

BAB II

KAJIAN PUSTAKA

2.1 Tinjauan Pustaka

Dalam penelitian yang telah dilakukan yaitu model CNN dapat diinterpretasikan dan disajikan untuk analisis data inframerah. Pendekatan berbasis regresi linier seperti *Ascending Stepwise Linear Regression* (ASLR) dimanfaatkan untuk mengekstraksi informasi *neuron* di lapisan rata dari model yang dilatih. Karakteristik jaringan CNN digunakan untuk memvisualisasikan variabel aktif sesuai dengan *neuron* yang diekstraksi. Pengulangan model CNN dan strategi yang diusulkan diverifikasi dengan melakukan validasi silang Monte dan Carlo (Xia dkk., 2022). Integrasi CNN (untuk ekstraksi ciri kompleks) dan SVM (untuk klasifikasi akhir) dapat meningkatkan keakurasian sistem deteksi kesehatan ayam. Keunggulan lain adalah penggunaan citra RGB dan inframerah secara bersamaan dapat memberikan informasi lebih komprehensif dibanding penelitian terdahulu yang hanya menggunakan satu spektrum (Supriyanto dkk., 2023). Dengan menggabungkan spektrum inframerah dekat (*Near-Infrared/NIR*) portabel dan algoritma klasifikasi dikembangkan menjadi metode yang dapat untuk menguji keaslian daging ayam. Penelitian ini menghasilkan kemampuan dalam membedakan daging segar atau daging yang dicairkan, berdasarkan spektrum NIR (Parastar dkk., 2020). Penyakit yang sering menyerang ayam seperti flu burung (*Avian Influenza/AI*) dan pencegahannya merupakan fokus penelitian ilmiah dari industri ayam. Dalam penelitian ini, metode pengenalan suara baru, jaringan saraf konvolusional suara ayam (*Chicken Sound Convolutional Neural Network/CSCNN*) telah diusulkan dalam deteksi ayam yang terkena flu burung (Cuan dkk., 2020).

Metode CNN juga digunakan dalam pemantauan distribusi spasial ayam tanpa sekat dalam kandang. Distribusi spasial ayam dalam berkelompok atau berkumpul di kandang merupakan salah satu indikator kondisi kesehatan ayam. Ruang kandang yang lebih besar memungkinkan ayam melakukan perilaku alami

seperti mandi debu, mencari makan, dan bertengger di dalam tanpa sekat. Tantangan yang ada adalah cara evaluasi pergerakan ayam dan distribusi spasial. Jika pemeriksaan manual terhadap distribusi spasial ayam akan memakan banyak tenaga, memakan waktu, rentan terhadap kesalahan manusia, dan menyebabkan stres ayam. Oleh karena itu, diperlukan sistem pemantauan otomatis untuk melacak sebaran spasial ayam secara dini untuk deteksi masalah kesehatan hewan. Dalam penelitian ini, metode visi mesin non-intrusif dikembangkan untuk memantau distribusi spasial ayam secara otomatis. YOLOv5 dikembangkan untuk menguji sebaran spasial ayam meliputi zona bertengger, zona makan, zona minum, dan zona bersarang. Dataset berisi seluruh periode pertumbuhan ayam dari hari ke dan 1 hingga hari ke dan 252. Terdapat 3000 citra diekstraksi secara acak dari rekaman video untuk pelatihan model, validasi, dan pengujian. Sebanyak 2400 citra digunakan untuk pelatihan dan 600 citra untuk pengujian. Hasil menunjukkan bahwa keakuratan model baru ini mencapai 87-94% untuk melacak distribusi di zona yang berbeda untuk berbagai usia ayam. Usia ayam mempengaruhi kinerja model karena ayam yang lebih muda memiliki ukuran tubuh yang lebih kecil dan cenderung sulit dideteksi karena keterbatasan peralatan. Kinerja model adalah 0,891-0,942 untuk anak ayam (umur ≤ 10 hari) dan ayam dewasa (> 10 hari) dalam mendeteksi perilaku bertengger; 0,874-0,932 dalam mendeteksi perilaku makan/minum. Deteksi kesalahan terjadi ketika kepadatan kawanan tinggi (> 18 ekor/m²) dan tubuh ayam terhalang oleh fasilitas lain (kotak sarang, tempat makan, dan tempat bertengger). Penelitian lebih lanjut seperti identifikasi perilaku ayam dalam sistem kandang komersial harus dikombinasikan dengan model untuk mencapai sistem deteksi otomatis (Yang dkk., 2023).

Pengembangan sistem peringatan otomatis terhadap penyebaran ayam yang anomali dan gerakan dapat digunakan pembelajaran mendalam dan pembelajaran mesin. Pendekatan yang diusulkan dapat berfungsi sebagai solusi untuk pemantauan otomatis terhadap penyebaran ayam yang anomali dan gerakan dalam peternakan ayam, memperingatkan para peternak potensi risiko kesehatan dan bahaya lingkungan di peternakan ayam (Chen dkk., 2023). Deteksi dan analisis perilaku ayam serta prediksi status kesehatan ayam dikembangkan model YOLOv5

dan *Convolutional Block Attention Module* (CBAM). Model terdiri dari dua bagian yaitu pertama model dasar YOLOv5 untuk ekstraksi ciri ayam pedaging dan deteksi objek serta CBAM untuk meningkatkan kemampuan ekstraksi ciri jaringan dan masalah deteksi dengan target kecil. Secara keseluruhan, model ayam pedaging YOLOv5 dan CBAM yang diusulkan dapat mencapai akurasi dan waktu nyata deteksi target yang cepat dan memberikan dukungan teknis untuk pengelolaan dan pemantauan ayam pedaging di kandang komersial (Xu dkk., 2020).

Metode YOLO juga digunakan dalam pengenalan keadaan ayam yang dipingsankan dan metode ini menjadi isu penting dalam industri ayam. Peminganan bertujuan untuk membuat ayam tidak peka terhadap rasa sakit sebelum disembelih. Metode pengenalan seperti jaringan saraf semakin mendapat perhatian karena kemampuan dan manfaat yang besar dalam akurasi diagnostik dan implementasi yang mudah. Untuk meningkatkan akurasi dan efisiensi pengenalan status ayam pedaging yang pingsan digunakan YOLO dengan *Multilayer Residual Module* (MRM) dalam pengenalan tiga keadaan pingsan pada ayam pedaging seperti tidak cukup, cukup dan berlebihan (Yu dkk., 2020).

