

BAB II

LANDASAN TEORI

2.1 Penelitian Terdahulu

Beberapa penelitian sebelumnya telah membuktikan bahwa metode CNN efektif dalam *feature extraction* penting dari citra medis, sedangkan SVM dikenal sebagai algoritma klasifikasi yang kuat dan mampu bekerja dengan baik pada *dataset* berukuran terbatas serta berdimensi tinggi. Berdasarkan karakteristik tersebut, CNN dan SVM dipilih karena keduanya saling melengkapi. CNN berperan dalam menangkap pola visual secara otomatis dari citra mata, sementara SVM bertugas mengklasifikasikan hasil ekstraksi fitur tersebut secara akurat. Kombinasi ini telah menunjukkan hasil yang menjanjikan dalam berbagai studi sebelumnya, terutama dalam konteks diagnosis penyakit berbasis citra. Oleh karena itu, model hybrid CNN-SVM dipilih dalam penelitian ini untuk mengoptimalkan proses diagnosa katarak secara otomatis. Tabel berikut menyajikan beberapa penelitian terdahulu yang relevan dan menjadi dasar pemilihan metode pada penelitian ini.

Tabel 2.1 Penelitian Terdahulu

| No. | Jurnal | Model | Hasil |
|-----|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| 1. | N. Gour and P. Khanna, "Multi-class multi-label ophthalmological disease detection using transfer learning based Convolutional Neural Network," <i>Biomedical Signal Processing and Control</i> , vol. 66, p. 102329, Apr. 2021. doi:10.1016/j.bspc.2020.102329 [10] | VGG16, ResNet, InceptionV3, MobileNet (Transfer Learning CNN architectures) | Penelitian ini menggunakan transfer learning dengan empat arsitektur CNN (VGG16, ResNet50, InceptionV3, MobileNet) untuk klasifikasi multi-label lima penyakit mata (Katarak, Glaukoma, ARMD, HR, DR) dari 1.169 citra fundus. InceptionV3 menghasilkan F1-score tertinggi (0.86), menunjukkan efektivitas metode ini dalam deteksi penyakit mata secara simultan dan akurat. |
| 2. | R. B. Simanjuntak et al., "Cataract classification based on fundus images | GoogLeNet, MobileNet, ResNet, Proposed | Penelitian ini membandingkan GoogLeNet, MobileNet, ResNet, dan CNN usulan untuk |

| No. | Jurnal | Model | Hasil |
|-----|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| | using convolutional neural network,” JOIV : International Journal on Informatics Visualization, vol. 6, no. 1, p. 33, Mar. 2022. doi:10.30630/joiv.6.1.856 [6] | CNN | klasifikasi katarak dari citra fundus ke dalam empat kelas (Normal, Immature, Mature, Hypermature) menggunakan 3.200 gambar hasil augmentasi. Model CNN usulan meraih akurasi tertinggi 92% dan performa stabil pada citra RGB, menunjukkan efektivitas CNN dalam mendeteksi dan mengklasifikasi tingkat katarak secara akurat. |
| 3. | A. A. Marouf, M. M. Mottalib, R. Alhadj, J. Rokne, and O. Jafarullah, “An efficient approach to predict eye diseases from symptoms using machine learning and ranker-based feature selection methods,” Bioengineering, vol. 10, no. 1, p. 25, Dec. 2022. doi:10.3390/bioengineering10010025 [11] | Decision Tree, Random Forest, Naive Bayes, AdaBoost, Logistic Regression, KNN, Bagging, Boosting, SVM | Penelitian ini memprediksi lima jenis penyakit mata berdasarkan gejala pasien dengan sembilan algoritma machine learning dan seleksi fitur berbasis Ranker (Pearson, IG, PCA, Relief). Data dikumpulkan dari rumah sakit dan dianalisis oleh dokter. SVM menghasilkan akurasi tertinggi sebesar 99.11%, menjadikannya model terbaik untuk prediksi berbasis gejala. |
| 4. | L. K. Singh, Pooja, H. Garg, M. Khanna, and R. S. Bhadoria, “An enhanced deep image model for glaucoma diagnosis using feature-based detection in retinal fundus,” Medical Engineering & Computing, vol. 59, no. 2, pp. 333–353, Jan. 2021. doi:10.1007/s11517-020-02307-5 [5] | SVM, K-Nearest Neighbors (KNN), Naive Bayes (NB), Artificial Neural Network (ANN) | Penelitian ini menggunakan fitur CDR dan area ISNT dari citra fundus untuk diagnosis glaukoma dengan klasifikasi ANN, SVM, NB, dan KNN. Dataset DRIONS-DB (140 gambar) digunakan dengan 70% data latih dan 30% uji. ANN memberikan akurasi tertinggi 97.61%, membuktikan efektivitasnya dalam deteksi dini glaukoma. |
| 5.. | N. Gharaibeh, O. M. Al-hazaimeh, A. Abu-Ein, and K. M.O. Nahar, “A hybrid SVM naïve-Bayes classifier for bright lesions recognition in eye fundus images,” International Journal on Electrical Engineering and Informatics, vol. 13, no. 3, pp. 530–545, Sep. 2021. | Hybrid Support Vector Machine (SVM)-Naive Bayes | Penelitian ini mendeteksi lesi terang pada citra fundus (eksudat dan cotton wool spots) untuk diagnosis dini DR menggunakan model Hybrid SVM-Naive Bayes. Dataset DIARETDB0 dan DIARETDB1 digunakan. Model hybrid mencapai akurasi 98.60%, mengungguli KNN dan SVM, menunjukkan efektivitas |

