyakit infeksi lainnya (Hulu dkk., 2020, hlm. 19).

Penyakit campak merupakan penyakit infeksi virus yang sangat menular, penyakit ini ditandai dengan gejala awal demam, batuk, pilek dan konjungtivitis yang kemudian diikuti dengan bercak kemerahan pada kulit (*rash*). Penyakit campak biasanya menyerang anak-anak dengan derajat ringan sampai sedang. Menurut Hulu dkk. (2020, hlm. 25–27) gejala campak melalui beberapa tahap :

(1) Tahap Prepatogenesis

Pada tahap ini, seseorang berada dalam keadaan normal atau sehat, meskipun telah terjadi interaksi antara tubuh dan virus penyebab penyakit tanpa menunjukkan gejala. Selama sistem imun tubuh tetap kuat, virus tersebut tidak akan memengaruhi kesehatan. Akan tetapi, jika sistem imun melemah dan lingkungan tidak kondusif, situasi dapat berubah dengan cepat, dan penyakit akan lanjut ke tahap selanjutnya, yaitu fase patogenesis.

(2) Tahap Patogenesis/Pra gejala

Pada tahap ini individu masih belum merasakan dirinya sakit

(3) Tahap klinis/Penyakit Dini

Pada tahap ini dimulai dengan timbulnya gejala dalam waktu 7-14 hari setelah terinfeksi yaitu berupa:

- (a) Demam dengan suhu meningkat pada hari ke-5 atau ke-6, yaitu pada saat puncak timbulnya erupsi;
- (b) Nyeri tenggorokan dan nyeri otot;
- (c) Hidung yang berair disertai dengan bersin dan penyumbatan hidung, di mana lendir yang pada mulanya bening berubah menjadi kental serta berwarna kuning kehijauan saat kondisi mencapai puncaknya. Gejala ini akan perlahan-lahan membaik seiring dengan penurunan demam;
- (d) Batuk, batuk dapat bertahan lama dan menghilang secara bertahap dalam waktu 5-10 hari;
- (e) Bercak Koplik adalah bercak kecil tidak beraturan sebesar ujung jarum, berwarna merah terang dengan bagian tengah putih keabu-abuan. Bercak ini menjadi tanda khas campak (morbili) dan muncul beberapa jam sebelum ruam, lalu menghilang 1-2 hari setelah ruam timbul;
- (f) Ruam muncul setelah 3-4 hari panas. Ruam awalnya muncul sebagai eritema *makulopapuler*, yaitu kombinasi bercak datar kemerahan (makula) dan benjolan kecil padat (*papula*) pada kulit. Ruam ini pertama kali terlihat di belakang telinga, di area batas rambut, kemudian menyebar ke pipi, leher, wajah, dan dada. Dalam waktu 24 jam, ruam meluas ke lengan atas dan seluruh tubuh, hingga akhirnya mencapai kaki pada hari ketiga. Saat ruam sudah menyebar ke kaki, ruam yang muncul lebih awal di bagian atas tubuh mulai memudar secara perlahan;
- (g) Mata merah.

4. Pengertian Convolutional Neural Network

Menurut Setiawan, (2021a, hlm. 5) pada dasarnya, CNN merupakan pengembangan dari Artificial Neural Network (ANN) konvolusional. ANN terdiri dari tiga hingga empat layer, sedangkan CNN merupakan network dengan puluhan hingga ratusan layer. CNN merupakan metode deep learning yang lebih baik diterapkan untuk data *supervised*. CNN ini memiliki kemampuan fitur pembelajaran yang lebih unggul dibandingkan dengan metode deep learning

lainnya. Selain itu, CNN memiliki kemampuan augmentasi data yang baik antara rotasi dan transformasi gambar.

Menurut Christian Cahyaningtyas dkk. (2025, hlm. 53–54) pelatihan model CNN merupakan proses yang kompleks yang melibatkan tahapan sistematis untuk mengoptimalkan kemampuan jaringan dalam mengekstrak fitur dan melakukan prediksi. Berikut adalah tahapan yang dilakukan:

- (1) Pengumpulan Dataset :Tahap pengumpulan data merupakan tahap penting karena dataset yang besar dan beragam yang memungkinkan model belajar fitur representatif dari berbagai variasi objek atau kondisi, misalnya pada dataset ekspresi wajah yang mencakup berbagai ekspresi dengan latar belakang dan pencahayaan berbeda;
- (2) Preprocessing Data : Tahap selanjutnya adalah menyiapkan data agar siap digunakan dalam pelatihan model yaitu *Preprocessing* data yang meliputi:
 - (a) Normalisasi : mengubah nilai pixel gambar ke rentang gambar standar misalnya 0-1. Tujuannya agar proses pelatihan menjadi lebih stabil dan mempercepat konvergensi model.

Rumus normalisasi:

$$x^1 = \frac{x - x_{min}}{x_{max} - x_{min}}$$

Keterangan :

x = nilai pixel asli

x_{min} = nilai pixel minimum

x_{max} = nilai pixel maksimum


x^1 = nilai pixel hasil normalisasi

- (b) Augmentasi data merupakan teknik yang digunakan untuk memperkaya variasi data latih dengan cara melakukan transformasi pada citra, seperti rotasi, flipping, dan zooming. Tujuan dari augmentasi adalah meningkatkan keberagaman data sehingga model tidak mudah mengalami overfitting;
- (c) Pembagian dataset: yaitu membagi dataset ke dalam training set, validation set, dan testing set dengan perbandingan umum seperti 70% : 15% : 15%.

Dalam bidang medis, algoritma CNN telah menjadi fondasi dalam analisis citra medis karena kemampuannya dalam mengekstraksi fitur secara

otomatis dan dapat mempelajari representasi hierarkis dari data citra yang dapat membantu proses diagnosis, dan pengobatan. Menurut (Mahendra *dkk.*, 2024b, hlm. 58) algoritma CNN sudah membuktikan performa untuk mendeteksi dan mengklasifikasikan gambar medis, seperti X-ray, MRI, dan juga CT scan. Hal tersebut dapat membantu dokter dalam mendiagnosis penyakit seperti kanker, penyakit jantung, dan juga penyakit paru – paru dengan tingkat keakurasian yang sangat tinggi.