Teknik pembelajaran mendalam juga digunakan dalam deteksi dan klasifikasi terhadap penyakit unggas berbasis ponsel pintar berdasarkan kotoran ayam. Sistem ini dikembangkan menggunakan dua algoritma inti seperti algoritma deteksi objek YOLO dan V3 dan ResNet50 untuk klasifikasi citra. YOLO dan V3 digunakan untuk segmentasi *region of interest* (ROI) dari citra feses, sedangkan ResNet50 digunakan untuk klasifikasi citra tersegmentasi menjadi empat kondisi kesehatan yaitu kesehatan, koksidiosis, salmonella, dan penyakit *New Castle Disease* (NCD). Sistem ini terbukti menjadi alat yang berharga untuk membantu peternak ayam dan dokter hewan (Degu dan Simegn, 2023).

Pengklasifikasi otomatis untuk memantau perilaku penerapan peletakan tanpa sekat kandang ayam dengan pembelajaran mendalam. Perilaku ayam merupakan indikator penting mengenai kesehatan, dan kinerja produksi. Pada penelitian-penelitian sebelumnya, sebagian besar penelitian ayam berfokus pada perilaku dasar seperti minum, memberi makan, dan aktivitas gerakan ayam pedaging. Namun, dengan adanya peralihan ke kandang tanpa sekat, jumlah

tersebut menjadi lebih banyak sehingga perilaku alami perlu dipantau kesehatan ayam. Klasifikasi enam perilaku (makan, minum, berjalan, hinggap, mandi debu, dan bersarang) dikembangkan berdasarkan beberapa model CNN (EfficientNetV2 dan YOLOv5). Kinerja YOLOv5 mencapai akurasi rata-rata 95,3%, berarti 5,01% lebih tinggi dibandingkan EfficientNetV2 dan I. Perilaku minum anak ayam dipantau paling tinggi akurasi (97,8%), sedangkan perilaku bersarang memiliki presisi deteksi 92,5%. Dilihat dari umur ayam, akurasi lebih baik untuk anak ayam yang lebih kecil (<10 hari) dibandingkan ayam yang lebih besar berumur lebih dari 10 hari (96,4% vs 94,3%). Hasil klasifikasi berguna untuk memisahkan perilaku ayam dalam kandang tanpa sekat dalam berbagai perilaku periode kehidupan dan lingkungan (Yang dkk., 2023). Estimasi pose yang akurat merupakan dasar dalam analisis perilaku unggas, dan sebagai peringatan ayam pedaging sehat atau sakit. Estimasi pose berdasarkan jaringan syaraf mendalam (*deep neural network/DNN*) diterapkan untuk analisis perilaku ayam pedaging. Kerangka pose dibangun titik ciri ayam, kemudian dilacak bagian tubuh tertentu. Model bayesian digunakan untuk mengklasifikasikan dan identifikasi pose ayam pedaging (Fang dkk., 2021). Teknik visi komputer pada citra resonansi magnetik untuk klasifikasi non-destruktif dan prediksi kualitas dada ayam terkena miopati *White dan Striping* (WS). Ciri komputasi dari kedua tekstur algoritma (GLCM) dan fraktal (OPFTA) berguna untuk klasifikasi dada ayam. Prediksi fisika dan kimia karakteristik dada ayam tersebut menerapkan regresi linier berganda (Batista dkk., 2021).

Namun semua penerapan metode pengolahan citra, *machine learning*, *reasoning*, dan optimalisasi tersebut pada citra inframerah dan citra RGB masih terbatas. Saat ini belum ditemukan penelitian yang melakukan klasifikasi kondisi kesehatan berdasarkan citra inframerah badan ayam apakah kondisi normal, tidak normal dan kondisi mati, sehingga peluang penelitian ini masih terbuka. Selain itu, integrasi metode pengolahan citra dan pembelajaran mesin untuk klasifikasi citra kurang efisien apabila dibandingkan dengan metode CNN yang mampu menangani sendiri pekerjaan klasifikasi citra dari awal hingga akhir. Salah satu contoh metode CNN digunakan untuk mendeteksi bidang bayangan awan dalam citra satelit multi dan saluran dari *World-View-2* (WV-2) dan *Sentinel-2* (S-2), menggunakan citra

RGB, dan citra dekat inframerah c sehingga memungkinkan pengolahan data yang lebih efisien atau cepat namun tetap akurat.

Metode *Support Vector Machine/SVM* dikenal luas sebagai metode klasifikasi yang efektif dan telah dibuktikan kinerja unggul dalam beragam aplikasi. Namun, untuk masalah klasifikasi pola skala besar, hal ini membutuhkan banyak memori dan biaya komputasi mahal (Wang dan Shao, 2024). Binerisasi citra dokumen sejarah yang terdegradasi dapat menggunakan lokal ciri dan SVM. Seluruh citra dibinarisasi lebih lanjut dengan metode ambang batas adaptif lokal (Xiong dkk., 2023). Dalam bidang kesehatan, keanekaragaman bakteri terungkap melalui pelacakan sumber kontaminasi tinja dengan menerapkan algoritma SVM. Urutan diskriminatif dipilih dari kelompok bakteri Clostridiales, Bacteroidales, atau Lactobacillales menggunakan pohon yang acak. Akurasi keseluruhan model SVM dan model RF pada sampel lokal adalah 96,08% - 98,04%, masing-masing lebih tinggi dibandingkan Adaboost (90,20%). Hasil menunjukkan bahwa SVM adalah metode yang hemat waktu dan akurat dalam pelacakan sumber mata air yang terkontaminasi (Tan dkk., 2021).

Pengklasifikasi pembelajaran mesin *Machine Learning* (ML) dapat memberikan solusi terhadap kesulitan budidaya ikan. Penelitian ini menyelidiki parameter fisika dan kimia air yang berpotensi menyebabkan wabah penyakit akibat bakteri di budidaya ikan. Empat algoritma ML yaitu SVM, Naive Bayes (NB), Random Forest (RF), dan K-Nearest Neighbour (KNN) digunakan untuk deteksi parameter fisika dan kimia air. Pengklasifikasi SVM dan RF memberikan hasil yang akurat (100% untuk keduanya), sedangkan pengklasifikasi KNN dan NB mencapai akurasi 91,3% (Çakir dkk., 2023).