| No. | Jurnal | Model | Hasil |
|-----|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| | doi:10.15676/ijeei.2021.13.3.2 [12] | | pendekatan dalam deteksi lesi secara akurat. |
| 6. | S. Baba, P. Kumari, and P. Saxena, "Retinal disease classification using custom CNN model from OCT images," <i>Procedia Computer Science</i> , vol. 235, pp. 3142–3152, 2024. doi:10.1016/j.procs.2024.04.297 [8] | Custom CNN, EfficientNetB0, Random Forest, SVM, XGBoost, PCA, GLCM | Penelitian ini mengklasifikasikan penyakit retina (CNV, DME, DRUSEN, dan normal) dari citra OCT menggunakan Custom CNN, EfficientNetB0, SVM, XGBoost, dan Random Forest. Fitur diekstraksi dengan GLCM dan PCA. Model CNN kustom meraih akurasi tertinggi 98.00%, membuktikan efektivitasnya dalam diagnosis retina berbasis citra medis. |
| 7. | M. T. Utami, J. C. Young, and A. Wicaksana, "Implementation of Support Vector Machine Algorithm for Identifying Facial Skin Types," <i>TEST Engineering & Management</i> , vol. 83, pp. 12271–12277, Apr. 2020. [13] | Support Vector Machine (SVM) | Penelitian ini mengklasifikasikan jenis kulit wajah (kering, berminyak, normal) dari citra mikroskop digital 60x menggunakan ekstraksi fitur tekstur (histogram & GLCM) dan klasifikasi SVM. Model dibangun dengan Python & Flask. SVM mencapai akurasi 90%, menunjukkan efektivitasnya dalam identifikasi jenis kulit wajah. |
| 8.. | R. O. Ogundokun, J. B. Awotunde, H. B. Akande, C.-C. Lee, and A. L. Imoize, "Deep Transfer Learning Models for mobile-based ocular disorder identification on retinal images," <i>Computers, Materials & Continua</i> , vol. 80, no. 1, pp. 139–161, 2024. doi:10.32604/cmc.2024.052153 [7] | MobileNetV2-SVM, InceptionV3, MobileNetV2, Xception (with Transfer Learning) | Penelitian ini mengembangkan deteksi gangguan mata berbasis citra retina untuk perangkat mobile menggunakan model MobileNetV2, InceptionV3, dan Xception yang dikombinasikan dengan SVM. Model MobileNetV2-SVM meraih akurasi tertinggi 90.11%, menunjukkan efektivitas pendekatan hybrid untuk deteksi dini gangguan mata secara mobile. |
| 9. | A. AKRAM and R. DEBNATH, "An automated eye disease recognition system from visual content of facial images using machine learning techniques," <i>TURKISH JOURNAL OF</i> | Deep Convolution Neural Network (DCNN), Support Vector Machine (SVM), Principal Component Analysis (PCA), t-Distributed | Penelitian ini mendeteksi tujuh jenis penyakit mata dari citra wajah menggunakan DCNN untuk ekstraksi fitur dan SVM untuk klasifikasi, dengan PCA dan t-SNE sebagai seleksi fitur. Dataset berisi 1.753 citra mata. DCNN mencapai akurasi |