Menurut Nurmaini *dkk.*, hlm. (2021, hlm. 36–37) Convolutional Neural Network merupakan arsitektur deep learning yang terdiri dari beberapa lapisan komputasi neuron dari node yang terhubung satu sama lain berdasarkan bobot. Pada umumnya CNN tersusun dari lapisan konvolusional yang bertujuan untuk merepresentasikan fitur dari input, sedangkan lapisan pooling bertujuan untuk mengurangi resolusi peta fitur, dan lapisan yang terhubung sepenuhnya (fully connected). (Nurmaini *dkk.*, 2021, hlm. 36–37) Menyatakan bahwa CNN berhasil dilatih yang dapat menyusun hierarki informasi seperti klasifikasi gambar, deteksi objek, informasi selama pra-pemrosesan dan segmentasi gambar.




Gambar 2. 2 Arsitektur CNN

Sumber (Nurmaini *dkk.*, 2021, hlm. 37):

Menurut Yudistira (2024, hlm. 133–139) terdapat 3 layer utama pada Dasar Convolutional Neural Network yaitu :

- (1) Convolutional layer, merupakan bagian utama dari CNN yang berfungsi mengekstraksi fitur penting dari citra. Proses konvolusi dilakukan dengan cara menggeser kernel atau filter di atas citra input, kemudian melakukan perkalian elemen per elemen antara kernel dengan nilai piksel citra, lalu menjumlahkan hasilnya. Hasil dari operasi ini membentuk feature map (convolved feature) yang menyoroti fitur penting seperti tepi, tekstur, atau pola tertentu.



Gambar 2. 3 Ilustrasi proses lapisan konvolusi

Sumber : (Yudistira, 2024, hlm. 133)

Dijelaskan pada ilustrasi gambar diatas menurut (Yudistira, 2024, hlm. 133):

- Input berupa citra berukuran $5 \times 5 \times 1$ (hijau).
- Kernel/filter yang digunakan berukuran $3 \times 3 \times 1$ (kuning) dengan stride = 1.
- Kernel digeser satu blok demi satu blok (ditandai warna oranye), sehingga terbentuk output berupa feature map $3 \times 3 \times 1$ (merah muda).

Nilai stride tersebut akan menentukan pergeseran perkalian matrik antara K dan bagian dari input, matrik kernel K yang digunakan berbentuk :

Kernel / Filter K :


$$\begin{bmatrix} 1 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 1 \end{bmatrix}$$

Seperti pada gambar paling terakhir, maka didapatkan Convoled featur:

$$\begin{bmatrix} 4 & 3 & 4 \\ 2 & 4 & 3 \\ 2 & 3 & 4 \end{bmatrix}$$

- Pooling layer, merupakan lapisan yang berfungsi untuk mengurangi dimensi dari featur map dengan cara mengambil nilai maksimum atau rata – rata dari wilayah tertentu. Tujuannya untuk mengurangi overfitting, meningkatkan invariansi terhadap pergeseran spasial kecil dan mengurangi jumlah parameter dalam jaringan. Pada umumnya operasi pooling menggunakan metode seperti Max pooling atau average pooling.

Ukuran operasi pooling biasanya lebih kecil dibandingkan dengan ukuran feature map. Pada umumnya, pooling menggunakan ukuran kernel 2×2 piksel dengan stride = 2, sehingga setiap langkah pergeseran mengurangi ukuran data secara signifikan. Sebagai contoh, ilustrasi pada gambar di bawah menunjukkan proses pooling terhadap sebuah feature map berukuran 4×4 piksel. Pada Max Pooling, setiap wilayah 2×2 diambil nilai maksimum, sedangkan pada Average Pooling nilai rata-ratanya yang digunakan.



Gambar 2. 4 Ilustrasi Max Pooling dan Average Pooling

Sumber: (Yudistira, 2024, hlm. 138)

Berikut adalah Rumus perhitungannya :

(a) Feature map input

$$\begin{bmatrix} 12 & 20 & 30 & 0 \\ 8 & 12 & 2 & 0 \\ 34 & 70 & 37 & 4 \\ 112 & 100 & 25 & 12 \end{bmatrix}$$

Kernel pooling: 2×2, stride = 2

(b) Max Pooling

Ambil nilai terbesar dari tiap kotak 2×2.

(1) Kotak kiri atas : {12,20,8,12} = Max -> 20

(2) Kotak Kanan Atas: {30,0,2,0}= Max -> 30

(3) Kotak kiri Bawah : { 34,70,112,100} = Max -> 122

(4) Kotak Kanan Bawah: {37,4,25,12} = Max -> 37

Maka hasil yang diperoleh dari Max Pooling : { 20,30,122,37}

(c) Average Pooling

Ambil rata rata dari tiap kotak 2x2

(1) Kotak kiri atas : $\frac{12+20+8+12}{4} = \frac{54}{4} = 13$


$$(2) \text{ Kotak kanan atas : } \frac{30+0+2+0}{4} = \frac{32}{4} = 8$$

$$(3) \text{ Kotak kiri bawah : } \frac{30+70+112+100}{4} = \frac{316}{4} = 79$$

$$(4) \text{ Kotak kanan bawah : } \frac{37+4+25+12}{4} = \frac{78}{4} = 19.5 \approx 20$$

Maka hasil yang diperoleh dari average pooling: **{13,8,79,20}**

- (3) Fully Connected Layer (FC) merupakan lapisan terakhir dari CNN yang menerima input hasil dari proses pooling. Sebelum masuk ke lapisan FC, output berbentuk matriks dari pooling terlebih dahulu diproses melalui Flatten Layer, yaitu proses mengubah matriks menjadi vektor (menipiskan nilai matriks ke dalam satu dimensi). Proses ini dapat dilihat pada gambar di bawah ini:



Gambar 2. 5 Arsitektur dengan FC layer

Sumber (Yudistira, 2024, hlm. 139)