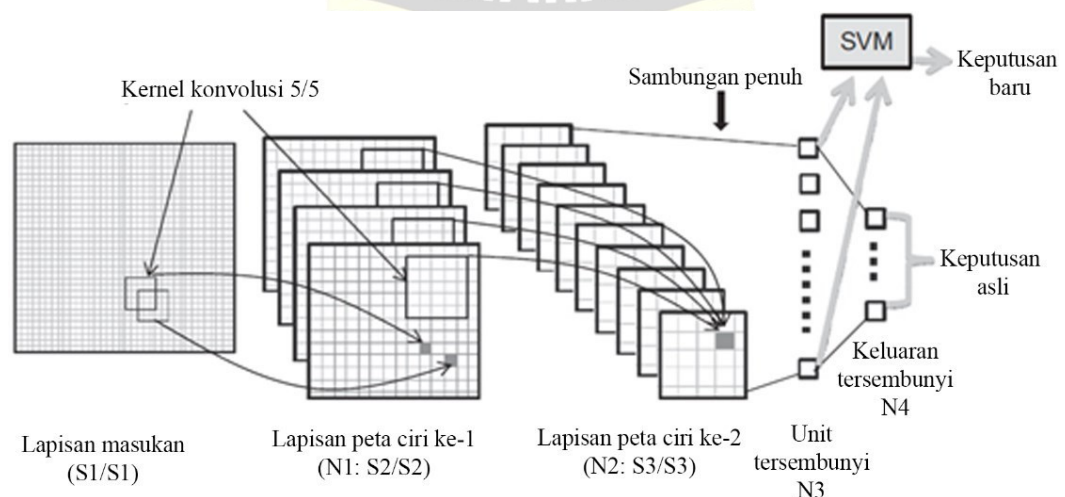
Penelitian lain, SVM dan klasifikasi *fuzzy* dalam pembelajaran mesin digunakan untuk segmentasi tumor otak citra MR. SVM merupakan salah satu algoritma klasifikasi dua kelas. Karakteristik yang diekstraksi dari setiap citra dikirim ke pelatihan SVM multi kelas yang membangun struktur SVM. Pengklasifikasi kode keluaran menyederhanakan klasifikasi kelas jamak masalah ke pengklasifikasi biner sederhana (Vankdothu dan Hameed, 2022). Penelitian lain

untuk deteksi cepat biomarker serologis pada karsinoma kandung empedu digunakan spektroskopi inframerah transformasi fourier dikombinasikan dengan pembelajaran mesin (Dou dkk., 2023).


Model penggabungan CNN dengan SVM didasarkan pada masing - masing kelebihan dan kekurangan dari kedua model tersebut. CNN telah terbukti sebagai metode yang paling kuat dan representatif untuk mengolah data citra yang umumnya berukuran besar dan beragam. Namun CNN juga memiliki kelemahan pada data yang berukuran kecil. Model *Vision Transformer* (ViT) secara teori dapat menghasilkan kinerja sangat tinggi dalam klasifikasi citra, namun arsitektur tersebut sangat bergantung pada jumlah data besar karena tidak memiliki inductive bias seperti CNN dalam hal translasi dan lokalitas. Dengan dataset terbatas, ViT cenderung mengalami *overfitting* dan membutuhkan regularisasi tambahan serta komputasi yang jauh lebih intensif.

Sementara itu, metode *ensemble learning* seperti Random Forest, Gradient Boosting, atau *stacking* beberapa model *deep learning* juga membutuhkan sumber daya komputasi yang besar serta proses pelatihan yang kompleks. Berbeda dengan itu, DenseNet201 menawarkan keunggulan berupa aliran gradien yang stabil melalui *dense connectivity* sehingga efektif untuk dataset terbatas, sedangkan SVM terbukti unggul dalam memisahkan kelas pada ruang ciri berdimensi tinggi hasil ekstraksi CNN. Keunggulan ini selaras dengan penelitian-penelitian sebelumnya yang menunjukkan bahwa gabungan CNN-SVM dapat mengungguli CNN murni atau model *ensemble* pada dataset kecil hingga menengah. Karena itu, pemilihan DenseNet201 dan SVM merupakan keputusan metodologis yang lebih tepat dibandingkan menggunakan *Vision Transformer* atau *ensemble learning* pada kasus penelitian ini. Oleh karena itu, pendekatan *pre-trained* yang mampu menyediakan data secara lengkap dan besar dapat diterapkan pada CNN (Hameed dkk., 2018). CNN membutuhkan ketersediaan dataset yang sangat besar. Cara lain dan mudah untuk mengatasi permasalahan keterbatasan dataset adalah dengan menerapkan pendekatan augmentasi data pada CNN untuk memperkaya keragaman data. Sedangkan masalah kelas tak seimbang yang umum terjadi pada data dapat ditangani secara sederhana menggunakan pendekatan kelas terbobot (Moola dkk.,

2021). Walaupun demikian, proses pelatihan CNN yang kompleks tentu saja masih membutuhkan waktu yang lama. Cara mudah untuk memanfaatkan kekuatan CNN tanpa menginvestasikan waktu untuk pelatihan adalah dengan memanfaatkan model CNN hanya untuk ekstraksi ciri (Simonyan dan Zisserman, 2015b). Namun cara ini harus menggunakan metode pengklasifikasi yang lebih unggul (efisien dan akurat) daripada CNN, karena CNN sendiri mampu pula berperan sebagai pengklasifikasi. Oleh karena itu, SVM yang unggul dalam mengolah data yang berdimensi kecil dengan *instance* yang jauh lebih besar (Santoso dkk., 2020a), juga telah terbukti lebih unggul dari metode pengklasifikasi kesehatan ayam berdasarkan citra postur 2D (Okinda dkk., 2019), tepat digunakan sebagai pengklasifikasi dengan memanfaatkan *flatten/vector feature* yang berdimensi kecil yang dihasilkan dari *fully connected layer* CNN. Beberapa penelitian sebelumnya telah menerapkan pengolahan citra dan penggabungan CNN dan SVM di berbagai bidang. Gambar 2.1 memperlihatkan struktur hibrid model CNN dan SVM dalam melakukan prediksi angka berdasarkan citra hasil tulisan tangan. Prediksi tulisan tangan angka dengan memanfaatkan CNN untuk ekstraksi ciri dan SVM untuk prediksi keluaran telah menghasilkan akurasi sebesar 99,81% tanpa penolakan, dan 94,40% dengan penolakan (Niu dan Suen, 2012).