| No. | Jurnal | Model | Hasil |
|-----|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| | ELECTRICAL ENGINEERING & COMPUTER SCIENCES, vol. 28, no. 2, pp. 917–932, Mar. 2020. doi:10.3906/elk-1905-42 [14] | Stochastic Neighbor Embedding (t-SNE) | tertinggi 98.79%, menunjukkan keunggulannya dalam deteksi otomatis penyakit mata. |
| 10. | T. A. Hartanto and S. Hansun, “Comparative Analysis of Pre-trained CNN Models on Retinal Diseases Classification,” International Journal of Industrial Engineering & Production Research, vol. 35, no. 3, pp. 1–12, Sep. 2024. doi:10.22068/ijiepr.35.3.1935 [15] | EfficientNet-B0, ResNet-50V2, Inception-V3, DenseNet-169 (Pre-trained CNN models) | Penelitian ini membandingkan empat model CNN (EfficientNet-B0, ResNet-50V2, Inception-V3, DenseNet-169) untuk klasifikasi penyakit retina dari citra fundus menggunakan dataset APTOS 2019. DenseNet-169 meraih akurasi tertinggi 92.59%, menjadikannya model terbaik untuk deteksi otomatis berbasis deep learning. |

Pada tabel 2.1 dari 10 penelitian terdahulu, penelitian tersebut digunakan sebagai referensi dan jurnal pendukung pada penelitian ini. Penelitian di atas membahas tentang penggunaan metode machine learning dengan algoritma CNN dan SVM untuk *image processing* dan terbukti bahwa metode tersebut memiliki tingkat akurasi yang tinggi. Oleh karena itu, algoritma CNN dan SVM akan digunakan pada penelitian kali ini.

Tujuan dari penelitian ini adalah untuk mendiagnosa penyakit katarak dari citra mata dengan menggunakan metode *hybrid* CNN dan SVM. Penelitian ini berbeda dari penelitian sebelumnya karena tidak hanya berfokus pada metode tunggal saja. Selain itu, penelitian ini menggunakan kombinasi metode *hybrid* CNN dan SVM untuk agar memberikan hasil yang lebih akurat dan reliabel. Penelitian yang secara khusus menggabungkan CNN dan SVM dalam satu model *hybrid* untuk diagnosis katarak masih terbatas.

2.2 Tinjauan Teori

2.2.1 Katarak

Katarak adalah kondisi di mana lensa mata mengalami kekeruhan, mengakibatkan gangguan penglihatan yang signifikan. Kekeruhan ini terjadi karena penumpukan atau pengendapan protein pada lensa mata, yang menghambat cahaya masuk ke retina. Meskipun katarak dapat terjadi pada berbagai usia, kondisi ini lebih umum ditemukan pada individu berusia lanjut, sering kali dikaitkan dengan proses penuaan alami. Faktor risiko lain termasuk paparan sinar ultraviolet yang berkepanjangan, riwayat diabetes melitus, hipertensi, dan penggunaan obat kortikosteroid [16].

Di Indonesia, katarak merupakan penyebab utama kebutaan. Data menunjukkan bahwa sekitar 81,2% gangguan penglihatan di Indonesia disebabkan oleh katarak. Kondisi ini tidak hanya mempengaruhi kualitas hidup individu tetapi juga berdampak pada aspek fisik, mental, dan sosial. Penanganan katarak umumnya melalui prosedur pembedahan untuk mengganti lensa yang keruh dengan lensa buatan, yang terbukti efektif dalam memulihkan penglihatan [17].

2.2.2 Deep Learning

Deep learning adalah bagian dari *machine learning* yang menggunakan *neural network* berlapis-lapis untuk mempelajari pola dan representasi data secara otomatis [18]. Arsitektur ini terdiri atas banyak *layer neuron* yang mengolah input secara bertahap melalui transformasi *non-linear*, sehingga mampu mengenali pola yang sangat kompleks tanpa memerlukan rekayasa fitur manual.

Sistem *code* yang kuat dan sejumlah besar data *training* adalah kunci keberhasilan dalam *deep learning*. Tugas yang berpotensi membutuhkan banyak waktu adalah pelatihan model *deep learning*.