Pada tahap ini, setiap vektor hasil flatten akan diproses secara matematis di setiap neuron menggunakan persamaan:

$$y = g(W^t x + b)$$

Dimana,

x : input vektor dengan dimensi (p_l, l)

W : matriks bobot dengan dimensi (p_l, n_l) di mana p_l adalah jumlah neuron pada lapisan sebelumnya dan n_l adalah jumlah neuron pada lapisan ini

b : bias

g : fungsi aktivasi ReLU

Fungsi aktivasi ReLU merupakan fungsi yang sering digunakan dalam CNN sebagai fungsi aktivasi default yang menerima input negatif maka

mengembalikan nilai 0 dan saat menerima input maka mengembalikan nilainya kembali. rumus ReLU adalah sebagai berikut

$$F(x) = \max(0, x)$$

dimana x = input vektor x

Citra digital menurut Dijaya, hlm. (2023, hlm. 1–6) merupakan bentuk representasi visual dari dunia nyata dalam bentuk digital yang dapat dipahami oleh komputer. Citra digital memiliki elemen titik seperti pixel, yang tersusun dengan baris kolom dan setiap pixel memiliki nilai numerik yang menggambarkan tingkat kecerahan atau warna pada posisi citra. Terdapat konsep dasar citra seperti dijelaskan di bawah ini :


- (a) Pixel, setiap pixel memiliki nilai numerik yang menggambarkan tingkat kecerahan (grayscale) atau kombinasi warna;
- (b) Resolusi Citra, mengacu pada jumlah pixel pada citra ;
- (c) Citra Biner, Citra biner hanya memiliki dua nilai pixel yang mungkin (hitam dan putih). Biasanya digunakan untuk segmentasi citra;
- (d) Format Citra, mengacu pada cara data disimpan dalam memori komputer seperti JPEG, PNG, atau BMP.

5. Arsitektur ResNet

Menurut Ermatita dkk. (2025, hlm. 47–48) arsitekturnya, ResNet (Residual Network) merupakan pengembangan dari jaringan saraf klasik yang diperkenalkan pada kompetisi ImageNet tahun 2015. ResNet memiliki beberapa versi, seperti ResNet-18, ResNet-34, ResNet-50, ResNet-101, hingga ResNet-152. Semakin dalam jumlah layer, semakin kompleks proses pelatihannya. Untuk menghindari kejenuhan pelatihan dan kesalahan yang tinggi, ResNet menambahkan identity layer melalui operasi $\text{add}()$, sehingga parameter dapat dilatih secara lebih optimal.

Adapun cara kerja Arsitektur ResNet (Residual Network) menurut (Ermata dkk., 2025, hlm. 48–49) adalah memanfaatkan Residual Blocks untuk mengatasi masalah exploding maupun vanishing gradient. Konsep utama yang diperkenalkan yaitu skip connections, yaitu menghubungkan aktivasi dari satu layer ke layer yang lebih jauh dengan melewati beberapa layer di antaranya. Hal ini membentuk residual block yang kemudian ditumpuk untuk membangun keseluruhan arsitektur ResNet. Pendekatan ini memungkinkan jaringan mempelajari residual mapping daripada pemetaan awal $H(x)$, sehingga pelatihan menjadi lebih stabil dan akurat.


$F(x) := H(x) - x$ which gives $H(x) := F(x) + x$



Gambar 2. 6 Skip Shorcut Connection

Sumber : (Ermatita dkk., 2025, hlm. 48–49)

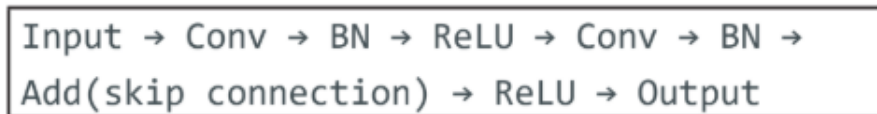
Adapun keuntungan utama dari penambahan skip connection (Ermatita dkk., 2025, hlm. 48–49) adalah apabila ada layer yang kinerjanya menurun, jalur tersebut dapat dilewati sehingga proses pelatihan tetap optimal. Dengan demikian, ResNet mampu melatih deep neural network tanpa mengalami masalah vanishing atau exploding gradient. Pendekatan serupa sebelumnya dikenal dengan Highway Networks, yang juga menggunakan skip connection. ResNet sendiri awalnya dibangun dari arsitektur 34-layer plain network yang terinspirasi oleh VGG-19, kemudian ditambahkan shortcut connection sehingga membentuk Residual Network.



Gambar 2. 7 Arsitektur Resnet 34

Sumber : (Ermatita dkk., 2025, hlm. 50)

Adapun struktur sederhana dari ResNet menurut (Fazri, 2025, hlm. 101–102) sebagai berikut:



Gambar 2. 8 Struktur Resnet

Sumber : (Fazri, 2025, hlm. 101)

- (d) Conv -> Convolutional Layer
- (e) BN -> Batch Normalization
- (f) ReLU -> Activation function
- (g) Add -> Penjumlahan elemen-wise dari input dan output

6. Pemrograman Phyton

Menurut Jubilee Enterprise, hlm. (2019, hlm. 1) Phyton adalah bahasa pemrograman berbasis teks yang bersifat interpretatif dan dianggap mudah dipahami, dengan penekanan pada keterbacaan kode. Menjelaskan (Jubilee Enterprise, 2019, hlm. 1) bahwa Phyton memiliki kemampuan untuk menangani pengembangan aplikasi modern yang berkaitan dengan istilah seperti big data, data mining, deep learning, data science, dan machine learning. Dengan kata lain, Phyton adalah bahasa pemrograman yang sederhana untuk menciptakan aplikasi yang berhubungan dengan kecerdasan buatan.