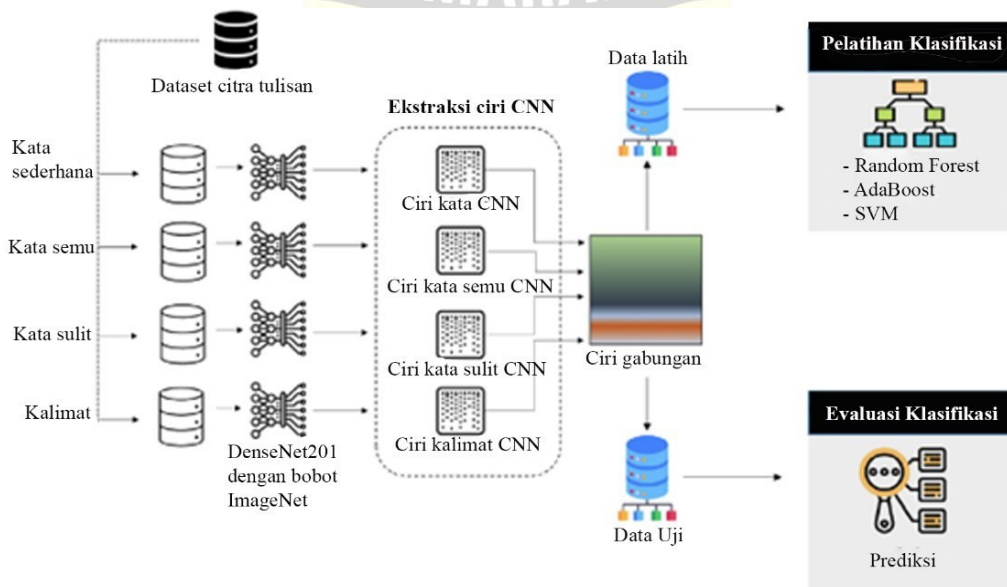


Gambar 2.1 Struktur hibrid model CNN dan SVM (Niu dan Suen, 2012)



Gambar 2.2 Arsitektur CNN dan SVM dengan *dropout* (Ali dan Mallallah, 2022)

Penelitian yang menggunakan arsitektur CNN dan SVM dengan *dropout* yang ditunjukkan seperti pada Gambar 2.2 digunakan untuk pengenalan teks dalam aksara Arab tulisan tangan dengan hasil akurasi klasifikasi CNN dan SVM lebih tinggi daripada klasifikasi lain dalam proses *training* dan *testing* (Ali dan Mallallah, 2022).

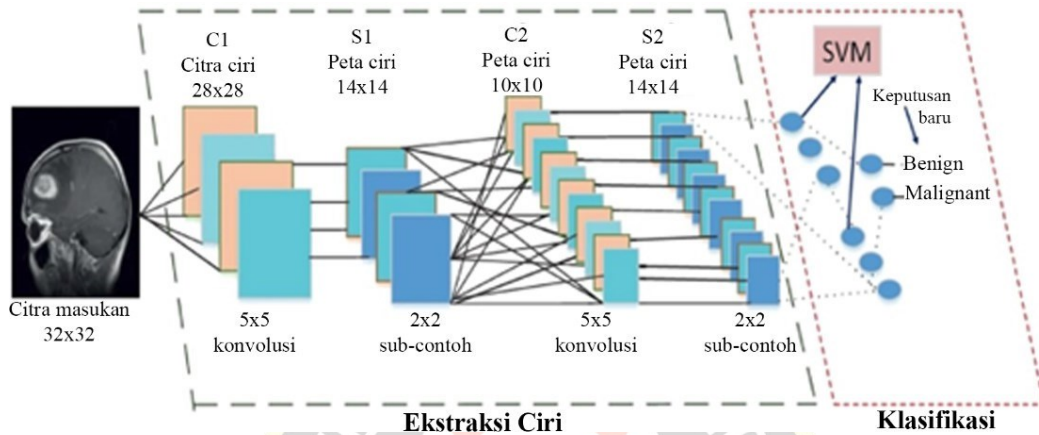


Gambar 2.3 Gambaran proses fusi ciri CNN dan pengklasifikasi RF, AdaBoost dan SVM tujuan khusus citra tulisan tangan (Kunhot dkk., 2023).

Proses fusi ciri CNN dan pengklasifikasi Random Forest, AdaBoost dan SVM digunakan untuk penelitian dengan tujuan khusus citra tulisan tangan seperti diperlihatkan pada Gambar 2.3. Prediksi citra tulisan tangan disgrafia juga menggunakan CNN (DenseNet201) digabungkan dengan 3 (tiga) jenis pembelajaran mesin yaitu SVM, AdaBoost, dan Random Forest dengan hasil bahwa model CNN (DenseNet201) dengan SVM tercapai akurasi tertinggi sebesar 91,7% dan jika ditambahkan fusi ciri akurasi mencapai 97,3% (Kunhoth dkk., 2023). Penerapan lain penggabungan CNN dan SVM digunakan dalam penelitian pendeteksian sabuk pengaman dalam sistem transportasi berdasarkan citra tangkapan kamera pengawasan jalan. Deteksi ini menggunakan model CNN *post-processing* menggunakan skor deteksi klasifikasi SVM. Hasil yang diperoleh adalah akurasi deteksi menggunakan CNN saja mencapai 80%, namun penggabungan CNN dan SVM mencapai akurasi 87% (Chen dkk., 2018).

Pada bidang kesehatan, model CNN dan SVM untuk mendeteksi dan klasifikasi tumor otak berdasarkan citra hasil *magnetic resonance imaging* (MRI). Citra MRI otak akan diklasifikasi dengan mempertimbangkan keunggulan CNN pada kumpulan data publik untuk mengklasifikasikan tumor jinak dan ganas. Akurasi dengan *Rough Extreme Learning Machine* (RELM):94,233%, *Deep CNN* (DCNN):95%, *Deep Neural Network* (DNN) dan *Autoencoder Wavelet Diskrit* (DWA) :96%, *K* dan *Nearest Neighbors* (KNN):96,6%, CNN:97,5%. Model hibrid yang diusulkan menggabungkan CNN-SVM untuk klasifikasi dan segmentasi berbasis ambang batas untuk deteksi. Model hibrid CNN- SVM ini memberikan teknik yang lebih efektif dan perbaikan klasifikasi. Akurasi tertinggi keseluruhan dari hibrid CNN SVM dapat mencapai 98,4959% (Khairandish dkk., 2022). Model-model hibrid tersebut menunjukkan bahwa integrasi CNN dengan pengklasifikasi konvensional mampu meningkatkan generalisasi dalam berbagai domain tugas visual. Selain itu, pendekatan multimodel ini memberikan fleksibilitas dalam memanfaatkan kekuatan ekstraksi ciri mendalam CNN dan kemampuan pemisahan kelas SVM yang lebih optimal pada ruang ciri berdimensi tinggi. Dengan demikian, strategi fusi seperti ini semakin relevan untuk diterapkan pada sistem cerdas yang


membutuhkan akurasi tinggi dan robust terhadap variasi data. Struktur hibrid CNN dan SVM ini seperti ditunjukkan pada Gambar 2.4.