Namun, sering kali dampaknya sangat signifikan dalam menyelesaikan tugas-tugas yang rumit seperti mengidentifikasi pola-pola, mengklasifikasikan data-data. Terjadi kemajuan yang cepat pada teknologi ini, dengan penelitian mengenai *deep learning* yang tidak henti-henti untuk memperbaiki performa serta efisiensi dari model-modelnya. Hal inilah yang membuat bidang tersebut menjadi salah satu bagian dari AI yang sangat menarik perhatian saat ini [19].

2.2.3 Klasifikasi

Salah satu dari banyak tugas di bidang *machine learning* yang disebut klasifikasi adalah membagi data ke dalam kelompok-kelompok tertentu berdasarkan karakteristiknya. Mengembangkan model yang dapat mengidentifikasi pola dalam set data pelatihan adalah titik utama proses klasifikasi. Kemudian, model ini digunakan sebagai dasar untuk mengklasifikasikan set data baru ke dalam kelompok atau kategori dengan benar. Dalam beberapa situasi, seperti *spam email* dan *email* umum, pembagian gambar dengan objek digunakan untuk membedakan jenis data. Model klasifikasi yang tersedia untuk *deep learning* sendiri termasuk *Decision Tree* dan algoritma *Support Vector Machines*. Selain itu, *Convolutional Neural Network* seringkali digunakan daripada yang lain [20].

Dalam banyak aplikasi, seperti pengambilan keputusan otomatis, pengelompokan data, dan analisis sentimen, hasil klasifikasi sangat bermanfaat. Klasifikasi juga merupakan komponen penting dalam pemrosesan data yang bertujuan untuk memberikan struktur dan makna pada data yang kompleks [21].

2.2.4 Image Processing

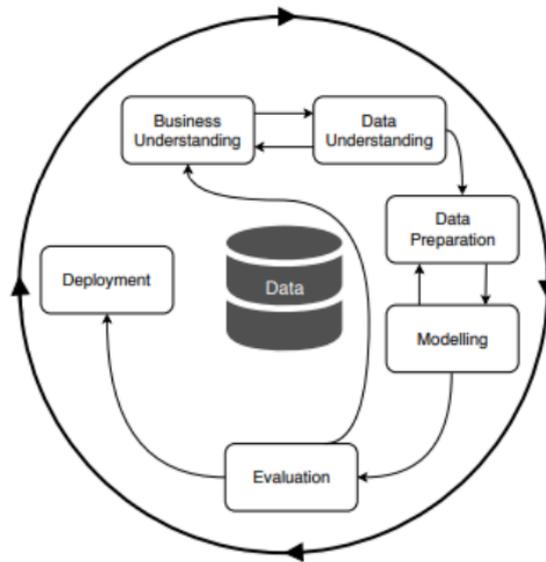
Image processing merupakan serangkaian teknik yang digunakan untuk mengolah dan menganalisis citra digital guna meningkatkan

kualitas visual atau mengekstrak informasi penting dari gambar tersebut. Dalam konteks penelitian medis, image processing memainkan peran penting dalam membantu sistem komputer mengenali pola, struktur, dan anomali pada citra medis seperti citra mata. Proses ini meliputi tahap-tahap seperti resize, rescale, normalisasi piksel, peningkatan kontras, serta augmentasi data untuk memperkaya variasi input. Dengan image processing yang tepat, data citra menjadi lebih konsisten dan representatif untuk dimasukkan ke dalam model pembelajaran mesin, sehingga meningkatkan akurasi dan efisiensi proses klasifikasi [22].

2.3 Framework / Algoritma Penelitian

2.3.1 CRISP-DM

Dalam proses *data mining* dan analisis data, terdapat sebuah kerangka kerja atau metodologi yang dikenal dengan nama CRISP-DM, atau *Cross-Industry Standard Process for Data Mining*. Tahapan langkah-langkah yang diperlukan untuk proyek data mining dapat dikonfigurasi menjadi enam tahap utama dalam kerangka kerja ini. Dalam tahap pertama, yang disebut "*Business Understanding*," menentukan tujuan bisnis dan kebutuhan untuk memahami data secara lebih menyeluruh. Tahap "*Data Understanding*" meliputi pengumpulan dan eksplorasi data yang relevan. "*Data Preparation*" menjadi langkah selanjutnya, di mana data akan dipersiapkan dan dimodifikasi sebelum melakukan analisis. Selama "*Modeling*," seseorang menciptakan model prediktif atau deskriptif yang kemudian dinilai dan diuji dalam langkah "*Evaluation*". Pada akhirnya, pada tahap akhir "*Deployment*", model-model ini dioperasikan dalam lingkungan bisnis [23].