Phyton merupakan bahasa pemrograman yang paling populer dalam pengembangan aplikasi berbasis data, terutama dalam bidang data science dan machine learning karena kemudahan sintaks dan dukungan pustaka yang luas. Menurut (Maesaroh *dkk.*, 2024, hlm. 93) , Python merupakan bahasa pemrograman yang menyediakan berbagai modul berisi fungsi dan alat bantu yang berguna untuk memenuhi kebutuhan dalam pengembangan perangkat lunak. Modul-modul ini dirancang untuk menyelesaikan berbagai tugas pemrograman umum, seperti pengolahan data, koneksi jaringan, pengolahan citra, serta analisis matematis. (Maesaroh *dkk.*, 2024, hlm. 93) juga menjelaskan bahwa library pada Python merupakan kumpulan dari beberapa package dan modul yang memiliki fungsi serupa, yang bertujuan untuk memudahkan proses pembuatan aplikasi tanpa harus menulis kode secara manual dalam jumlah besar.

7. Research and Development


Berdasarkan pendapat Sugiyono, hlm. (2019, hlm. 17) metode penelitian pengembangan (R&D) adalah suatu cara penelitian yang bertujuan

untuk menciptakan desain produk baru, menguji efektivitas produk yang sudah ada, serta merancang dan menciptakan produk baru. Apabila produk tersebut telah terbukti efektif, maka dapat diterapkan dalam pekerjaan, sehingga pelaksanaan tugas bisa menjadi lebih mudah dan cepat. Menurut (Sugiyono, 2019, hlm. 754) metode penelitian dan Pengembangan dapat diartikan sebagai pendekatan ilmiah untuk meneliti, merancang, memproduksi, serta menguji validitas produk yang telah dibuat. Dalam buku yang ditulis oleh (Sugiyono, 2019, hlm. 753) Borg and Gall (1998) menjelaskan bahwa yang dimaksud dengan produk di sini tidak hanya merujuk pada benda fisik seperti buku teks, film edukasi, dan perangkat lunak komputer, melainkan juga termasuk metode seperti pengajaran dan program-program seperti program pendidikan untuk menangani masalah anak yang terlibat dengan alkohol serta program pengembangan bagi staf.

8. Prototyping

Menurut Putra, Efitra dan Sari, hlm. (2024, hlm. 105) prototyping merupakan suatu metode pengembangan perangkat lunak dimana dibuat suatu model awal atau prototipe suatu sistem dibuat untuk melihat, memahami, dan menentukan kebutuhan pengguna sebelum pembuatan sistem akhir. Sedangkan menurut (Budi Hartono, 2022, hlm. 71) prototyping adalah sebagai metode berulang dalam pembangunan sistem di mana kebutuhan diubah menjadi sistem yang berfungsi, yang terus-menerus disempurnakan melalui kolaborasi antara pengguna dan analis. Prototipe juga dapat dibuat dengan menggunakan berbagai alat pengembangan untuk mempermudah proses.

Prototyping memiliki peran penting dalam proses pengembangan perangkat lunak karena berbagai fungsi yang mendukung pemahaman kebutuhan sistem yang lebih baik. Menurut Putra, Efitra dan Sari, hlm. (2024, hlm. 105) prototyping berfungsi sebagai contoh awal sistem yang dapat dimanfaatkan oleh pengguna untuk memberikan masukan, sehingga sistem dapat disempurnakan sebelum dikembangkan secara menyeluruh Terdapat beberapa tahapan menurut (Budi Hartono, 2022, hlm. 71), yang mencakup identifikasi kebutuhan, pengembangan prototyping, penggunaan dan evaluasi oleh pengguna, pengkodean sistem, pengujian, hingga evaluasi akhir sebelum implementasi sepenuhnya dilakukan.



Gambar 2. 9 Tahapan model prototyping

Sumber : (Budi Hartono, 2022, hlm. 72)

9. Pengujian Sistem

Pengujian perangkat lunak merupakan bagian penting dalam memastikan kualitas dan keandalan suatu sistem. Menurut (Wicaksono, 2021, hlm. 15) berdasarkan teori ANSI/IEEE 1059 merupakan proses analisis dari suatu entitas software yang berfungsi untuk mendeteksi perbedaan antara kondisi yang ada dan yang diinginkan (defects / error / bugs) dan untuk mengevaluasi fitur - fitur dari suatu entitas software. Proses tersebut dapat dilakukan dengan menggunakan metode seperti white box dan black box testing.

Dalam proses pengembangan perangkat lunak, pengujian menjadi langkah penting untuk memastikan bahwa aplikasi berjalan sesuai dengan fungsinya dan bebas dari kesalahan. Menurut (Wicaksono, 2021, hlm. 20–23), pengujian white-box merupakan metode pengujian perangkat lunak yang bertujuan untuk menguji struktur internal atau kode program untuk memastikan bahwa fungsi eksternal dari aplikasi berjalan sesuai dengan yang diharapkan. Sedangkan Blackbox testing menurut (Wicaksono, 2021, hlm. 48), merupakan metode pengujian perangkat lunak yang digunakan untuk

mengevaluasi fungsionalitas suatu aplikasi tanpa mengetahui atau mempertimbangkan struktur internal dari kode program.

10. Confusion Matrix

Menurut buku machine learning Rahmadden dkk., hlm. (2024, hlm. 79) confusion matrix merupakan bagian dari machine learning yang mempelajari data yang sudah ada dan mengelompokkannya sebagai data baru dengan cara memberikan hasil output dengan variabel yang bersifat kategorial nominal atau ordinal. Confusion matriks mempunyai fungsi utama yaitu dapat memberikan atau menguji dari pemorma model. Pada confusion matrix terdapat 4 istilah yang digunakan untuk merepresentasikan dari hasil proses klasifikasi : True Positive (TP), True Negatif (TN), False Negatif (FN), dan False Positive (FP) TP merupakan total data positif yang berhasil diidentifikasi dengan akurat oleh sistem. TN adalah jumlah data negatif yang dikenali dengan tepat oleh sistem. FN adalah jumlah data negatif yang teridentifikasi secara keliru oleh sistem. FP adalah jumlah data positif yang terklasifikasi dengan tidak benar oleh sistem. berikut digambarkan hasil klasifikasi dua kelas menggunakan confusion matriks :

	Prediksi Negatif	Prediksi Positif
Aktual Negatif	True Negative [TN]	False Positive [FP]
Aktual Positif	False Negative [FN]	True Positive [TP]