Gambar 2.4 Struktur hibrid CNN dan SVM (Khairandish dkk., 2022)

Pengklasifikasi yang umum digunakan untuk pengenalan pola gerakan manusia, seperti *back propagation neural network* (BPNN) dan SVM, biasanya menerapkan klasifikasi dengan mengekstraksi beberapa ciri buatan tangan dari isyarat biologis manusia. Ciri ini umumnya memerlukan pengetahuan lebih dan membutuhkan waktu lama untuk diuji serta dipilih untuk kinerja klasifikasi tinggi. Sebaliknya CNN telah banyak diterapkan pada visi komputer yang mampu mengekstraksi ciri dari data pelatihan melalui konvolusi dan *subsampling*, tetapi CNN perlu data contoh yang besar serta terdapat masalah *overfitting*. Di sisi lain, SVM memiliki kemampuan generalisasi dan dapat memecahkan masalah contoh kecil. Oleh karena itu, model gabungan CNN-SVM untuk dimanfaatkan kelebihan masing-masing dalam mendeteksi isyarat mekanomiografi mulai otot paha dan memasukkan dalam bentuk isyarat deret waktu ke model gabungan CNN dan SVM untuk pengenalan pola gerakan lutut. Dibandingkan dengan pengklasifikasi umum melakukan klasifikasi, model gabungan CNN dan SVM dapat secara otomatis mengekstraksi ciri menggunakan CNN, untuk meningkatkan kemampuan klasifikasi dilakukan dengan cara menggabungkan bersama SVM. Model CNN dan SVM dapat mencapai akurasi 94,04% dibandingkan CNN saja sebesar $88,45 \pm 2,79\%$ (Wu dkk., 2018). Pendekatan hibrid ini juga menunjukkan bahwa integrasi kedua metode mampu mengurangi ketergantungan pada rekayasa ciri manual yang

selama ini menjadi keterbatasan utama pada pengklasifikasi tradisional. Dengan demikian, kombinasi CNN–SVM memberikan solusi yang lebih adaptif dan efisien dalam memproses sinyal biologis yang kompleks dan bervariasi. Arsitektur dan proses implementasi dari model kombinasi CNN dan SVM ditunjukkan seperti pada Gambar 2.5 dan Gambar 2.6.



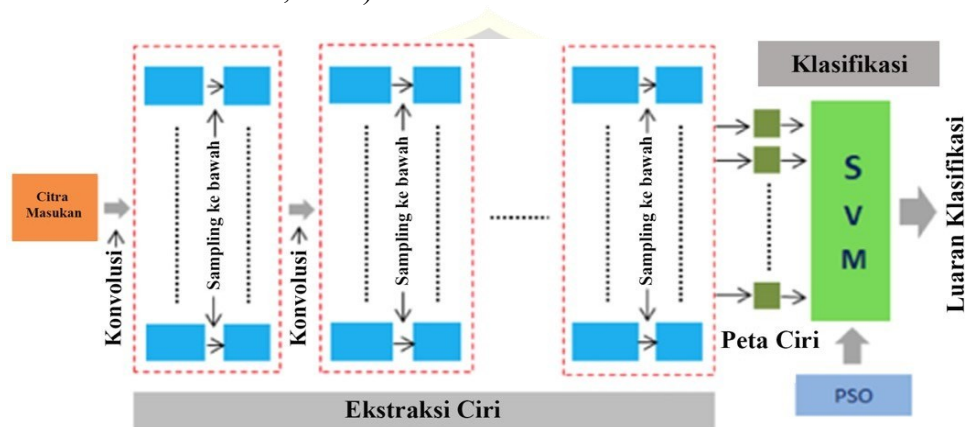
Gambar 2.5 Arsitektur model kombinasi CNN dan SVM (Wu dkk., 2018)



Gambar 2.6 Implementasi model kombinasi CNN dan SVM (Wu dkk., 2018)

Model yang diusulkan *Particle Swarm Optimized* (PSO) 1-Dimensi CNN dengan arsitektur SVM (1 -D CNN-SVM) digunakan untuk deteksi dan klasifikasi waktu nyata penyakit. Kinerja arsitektur yang diusulkan divalidasi dengan model perangkat keras baru untuk mendeteksi penyakit ginjal kronis (*Chronic Kidney Disease/CKD*) dari sampel air liur. Untuk mendeteksi CKD, konsentrasi urea dalam contoh air liur dipantau dan diubah menjadi amonia. Urea dihidrolisis dengan enzim urease menghasilkan amonia. Amonia ini kemudian diukur menggunakan sensor gas berbahan semikonduktor. Tanggapan sensor diberikan kepada arsitektur yang diusulkan untuk ekstraksi ciri dan klasifikasi. Kinerja arsitektur dioptimalkan dengan mengatur nilai parameter menggunakan algoritma PSO. Arsitektur yang diusulkan berkinerja lebih baik dari metode konvensional saat ini, karena