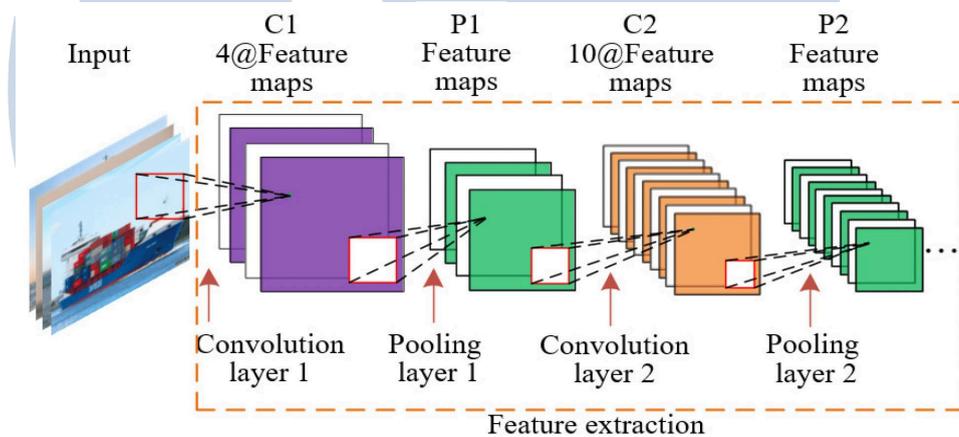
Gambar 2.1 Proses CRISP-DM
Sumber: [24]

Pada gambar 2.1 merupakan gambaran proses CRISP-DM. Pendekatan CRISP-DM sangat berguna dalam industri dan proyek data mining karena dapat memberikan struktur dan panduan yang jelas untuk setiap tahapan proses. Hal ini membantu tim proyek untuk menjalankan risiko, memastikan kualitas data, dan mencapai hasil yang lebih baik dalam analisis data. Kelebihannya yang fleksibel serta kemampuannya untuk disesuaikan, CRISP-DM dapat diterapkan dalam berbagai situasi dan sektor industri yang berbeda [25].

2.3.2 Convolutional Neural Network

Convolutional Neural Network (CNN) adalah suatu jaringan yang khusus dirancang untuk tugas-tugas pemrosesan gambar dan data, seperti pengenalan gambar, klasifikasi objek, deteksi wajah, dan segmentasi objek. CNN memiliki arsitektur yang terinspirasi dari cara otak manusia mengenali pola visual. Salah satu komponen utama dalam CNN adalah *layer convolution*, yang digunakan untuk mengekstraksi fitur-fitur penting dari gambar atau data. *Layer* ini melakukan operasi konvolusi untuk menggabungkan informasi lokal

dari area kecil dalam gambar dengan bobot-bobot tertentu. CNN juga umumnya memiliki *layer pooling* yang digunakan untuk mereduksi dimensi data dan menjaga invariansi terhadap pergeseran dalam gambar. Kombinasi dari *layer convolution*, *pooling*, dan *layer* tersembunyi lainnya dalam CNN memungkinkan model ini untuk secara efektif memahami dan memproses informasi visual kompleks [26].



Gambar 2.2 Arsitektur *Feature Extractor* CNN
Sumber: [27]

Dengan pengenalan pola, deteksi objek, pengenalan wajah, dan kendaraan, CNN telah menjadi komponen penting dalam berbagai aplikasi pengolahan gambar dan video. Salah satu keunggulan utama CNN adalah kemampuannya untuk otomatis mengekstraksi elemen hierarkis yang semakin kompleks dari gambar, yang memungkinkannya melakukan tugas-tugas pemrosesan gambar dengan tingkat akurasi yang tinggi. *Image recognition* dan *computer vision* melalui CNN adalah komponen penting dari kemajuan AI [28]. Pada gambar 2.2 CNN berperan sebagai *feature extraction* dengan memanfaatkan arsitektur *layer convolutional* untuk menangkap representasi hierarkis dari citra, mulai dari pola sederhana hingga kompleks. Dalam konteks ini, CNN *pre-trained* MobileNetV2 yang telah dilatih pada dataset, digunakan untuk mengekstrak fitur dengan

menghilangkan *layer* klasifikasi akhir dan mengambil *output* dari *layer convolution* atau *global pooling* sebagai representasi fitur [8]. Fitur ini bersifat *high-dimensional* dan mengandung informasi spasial yang relevan untuk analisis patologi, seperti kekeruhan lensa pada katarak. Keunggulan CNN sebagai *feature extraction* terletak pada kemampuannya mengotomatisasi proses ekstraksi fitur tanpa bergantung pada metode *handcrafted*, sehingga mengurangi bias manusia dan meningkatkan generalisasi pada variasi citra medis [29].