Gambar 2. 10 Tabel Confusion Matrix

Sumber : (Sanjaya, 2023, hlm. 26)

Adapun rumus yang digunakan dalam menggunakan confusion matrix menurut Sanjaya (2023, hlm. 23–25) adalah sebagai berikut :

(a) Akurasi

Akurasi berfungsi untuk mengukur seberapa sering model memberikan prediksi yang benar dalam klasifikikasi citra:

$$Akurasi (\%) = \frac{(TP + TN)}{(TP + FP + FN + TN)}$$

(b) Presisi (Precision)

Presisi berfungsi untuk mengukur sejauh mana hasil positif yang diprediksi oleh model adalah benar.

$$Precision (\%) = \frac{TP}{(TP + FP)}$$

(c) Recall

Recall berfungsi untuk sejauh mana model dapat mengenali semua hasil positif yang sebenarnya.

$$Recall (\%) = \frac{TP}{(TP + FN)}$$

(d) F1-Score

F1-score berfungsi untuk menggabungkan antara presisi dan recall menjadi satu angka tunggal. F1- score digunakan untuk memberikan pengukuran yang seimbang dengan mempertimbangkan false positive dan false negatif

$$F1\ Score (\%) = \frac{(2 * Recall * Precision)}{(Recall + Precision)}$$

B. Tinjauan Studi

Pada penelitian ini tidak terlepas dari penelitian terdahulu yang berkaitan dengan penyakit kulit pada manusia yang telah dilaksanakan sebelumnya dengan menggunakan metode CNN hingga penerapan machine learning dan deep learning. Beberapa hasil penelitian berikut akan dijadikan acuan untuk penelitian yang akan dilakukan. Berikut adalah penelitian yang dimaksud antara lain:

- (1) **Penelitian dilakukan oleh**(Lubis dkk., 2023) **dengan judul “Klasifikasi Penyakit Kulit Menggunakan Convolutional Neural Network (CNN) Dengan Arsitektur Vgg16”**. Penelitian tersebut menggunakan data set dengan jumlah 1.456 dalam bentuk citra yang terdiri dari 7 jenis penyakit kulit yaitu Dermatitis, Campak, Herpes, Kutil, Cacar Air, Kurap dan Psoriasis yang bersumber dari Kaggle. Pada penelitian ini difokuskan untuk pengembangan model klasifikasi penyakit kulit menggunakan Arsitektur VGG16 dan MobileNet. Hasil yang didapatkan performa model dari hasil pengujian data citra dengan arsitektur VGG16 memiliki hasil akurasi yang baik yaitu 82% dibandingkan dengan MobileNet 80%.
- (2) **Penelitian dilakukan oleh**(Wibowo et al., 2022) **dengan judul “Image Detection for Common Human Skin Diseases in Indonesia Using CNN and Ensemble Learning Method”**. Pada penelitian tersebut menggunakan data set dengan jumlah 1203 jenis penyakit yang dibagi menjadi 6 kelas terdiri dari Herpes simplex, Pityriasis, Psoriasis, Scabies, Tinea Corporis, dan Vitilo yang bersumber dari situs atlasdermatology.com.br, dermnetz.org, dermatlas.net. Pada penelitian tersebut berfokus untuk melakukan perbandingan antara akurasi gambar RGB dan Grayscale melalui metode CNN ResNet50 serta teknik ensemble elearning. Hasil yang diperoleh Cross Validation menunjukkan bahwa gambar RGB memiliki performa yang lebih baik dengan tingkat akurasi 49%. Sementara itu, penggunaan gambar Grayscale menghasilkan akurasi 47%. Di sisi lain, hasil dari model ensemble menunjukkan hasil yang setara, dengan gambar Grayscale memiliki akurasi

yang lebih tinggi, yaitu 93%, dibandingkan dengan gambar RGB yang mencapai akurasi 86%.

- (3) **Penelitian dilakukan oleh** (Aritonang et al., 2023) **dengan judul “Human Skin Disease Detection using Convolutional Neural Network Method with Hyperparameter Tuning to Determine the Best Parameter Combination”**. Penelitian ini menggunakan data set dengan jumlah 1605 gambar penyakit kulit yang terdiri dari 3 jenis kelas yaitu, Eczema, Seboroik Keratosis, dan Melanocytic Nevi yang diperoleh dari Kaggle. Penelitian tersebut difokuskan untuk mendapatkan kombinasi hyperparameter terbaik untuk optimasi dalam pengklasifikasian penyakit kulit. Hasil yang diperoleh yaitu mendapatkan kombinasi hyperparameter terbaik yaitu 3 convolutional layer, 0,05 APL dropout, 0,5 dropout layer, 64 dense layer dan optimizer RMSProp. persentase akurasi dari skenario 1 tanpa hyperparameter tuning menghasilkan akurasi 91,63% dan skenario 2 menggunakan hyperparameter tuning dengan akurasi 97,81%.
- (4) **Penelitian dilakukan oleh** (Rianto dkk., 2023) **dengan judul “Convolutional Neural Network untuk Mengklasifikasi Tingkat Keparahan Jerawat”**. Penelitian ini menggunakan data set yang diperoleh dari kaggle dengan jumlah 1.500 gambar wajah berjerawat yang dibagi ke dalam tiga kelas yaitu 0, 1, dan 2. Penelitian tersebut difokuskan untuk mengembangkan model klasifikasi jenis dan tingkat keparahan jerawat menggunakan Convolutional Neural Network (CNN). Hasil yang diperoleh menunjukkan model yang dikembangkan memiliki akurasi sebesar 0.9234 atau 92% pada epoch ke-100, dengan hasil uji validasi yang menunjukkan bahwa model pengklasifikasi dapat bekerja dengan baik, mampu mengklasifikasikan data baru dengan benar, dan penerapan Early serta contrast factor terbukti dapat meningkatkan akurasi model.
- (5) **Penelitian dilakukan oleh** (Martin et al., 2024) **dengan judul “Klasifikasi Kanker Kulit Pada Citra Dermatoskopi Menggunakan CNN”**. Penelitian tersebut menggunakan data set dengan jumlah 24.839 citra, dengan pengujian menggunakan seluruh data dan 3.000 data, masing-masing 500 gambar kanker kulit yang terdiri dari 6 kelas yaitu Actinic Keratosis, Basal Cell Carcinoma, Melanocytic Nevus, Melanoma, Pigmented Benign Keratosis, dan Squamous Cell Carcinoma yang bersumber dari Kaggle. Penelitian tersebut berfokus untuk mengklasifikasi jenis kanker kulit menggunakan Arsitektur Alexnet. Hasil yang diperoleh model yang dikembangkan mampu mengklasifikasikan citra dermatoskopi menjadi 6