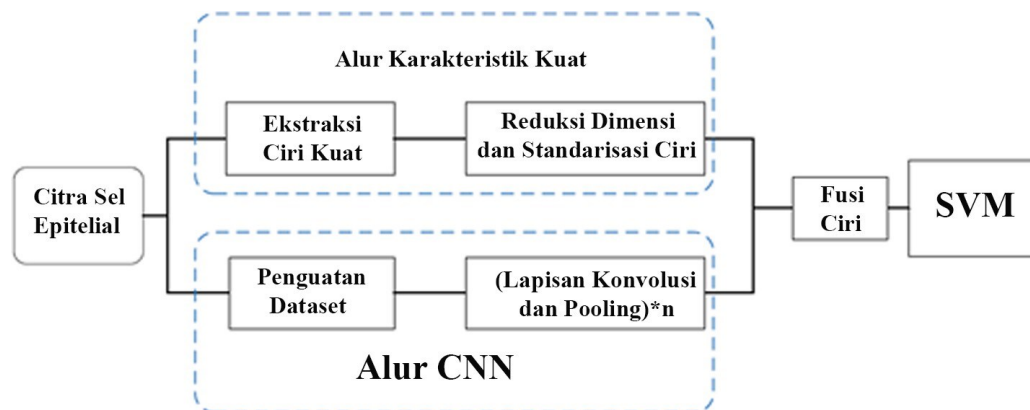
pendekatan ini merupakan kombinasi ekstraksi ciri dan teknik klasifikasi yang kuat. Proses ekstraksi ciri dilakukan secara langsung dari isyarat awal, yang bertujuan untuk mengurangi waktu komputasi dan kompleksitas. Arsitektur yang diusulkan telah mencapai akurasi 98,25%. Model 1D CNN-SVM seperti diperlihatkan pada Gambar 2.7 yang digunakan untuk deteksi dan klasifikasi waktu nyata penyakit (Navaneeth dan Suchetha, 2019).



Gambar 2.7 Arsitektur 1-D CNN dan SVM dengan *Particle Swarm Optimized* (PSO) (Navaneeth dan Suchetha, 2019)

Skринing tradisional sel serviks sangat bergantung pada pengalaman ahli patologi yang juga memiliki masalah akurasi rendah dan efisiensi buruk. Pengolahan citra medis menggabungkan *deep learning* dan pembelajaran mesin untuk mendapat keunggulan dalam bidang klasifikasi sel. Diagram topologi model CNN dan SVM berbasis ciri kuat ditunjukkan pada Gambar 2.8. dengan kerangka kerja baru berdasarkan ciri kuat model hibrid CNN dan SVM diusulkan untuk mengklasifikasikan sel dan sel serviks secara akurat. Selain itu, dalam penelitian ini telah dilakukan metode penggabungan ciri kuat yang diekstraksi dengan *Gray dan Level Co dan occurence Matrix* (GLCM) dan Gabor dengan ciri - ciri abstrak dari lapisan tersembunyi CNN, sedangkan ciri-ciri yang telah digabungkan dimasukkan ke dalam SVM untuk klasifikasi. Metode penguatan dalam kumpulan data yang efektif dirancang untuk meningkatkan ketahanan model. Metode yang diusulkan akan dievaluasi pada dua kumpulan data bebas dengan pengukuran kinerja berupa akurasi (Acc), sensitivitas (Sn), dan spesifisitas (Sp). Pendekatan ini mengungguli

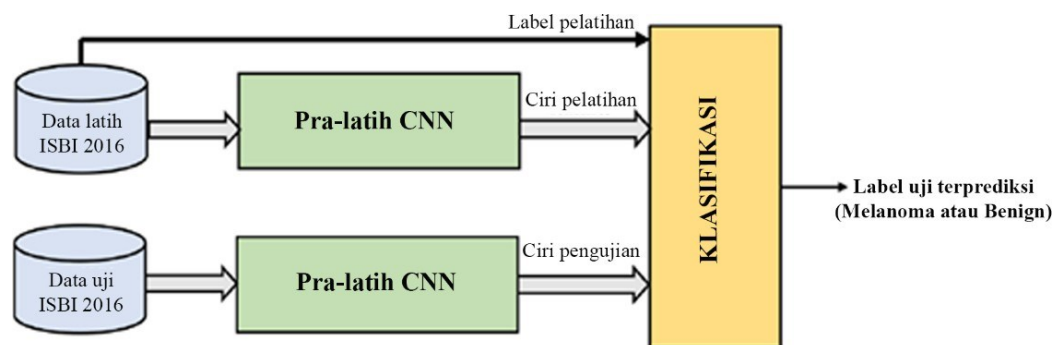
model canggih dengan Acc, Sn, dan Sp sebesar 99,3%; 98,9%; 99,4% untuk deteksi 2 kelas secara massal. Hasil model ini menunjukkan bahwa ciri kuat model CNN dan SVM dapat diterapkan dalam klasifikasi sel untuk skrining dini kanker serviks (Jia dkk., 2020).




Gambar 2.8 Diagram topologi model CNN-SVM berbasis ciri kuat (Jia dkk., 2020)

Penelitian bidang kesehatan lain yang memanfaatkan model CNN-SVM juga digunakan untuk membantu dokter kulit yang banyak menggunakan citra dermoskopi digital dalam pendeteksian melanoma. Namun demikian, deteksi melanoma oleh dokter masih bersifat subjektif dan tergantung pengalaman yang ada. Sistem diagnosis otomatis berbasis komputer diperlukan untuk menghilangkan variabilitas antar operator yang melekat dalam analisis citra dermoskopi. Penelitian ini bertujuan untuk klasifikasi lesi pada permukaan kulit secara otomatis. Penelitian ini mengusulkan dua model CNN hibrid baru dengan pengklasifikasi SVM pada lapisan keluaran untuk klasifikasi citra dermoskopi menjadi lesi jinak atau melanoma. Ciri yang diekstraksi oleh CNN pertama dan model CNN kedua digabungkan kemudian dimasukkan ke SVM untuk proses klasifikasi. Label yang diperoleh dari ahli kulit digunakan sebagai acuan untuk evaluasi kinerja model yang diusulkan. Hasil model yang diusulkan menunjukkan kinerja yang lebih baik dibandingkan model CNN saja. Model yang diusulkan mencapai akurasi 88,02% dan 87,43%, yang masih lebih tinggi dibandingkan model CNN saja. Kerangka kerja yang diusulkan ini dapat mencapai peningkatan kinerja yang cukup besar

dalam akurasi klasifikasi citra dermoskopi (Keerthana dkk., 2023). Gambar 2.9 memperlihatkan diagram blok kerangka kerja keseluruhan menggunakan pembelajaran mesin, sedangkan Gambar 2.10 memperlihatkan diagram blok model hibrid untuk klasifikasi kanker kulit.