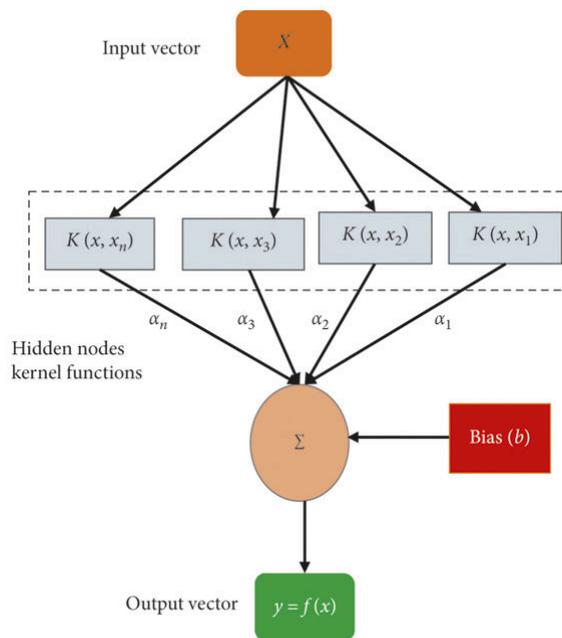
MobileNetV3 merupakan pengembangan dari MobileNetV2 yang dirancang menggunakan teknik *Neural Architecture Search (NAS)* dan dilengkapi dengan *Squeeze-and-Excitation blocks* serta fungsi aktivasi *hard-swish* untuk meningkatkan efisiensi dan akurasi pada perangkat *mobile*. Meskipun MobileNetV3 menawarkan performa yang lebih unggul secara teoretis, dalam penelitian ini dipilih MobileNetV2 karena arsitekturnya lebih stabil, ringan, dan telah banyak digunakan dalam studi klasifikasi citra medis. Selain lebih mudah diintegrasikan sebagai *feature extractor*, MobileNetV2 juga memberikan keseimbangan yang baik antara akurasi dan efisiensi komputasi dalam skenario klasifikasi tiga kelas [30].

Selain MobileNetV2, ResNet50 merupakan salah satu arsitektur CNN yang dikembangkan berdasarkan konsep *residual learning*. Model ini memiliki 50 *layer* dan dirancang untuk mengatasi masalah degradasi akurasi pada jaringan yang sangat dalam dengan memperkenalkan *shortcut connection* atau *skip connection* yang memungkinkan informasi melewati beberapa *layer* sekaligus. Dengan struktur tersebut, ResNet50 mampu melakukan ekstraksi fitur secara lebih dalam dan efektif tanpa kehilangan informasi penting dari citra input. Arsitektur ini umum digunakan dalam berbagai tugas klasifikasi citra dan dapat dimanfaatkan sebagai *feature extractor* yang kuat untuk

menghasilkan representasi vektor dari gambar sebelum dilanjutkan ke tahap klasifikasi [31].

2.3.3 Support Vector Machine

Support Vector Machine (SVM) merupakan algoritma *machine learning* yang digunakan untuk menyelesaikan masalah klasifikasi maupun regresi. Algoritma ini bekerja dengan menentukan *hyperplane* terbaik yang mampu memisahkan data ke dalam dua kategori secara optimal. *Hyperplane* tersebut diposisikan sedemikian rupa agar memiliki *margin* atau jarak maksimum terhadap titik data terdekat dari masing-masing kelas. Strategi ini bertujuan untuk mengurangi kesalahan saat model diterapkan pada data baru yang belum dikenal sebelumnya, sehingga meningkatkan kemampuan generalisasi model [32].