jenis kanker kulit dengan hasil berupa akurasi 72%, Precision 70%, Recall 72% dan F1-Score 69%. Ini menunjukkan bahwa model ini memiliki performa yang cukup baik dalam mendeteksi berbagai jenis kanker kulit.

- (6) **Penelitian dilakukan oleh (Gusti dkk., 2024) dengan judul “Implementasi Algoritma Convolutional Neural Network (Resnet-50) untuk Klasifikasi Kanker Kulit Benign dan Malignant ”.** Penelitian tersebut menggunakan Data set dengan jumlah 5000 data latih kanker kulit benign dan 4600 data latih kanker kulit malignant dan menggunakan 1000 data uji kanker kulit benign dan 1000 data uji kanker kulit malignant yang bersumber dari International Skin Image Collaborating (ISIC). Penelitian ini berfokus untuk mengembangkan model Resnet-50 menggunakan algoritma CNN dan mengevaluasi model menggunakan matriks accuracy pada citra medis kanker kulit. Hasil yang diperoleh mencapai akurasi sebesar 93,88% dan loss sebesar 13,24%. Hasil model ini kemudian diekspor ke dalam format h5 guna diimplementasikan ke dalam tampilan sebuah website menggunakan framework Flask.
- (7) **Penelitian dilakukan oleh (Susanto et al., 2024) dengan judul “Klasifikasi Penyakit Cacar Menggunakan Arsitektur AlexNet”.** Penelitian tersebut menggunakan 3200 data gambar penyakit kulit yang dibagi menjadi 4 kelas yaitu Chickenpox, Cowpox, Monkeypox dan Healthy Skin. Pada penelitian tersebut berfokus pada klasifikasi jenis-jenis penyakit cacar menggunakan arsitektur AlexNet. Hasil yang diperoleh dari penelitian tersebut terdapat pada skenario pengujian ke 7 dengan menggunakan parameter batch size 16, learning rate 0,0001, optimizer Adam, dan Epoch 40 didapatkan nilai precision sebesar 92%, recall sebesar 92%, f1 score sebesar 92%.
- (8) **Penelitian dilakukan oleh (Nigat et al., 2023) dengan judul “Fungal Skin Disease Classification Using the Convolutional Neural Network”.** Pada penelitian tersebut menggunakan data set dengan jumlah 407 gambar yang dibagi menjadi 4 kelas yaitu Tinea pedis, tinea capitis, Tinea Corporis, dan tinea unguium yang bersumber dari klinik Medium Dr. Gerbi di Jimma, Ethiopia gambar tersebut diambil setelah proses diagnosis dikonfirmasi oleh dokter. Pada penelitian tersebut berfokus untuk mengklasifikasikan jenis penyakit kulit yang disebabkan oleh jamur menggunakan algoritma CNN. Hasil yang diperoleh dalam penelitian ini mencapai tingkat akurasi 93,3%, dengan sensitivitas 86,4%, spesifisitas 95,4%, presisi 87,3%, dan skor F1

86,8%. Model ini juga mengungguli arsitektur CNN lainnya seperti MobileNetV2 dan ResNet50.

(9) **Penelitian dilakukan oleh**(Mallick dkk., 2023) **dengan judul “Skin Cancer Detection Using CNN (Vgg16) Inculcated With Clah And Gaussian Filter”**. Pada penelitian tersebut menggunakan data set dengan jumlah 4000 citra yang terbagi menjadi 4 kelas yaitu Melanoma, Karsinoma sel skuamosa, Dermatofibroma dan Nevus Pigmentosus yang bersumber dari arsip dokter kulit akses terbuka yaitu International Skin Imaging Collaboration. Penelitian ini berfokus pada pengklasifikasian kanker kulit menggunakan CNN arsitektur VGG-16. Hasil yang diperoleh dalam penelitian ini mencapai akurasi sebesar 99.70%, dengan nilai loss 0.0055%, precision 99.75%, recall 99.75%, dan f1-score 99.50%.

(10)**Penelitian dilakukan oleh** (Anggriandi et al., 2023) **dengan judul “Comparative Analysis of CNN and CNN-SVM Methods For Classification Types of Human Skin Disease”**. Penelitian tersebut menggunakan data set HAM10000 yang terdiri dari 21.000 gambar dermatoskopi yang terbagi menjadi 7 kelas penyakit kulit yaitu Actinic Keratoses and Intraepithelial Carcinoma, Basal Cell Carcinoma, Benign Keratosis-like Lesions, Dermatofibroma, Melanocytic Nevi, Melanoma, Vascular Lesions yang bersumber dari situs web Harvard Dataverse. Penelitian ini berfokus untuk membandingkan 2 metode yaitu CNN dan gabungan CNN-SVM dalam mengklasifikasikan multikelas penyakit kulit. Hasil yang diperoleh menunjukkan bahwa pendekatan CNN dengan arsitektur MobileNet adalah yang paling efektif dalam mengidentifikasi penyakit kulit jika dibandingkan dengan model CNN-SVM yang menggunakan kernel "poly," "rbf," "linear," dan "sigmoid." Model CNN dapat mencapai tingkat akurasi yang mencapai 93,47% menandakan kemampuan model CNN dalam mengklasifikasikan gambar dengan baik.