Gambar 2.9 Diagram blok kerangka kerja keseluruhan menggunakan ML (Keerthana dkk., 2023)



Gambar 2.10 Diagram blok model hibrid untuk klasifikasi kanker kulit (Keerthana dkk., 2023)

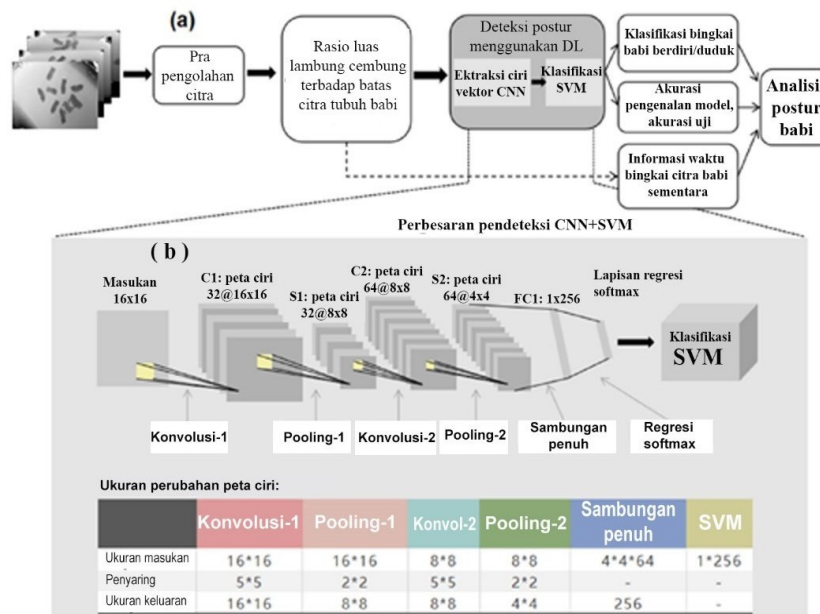
Penelitian lain untuk deteksi kesehatan hewan menggunakan hibrid CNN - SVM berdasarkan citra postur hewan dilatarbelakangi perilaku hewan yang yang dapat digunakan sebagai indikator atau informasi kesehatan, dan kenyamanan lingkungan. Dalam beberapa tahun terakhir, teknologi visi mesin dan pembelajaran mesin telah berkembang dan banyak digunakan untuk mendeteksi perilaku individu atau kelompok babi. Tujuan dari penelitian ini untuk mengenali dan menilai berbagai postur babi (berdiri, duduk, posisi sandaran dada, posisi ventral, dan posisi lateral) berdasarkan kedalaman citra. Dalam penelitian ini, kamera *Azure Kinect DK* dipasang di atas untuk mendapatkan citra babi. Citra target diperoleh dengan segmentasi citra GrabCut dan segmentasi *watershed* kalibrasi objek target. Kemudian berdasarkan ciri-ciri citra diperoleh batas, lambung, jarak bahu dan

pinggul. Rasio keliling lambung cembung terhadap batas dan rasio luas lambung cembung terhadap batas, serta jarak kedalaman bahu dan pinggul, dan rasio jarak bahu ke pinggul diperoleh sebagai masukan dari CNN dan SVM, dan model tersebut dilatih dan diuji.

Di dalam berbagai eksperimen deteksi pengklasifikasi, kinerja pengklasifikasi postur babi untuk postur berdiri dan postur berbaring menyamping lebih baik, dengan area di bawah nilai karakteristik operasi penerima (AUC), masing-masing menjadi 0,9969 dan 0,9967. Namun kinerja postur duduk, postur terlentang buritan dan pengklasifikasi postur terlentang ventral sedikit lebih buruk tetapi masih memiliki kinerja yang baik dengan nilai AUC masing - masing adalah 0,9790; 0,9355 dan 0,9795. Model dalam artikel ini digunakan untuk mendeteksi postur rata - rata babi dalam satu hari (mengambil rata - rata selama delapan hari berturut - turut), dan ditemukan proporsi postur berbaring lebih tinggi dibandingkan postur lainnya (postur berbaring 72%, postur berdiri 20%, dan postur duduk 8%). Proporsi postur berdiri pada siang hari lebih tinggi dibandingkan pada malam hari dan postur berbaring adalah sebaliknya. Proporsi ketiga postur berbaring juga berubah seiring berjalannya waktu.

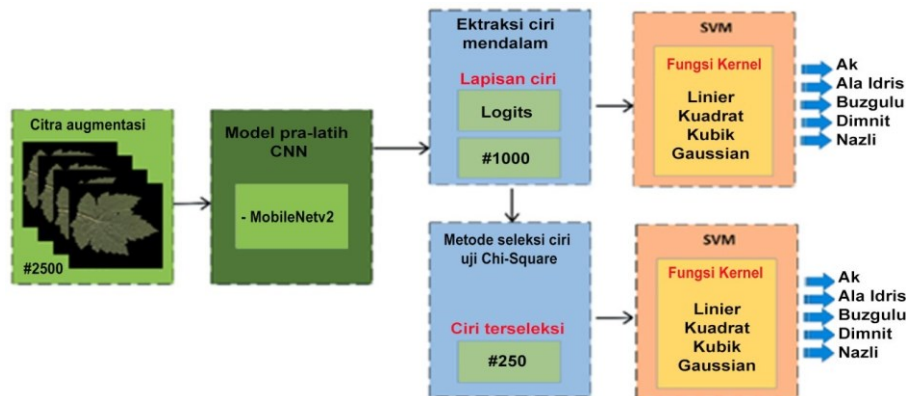
Penelitian ini membandingkan perbedaan akurasi pengenalan postur antar model dalam makalah ini hibrid CNN-SVM, SVM saja, dan CNN saja yang menggunakan data pelatihan dan data eksperimen yang sama. Keakuratan pengenalan postur ketiga model adalah masing - masing 94,6368%; 92,2175% dan 90,5396%. Oleh karena itu, keakuratan pengenalan model CNN dan SVM dalam makalah ini meningkat pesat dibandingkan dengan CNN saja atau SVM (Xu dkk., 2022). Prosedur pengenalan pola postur untuk deteksi kesehatan hewan menggunakan struktur hibrid CNN-SVM ditunjukkan pada Gambar 2.11. Penelitian terkait hibrid CNN dan SVM juga diterapkan pada klasifikasi 5 spesies daun anggur. Tahapan proses ekstraksi ciri CNN, klasifikasi SVM dan klasifikasi SVM dengan seleksi ciri. Produk utama tanaman anggur adalah buah anggur yang dikonsumsi segar atau diolah. Selain itu daun grapevine dapat dipanen setahun sekali sebagai produk sampingan. Jenis daun grapevine penting dari segi harga dan rasa. Pada penelitian ini dilakukan klasifikasi berbasis Deep Learning dengan

menggunakan data citra daun grapevine. Sebanyak 500 citra daun anggur dari 5 spesies diambil dengan sistem penerangan otomatis. Kemudian ditambah jumlahnya menjadi 2500 dengan metode augmentasi citra. Klasifikasi dilakukan dengan model CNN MobileNetv2 yang disempurnakan.