Gambar 2.3 Arsitektur SVM
Sumber: [33]

Pada gambar 2.3 merupakan gambaran arsitektur SVM. Salah satu fitur utama SVM adalah kemampuannya untuk melakukan klasifikasi

non-linear melalui penggunaan kernel *trick*. Dengan memetakan data input ke dalam ruang fitur berdimensi lebih tinggi, SVM dapat menemukan *hyperplane* yang memisahkan data yang tidak dapat dipisahkan secara *linear* dalam ruang asli. Fungsi kernel yang umum digunakan meliputi kernel polinomial, *Gaussian radial basis function* (RBF), dan sigmoid. Fleksibilitas ini memungkinkan SVM untuk menangani berbagai jenis data dan pola yang kompleks.

2.3.4 CNN-SVM

Hybrid CNN-SVM menggabungkan kemampuan *feature extraction* mendalam dari *Convolutional Neural Network* (CNN) dengan kekuatan klasifikasi *Support Vector Machine* (SVM). Pada pendekatan ini, CNN berperan sebagai *feature extraction* dengan memanfaatkan *layer convolution* Untuk menangkap representasi hierarkis citra, sementara SVM digunakan sebagai *classifier* akhir yang bekerja pada fitur yang telah diekstraksi. Arsitektur CNN *pre-trained* umumnya dimodifikasi dengan menghapus *layer fully connected* terakhir, sehingga *output* dari *layer global average pooling* atau *layer convolution* akhir diambil sebagai vektor fitur berdimensi tinggi. Fitur ini kemudian menjadi input untuk SVM yang menggunakan kernel untuk memetakan data ke ruang berdimensi lebih tinggi dan menemukan *hyperplane* optimal pemisah kelas. Keunggulan *hybrid* ini terletak pada efisiensi komputasi dan peningkatan akurasi, terutama pada dataset kecil, di mana SVM cenderung lebih stabil daripada *layer fully connected CNN* [34].

2.3.5 Confusion Matrix

Dalam evaluasi kinerja model klasifikasi, *confusion matrix* digunakan sebagai alat. Untuk mewakili hasil dari klasifikasi model, digunakan tabel dalam bentuk *matrix* yang membandingkan model prediksi dengan kelas aktual pada data yang diuji. *confusion matrix*

terdiri dari empat komponen utama. Dalam klasifikasi, *confusion matrix* bertujuan untuk meminimalkan jumlah FP dan FN sekaligus memaksimalkan jumlah TP dan TN. Istilah TP mewakili jumlah contoh positif yang diprediksi dengan benar. TN menunjukkan jumlah kejadian negatif yang diprediksi secara akurat. FP terdiri dari contoh-contoh positif yang salah diklasifikasikan. Terakhir, FN mewakili contoh negatif yang diberi label salah. Dalam menggunakan *confusion matrix*, penghitungan *matrix* evaluasi seperti *Accuracy*, *Precision*, *Recall*, *F1-score* diperlukan untuk memancarkan keefektifan klasifikasi model dalam mengidentifikasi berbagai kelas dengan baik [35].

Kontribusi yang sangat penting dari *confusion matrix* dalam pemahaman kinerja klasifikasi model adalah memberikan gambaran yang jelas tentang keefektifan model tersebut dalam mengklasifikasikan data, terutama jika ada ke integrasi antara kelas-kelas yang berbeda di dalam dataset. Mengacu pada *confusion matrix*, dapat dilakukan identifikasi model tren dalam melakukan kesalahan spesifik, seperti memberikan prediksi yang lebih sering salah pada satu kelas dibandingkan yang lain. Hal ini memberi gambaran tindakan perbaikan yang perlu dilakukan untuk meningkatkan kinerja model tersebut [35].

2.3.5.1 Accuracy

Accuracy pada *Confusion Matrix* adalah *matrix* yang mengukur tingkat kesesuaian antara prediksi model dan data aktual dalam klasifikasi. Ini dihitung dengan membagi jumlah prediksi yang benar (*True Positives* dan *True Negatives*) dengan jumlah *total instance* atau sampel dalam dataset.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} * 100\%$$

Rumus 2.1 Rumus *Accuracy* [36]

2.3.5.2 Precision

Precision pada *Confusion Matrix* adalah *matrix* yang mengukur sejauh mana prediksi positif yang dihasilkan oleh model klasifikasi adalah benar positif. Ini dihitung dengan membagi jumlah *True Positives* dengan jumlah *True Positives* dan *False Positives*.