Tabel 2. 1 Tinjauan Studi Penelitian

NO	PENELITI	JUDUL	JURNAL SUMBER	KONTRIBUSI
1	Supirman, Chairisni Lubis, Danu	Klasifikasi Penyakit Kulit Menggunakan Convolutional Neural	Jurnal Sistem Informasi dan Teknik Komputer	Penelitian ini berkontribusi dalam mengembangkan model pengklasifikasian penyakit kulit dengan memanfaatkan CNN dengan arsitektur VGG16 dan

NO	PENELITI	JUDUL	JURNAL SUMBER	KONTRIBUSI
	Yuliarto 2023	Network (CNN) Dengan Arsitektur Vgg16	Vol.8, No.1 2023 https://ejournal.catur.sakti.ac.id/index.php/simtek/article/view/217	MobileNet. Penelitian ini juga dapat menawarkan solusi berbasis teknologi untuk mendukung diagnosis awal penyakit kulit, khususnya bagi masyarakat yang memiliki akses kesehatan terbatas atau yang enggan untuk melakukan konsultasi secara langsung.
2	Fauzi Dzulfiqar Wibowo, Irma Palupi, Bambang Ari Wahyudi 2022	Image Detection for Common Human Skin Diseases in Indonesia Using CNN and Ensemble Learning Method	Journal of Computer System and Informatics (JoSYC) Volume 3, No. 4, August 2022, Page 527–535 https://www.mendeley.com/catalogue/68a18b96-a26f-3150-ac63-d929ae425f39/	Penelitian ini berkontribusi dengan mengembangkan model klasifikasi untuk penyakit kulit berbasis CNN melalui metode ensemble learning, yang mencapai akurasi 93% pada gambar Grayscale. Penelitian ini memberikan solusi otomatis yang penting untuk mempercepat dan meningkatkan keakuratan dalam mendiagnosis penyakit kulit, terutama di Indonesia.
3	Riki Matua Aritanong, Mangaras Yanu Florestiyanto, Bambang	Deteksi Penyakit Kulit Manusia Menggunakan Metode Convolutional Neural Network	Telematika: Jurnal Informatika dan teknologi informasi Vol.20, No..2, Juni 2023	Penelitian ini berkontribusi dalam meningkatkan kinerja CNN dengan melakukan penyesuaian hyperparameter, yang mencapai tingkat akurasi hingga 97,81%. Teknik augmentasi data berhasil mengatasi keterbatasan data

NO	PENELITI	JUDUL	JURNAL SUMBER	KONTRIBUSI
	Yuwono 2023	Dengan Hypermeter Tuning	http://www.jurnal.upnyk.ac.id/index.php/telematika/article/view/9161	set, dan penekanan pada tiga jenis penyakit kulit yang dapat mendukung pengembangan alat diagnosis yang lebih efisien.
4	Rianto, Demas Riddho Listianto 2023	Convolutional Neural Network Untuk Mengklasifikasi Tingkat Keparahan Jerawat	Jurnal Teknologi Informasi Vol.20 No.2 2023 https://ejournal.uksw.edu/article/view/8843	Penelitian ini berkontribusi dalam mengidentifikasi tingkat keparahan jerawat yang berhasil mencapai tingkat akurasi sebesar 92,34%. Penelitian ini juga memperkenalkan penggunaan Early stopping untuk menghindari overfitting, sedangkan augmentasi dan modifikasi kontras gambar berperan dalam meningkatkan kinerja model.
5	Nicolas Martin, Daniel Udjulawa 2024	Klasifikasi Kanker Kulit Pada Citra Dermatoskopi Menggunakan CNN	Jurnal Algoritme Vol.5, No.1 2024 https://jurnal.mdp.ac.id/index.php/algoritme/article/view/9034	Penelitian ini memberikan kontribusi dengan mengembangkan model CNN yang berbasis AlexNet untuk mengidentifikasi 6 tipe kanker kulit dengan tingkat akurasi 72%. Penelitian ini menawarkan alternatif yang lebih terjangkau dibandingkan dengan prosedur biopsi. Penelitian ini dapat berkontribusi dalam proses diagnosis awal, untuk meningkatkan tingkat kesembuhan pasien kanker kulit.

NO	PENELITI	JUDUL	JURNAL SUMBER	KONTRIBUSI
6	Gogor Putra Hafi Puja Gusti, Elin Haerani, Fadhillah Syafrica, Febi Yanto, Siska Kurnia Gusti 2024	Implementasi Algoritma Convolutional Neural Network (Resnet-50) untuk Klasifikasi Kanker Kulit Benign dan Malignant	MALCOM: Indonesian Journal of Machine Learning and Computer Science Vol. 4 Iss. 3 July 2024, pp: 984-992 https://journal.irpi.or.id/index.php/malcom/article/view/1398	Penelitian ini berkontribusi dalam mengembangkan model klasifikasi kanker kulit berbasis CNN dengan arsitektur ResNet-50, mencapai akurasi 94,88%. Model ini telah sukses diimplementasikan dalam aplikasi web berbasis Flask, memungkinkan pengguna untuk dengan cepat mendiagnosis kanker kulit secara langsung.
7	Rafael Ivan Susanto, Tinaliah 2024	Klasifikasi penyakit Cacar Menggunakan Arsitektur AlexNet	Jurnal Algoritme, Vol. 5, No. 1, Oktober 2024, pp. 47~56 https://jurnal.mdp.ac.id/index.php/algoritme/article/view/9045/2111	Penelitian ini memberikan kontribusi dengan menggunakan arsitektur AlexNet untuk mengidentifikasi penyakit cacar, dengan memanfaatkan data set yang telah diperluas untuk meningkatkan variasi data, serta melaksanakan analisis mendetail terhadap parameter model, sehingga dapat membantu diagnosis penyakit cacar dengan akurasi tinggi dan efisiensi.
8	Tsedenya Debebe nigat, Tilahun Melak	Fungal Skin Disease Classification Using the Convolutional	Journal of Healthcare Engineering Volume 2023, Article	penelitian ini memberikan kontribusi dengan mengembangkan model CNN yang efektif dalam mendeteksi empat jenis penyakit kulit jamur