$$Precision = \frac{TP}{TP + FP} * 100\%$$

Rumus 2.2 Rumus *Precision* [36]

2.3.5.3 Recall

Recall pada *Confusion Matrix* adalah *matrix* yang mengukur kemampuan model klasifikasi untuk mengidentifikasi semua *instance* yang sebenarnya positif dalam dataset. Ini dihitung dengan membagi jumlah *True Positives* dengan jumlah *True Positives* dan *False Negatives*.

$$Recall = \frac{TP}{TP + FN} * 100\%$$

Rumus 2.3 Rumus *Recall* [36]

2.4 Tools / Software Penelitian

2.4.1 Google Colaboratory

Google Colaboratory, atau sering disebut Google Colab, adalah platform berbasis *cloud* yang disediakan oleh Google untuk pemrograman Python, khususnya dalam penerapan machine learning dan deep learning. Menggunakan Google Colab, pengguna dapat menulis dan mengeksekusi kode Python melalui *notebook* Jupyter yang berjalan di *server* Google. Hal ini memungkinkan pemrosesan dilakukan tanpa memerlukan konfigurasi perangkat keras lokal yang

canggih, karena Colab menyediakan akses ke CPU, GPU, dan TPU yang dapat digunakan secara gratis. Selain itu, Colab telah dilengkapi dengan berbagai pustaka seperti Keras, TensorFlow, NumPy, dan Pandas, memudahkan pengguna dalam mengembangkan dan menguji model *machine learning* [37].

2.4.2 Python

Python adalah bahasa pemrograman yang sangat fleksibel karena kemampuannya menangani tugas-tugas seperti pengembangan perangkat lunak, pemrograman *website*, analisis data, *Artificial Intelligence*, dan banyak lagi. Ini sangat populer di kalangan pemula karena memahami sintaksisnya. Fokus pada penulisan kode yang jelas. Python menawarkan berbagai modul dan perpustakaan termasuk *TensorFlow* dan *scikit learning* untuk *machine learning* serta *Django* dan *Flask* untuk pengembangan *website*. Fitur-fitur ini menjadikannya pilihan pilihan bagi pengembang di industri. Komunitas Python besar dan aktif memberikan banyak dukungan dan sumber belajar yang beragam, menjadikannya bahasa yang sangat populer di dunia pemrograman [38].

2.4.3 Borealis Data

Borealis Data adalah *platform repository* yang bersifat *open data repository* yang dikembangkan untuk mendukung kolaborasi riset, transparansi, dan keberlanjutan akses data ilmiah. *Platform* ini merupakan bagian dari ekosistem *Dataverse*, sebuah infrastruktur perangkat lunak yang memungkinkan untuk menyimpan, mengelola, membagikan, dan mengutip dataset secara terstruktur. Borealis dirancang untuk memenuhi prinsip FAIR (*Findable, Accessible, Interoperable, Reusable*), dengan fitur seperti metadata terstandar seperti Dublin Core dan DataCite, kontrol akses granular seperti publik, terbatas atau privat. Serta integrasi dengan sistem identifikasi

digital seperti DOI dan ORCID. Awalnya diluncurkan oleh *Canadian Association of Research Libraries* (CARL), Borealis digunakan oleh universitas dan lembaga riset di Kanada untuk mendukung kebijakan data terbuka dan tata kelola data penelitian [39]. Contoh penggunaannya mencakup penyimpanan data sensus, hasil eksperimen laboratorium, dan dataset ilmu sosial yang kompleks.

2.4.4 Streamlit

Streamlit adalah sebuah *framework open-source* berbasis Python yang digunakan untuk membangun UI berbasis *web* dengan cepat dan sederhana, terutama untuk kebutuhan *data science* dan *machine learning*. Dengan sintaksis yang minimal dan intuitif, Streamlit memungkinkan para pengembang menampilkan hasil analisis, visualisasi data, serta interaksi model secara *real-time* tanpa perlu menguasai pengembangan *web* secara mendalam. Streamlit mendukung integrasi langsung dengan berbagai *library* populer seperti NumPy, Pandas, Matplotlib, dan TensorFlow, sehingga memudahkan proses *deployment* aplikasi analitik atau sistem prediksi ke dalam *platform* yang dapat diakses oleh pengguna secara luas [40].

UMMN

UNIVERSITAS
MULTIMEDIA
NUSANTARA