NO	PENELITI	JUDUL	JURNAL SUMBER	KONTRIBUSI
	Sitote, Berihun Molla Gedefaw 2023	Neural Network	ID 6370416, 9 pages https://www.mendeley.com/catalogue/30dfb81b-c797-35f2-8f97-2e699baa7879/	dengan tingkat akurasi mencapai 93,3%, serta menawarkan alternatif bagi fasilitas kesehatan yang mengalami keterbatasan alat dalam mendiagnosis masalah kulit, untuk penanganan yang cepat.
9	Shweta Mallick, Dr S P Mishra 2023	Skin Cancer Detection Using CNN (Vgg16) Inculcated With Clah And Gaussian Filter	International Journal on Recent and Innovation Trends in Computing and Communicati on Vol.11, Issue:9s 2023 https://www.mendeley.com/catalogue/a5ff675e-542c-30b9-ad22-6f60240eb7a7/	Penelitian ini berkontribusi dalam mengembangkan sistem deep learning berbasis CNN dengan struktur VGG-16 untuk mengenali empat jenis kanker kulit, mencapai akurasi 99,70% dengan menggunakan teknik pre-processing CLAHE dan filter Gaussian. Penelitian dapat membantu tenaga medis untuk mempercepat proses diagnosis dan mengurangi risiko keterlambatan penanganan kanker kulit.
10	Dendi Anggriandi, Ema Utami, Dhani	Comparative Analysis of CNN and CNN-SVM Methods For	Sinkron: Jurnal dan Penelitian Teknik Informatika	Penelitian ini berkontribusi dalam menciptakan model klasifikasi untuk penyakit kulit yang menggunakan CNN dengan akurasi yang tinggi

NO	PENELITI	JUDUL	JURNAL SUMBER	KONTRIBUSI
	Ariatmanto 2023	Classification Types of Human Skin Disease	Volume 7, Number 4, Oktober 2023 https://www. mendeley.co m/catalogue/ 6941f636- 7709-3432- 9c17- 55f7cfe3bb77 /	(93,47%) dan melakukan perbandingan dengan CNN-SVM. Model CNN terbukti memberikan hasil yang lebih baik dibandingkan dengan CNN-SVM, yang menunjukkan tingkat akurasi yang lebih rendah (51%-81%) pada berbagai jenis kernel.

Dalam referensi atau rujukan dari sepuluh jurnal yang telah digunakan di atas terdapat perbedaan penelitian. Perbedaannya dalam beberapa jurnal ini, peneliti membahas pengklasifikasian jenis penyakit kulit, sementara kontribusi dalam penelitian ini adalah mengembangkan sistem berbasis website yang dapat mendeteksi penyakit kulit campak untuk membantu tenaga medis dalam diagnosis awal dalam mengenali ruam campak. Sistem ini tidak hanya menampilkan hasil campak yang terdeteksi beserta tingkat akurasinya, tetapi juga menyertakan heatmap pada area kulit yang terdampak serta memberikan saran tindak lanjut sesuai hasil analisis.

C. Kerangka Berpikir

Kerangka berpikir ini menggambarkan gagasan solusi untuk pemecahan masalah dalam penelitian ini, yang berfokus pada penerapan algoritma Convolutional Neural Network (CNN) untuk mendeteksi penyakit kulit campak. Proses ini mencakup pengenalan pola visual dalam citra kulit untuk mengenali karakteristik spesifik yang berkaitan dengan jenis penyakit kulit campak. Dengan kemampuan CNN yang unggul dalam analisis gambar, penelitian ini bertujuan untuk mengembangkan sistem deteksi yang akurat dan efektif untuk mendukung proses diagnosis awal.



Gambar 2. 11 Kerangka Berpikir

Gambar 2.6 menjelaskan kerangka pemikiran penerapan algoritma CCN mulai dari permasalahan yang ada sampai kepada hasil yang diperoleh. Penjelasan lebih detail mengenai kerangka pemikiran pada penelitian ini adalah :

- (1) Penetapan masalah adalah untuk mengidentifikasi dan merumuskan masalah yang akan diteliti
- (2) Melakukan pendekatan algoritma CNN pada permasalahan yang sudah ditetapkan
- (3) Tahapan pengembangan merupakan proses untuk melakukan analisis data dan perancangan desain untuk dilakukan evaluasi dan validasi data. Pada tahap penerapan ini, dilakukan penerapan algoritma CNN ke dalam aplikasi/sistem yang akan dibuat serta pembuatan prototype untuk melakukan uji coba hasil dari sistem tersebut.
- (4) Penerapan adalah tahap untuk menerapkan algoritma menggunakan algoritma CNN ke dalam sistem atau aplikasi yang akan dibuat dengan menggunakan bahasa pemrograman python dan menggunakan data set berupa gambar penyakit kulit campak.
- (5) Pengukuran merupakan proses pengujian ketepatan hasil dalam penerapan algoritma CNN dalam mendeteksi penyakit kulit.

- (6) Hasil merupakan terciptanya sebuah produk yang kemudian dapat mengatasi permasalahan masih belum akurat dan efisiennya proses pemeriksaan manual dalam mendeteksi penyakit kulit

D. Hipotesis

Dengan menerapkan metode Convolutional Neural Network (CNN), diduga dapat mendeteksi jenis penyakit kulit secara lebih akurat dan cepat, yang pada akhirnya dapat mencegah kesalahan diagnosis dan mempercepat pengobatan, karena CNN memiliki kemampuan untuk mengekstraksi fitur-fitur penting dalam citra kulit, seperti warna, bentuk, area ruam yang sering kali sulit dikenali oleh manusia. Dari 10 penelitian sebelumnya yang telah dilakukan, rata-rata akurasi yang berhasil didapatkan mencapai tingkat akurasi 89,25% dalam mendeteksi penyakit kulit menggunakan CNN. Pendekatan CNN diharapkan dapat membantu mengatasi permasalahan dalam mendeteksi penyakit kulit campak yang sering kali sulit dilakukan secara konvensional dan mempercepat proses diagnosis awal untuk pengobatan yang lebih cepat dan tepat.