Gambar 2.11 (a) Prosedur pengenalan pola postur, (b) struktur pendeteksi berbasis CNN dan SVM (Xu dkk., 2022)

Sebagai pendekatan kedua, ciri diekstraksi MobileNetv2 yang telah dilatih sebelumnya. Lapisan dan klasifikasi logit dibuat menggunakan berbagai kernel SVM. Sebagai pendekatan yang ketiga, 1000 ciri diekstraksi dari MobileNetv2, lapisan logit dipilih dengan metode *Chi dan Squares* dan dikurangi menjadi 250. Kemudian dilakukan klasifikasi dengan berbagai kernel SVM menggunakan ciri yang dipilih. Metode yang paling berhasil diperoleh dengan mengekstraksi ciri dari lapisan logit dan mereduksi ciri tersebut dengan Metode *Chi dan Squares* yang ditunjukkan seperti pada Gambar 2.12. Keberhasilan klasifikasi sistem dapat mencapai 97,60% (Koklu dkk., 2022).



Gambar 2.12 Tahapan proses ekstraksi ciri CNN, klasifikasi SVM dan klasifikasi SVM dengan seleksi ciri (Koklu dkk., 2022)

Penelitian ini akan menjelaskan studi masa depan yang dapat dilakukan dengan model CNN-SVM diterapkan pada penentuan jenis daun *grapevine*. Berbagai penelitian terdahulu telah menunjukkan kinerja yang baik dalam pendeteksian kondisi kesehatan ayam menggunakan satu jenis data, seperti citra RGB, citra postur, suara vokal ayam, citra feses, maupun citra termografi inframerah. Meskipun beberapa metode tersebut mampu mencapai akurasi tinggi hingga mendekati 98%, sebagian besar penelitian dilakukan pada lingkungan yang relatif terkontrol dan hanya berfokus pada satu sumber informasi sehingga belum mampu menangkap kompleksitas kondisi sebenarnya di lapangan.

2.2 Keaslian Penelitian

State of the art dalam penelitian ini disusun berdasarkan kontribusi dan rekomendasi dari jurnal penelitian sebelumnya seperti pada Tabel 2.1. Adapun beberapa jurnal yang telah dikumpulkan ditujukan agar penelitian yang dilakukan ini menjadi lebih terarah. Hingga saat ini belum ditemukan penelitian yang secara eksplisit menggabungkan citra RGB dan citra inframerah ayam secara simultan untuk klasifikasi tiga kondisi kesehatan ayam (sehat, sakit, dan mati) dalam lingkungan kandang tertutup yang menunjukkan adanya celah penelitian (*research gap*), dimana integrasi data multimodal berpotensi meningkatkan ketahanan model terhadap variasi lingkungan dan menghasilkan klasifikasi lebih akurat, realistis, dan sesuai dengan kebutuhan sistem pemantauan kesehatan ayam secara non-invasif.

Tabel 2.1 Penelitian sebelumnya yang terkait

Referensi	Objek	Tujuan	Metode	Hasil
(Niu dan Suen, 2012)	Citra angka tulisan tangan	Prediksi tulisan tangan angka	CNN untuk ekstraksi ciri dan SVM untuk prediksi keluaran	Akurasi 99,81% tanpa penolakan, dan 94,40% dengan penolakan
(Shen dkk., 2016)	Citra RGB ayam	Estimasi jumlah ayam dalam setiap citra	Filter <i>Gaussian</i> untuk penghalusan citra, threshold Otsu untuk ambang skala abu dan abu serta segmentasi kepala dan kaki ayam, dan Watershed untuk estimasi jumlah ayam	Menganalisis suhu ayam dari ketinggian 160 cm dan sudut depresi 30 dan estimasi jumlah ayam dengan tingkat akurasi 91,3%
(Chen dkk., 2018)	Citra pengawasan jalan	Deteksi sabuk pengaman dalam sistem transportasi	Deteksi menggunakan CNN dan post dan processing menggunakan skor deteksi model klasifikasi SVM	Hasil deteksi CNN dengan SVM mencapai 87% dan deteksi CNN saja mencapai 80%.
(Wu dkk., 2018)	Citra sinyal mekanomio grafi (MMG)	Pengenalan pola gerakan lutut	Model gabungan CNN dan SVM untuk pengenalan pola gerakan lutut.	Model CNN dan SVM akurasi 94,04% dibandingkan CNN saja sebesar $88,45 \pm 2,79\%$.
(Zhuang dan Zhang, 2019)	Citra postur ayam	Deteksi ayam sakit berdasarkan postur tubuh ayam	Deteksi ayam sakit berdasarkan postur tubuh ayam menggunakan pembelajaran mesin termasuk SVM	Model SVM lebih unggul dari pembelajaran mesin lainnya.
(Geronimo dkk., 2019)	Citra daging dada ayam	Deteksi kelainan (wooden breast/WD)	Metode SVM, MLP, RF dan J48 untuk deteksi dada ayam diklasifikasikan dengan benar sebagai WB atau Normal (N)	Klasifikasi SVM akurasi mencapai 91,8% dan dengan informasi spektral NIR menunjukkan akurasi 97,5%.
(Navaneeth dan Suchetha, 2019)	Data sensor amonia	Deteksi penyakit ginjal akut berdasarkan kadar amonia	Particle Swarm Optimized (PSO) 1 dan D CNN dan SVM untuk deteksi penyakit Ginjal Kronis (CKD)	Arsitektur yang diusulkan dapat mencapai akurasi 98,25%

Tabel 2.1 Penelitian sebelumnya yang terkait (lanjutan)

Referensi	Objek	Tujuan	Metode	Hasil
(Okinda dkk., 2019)	Citra 2D bentuk postur ayam	Klasifikasi status kesehatan ayam	<i>Radial Basis Function (RBF) dan Support Vector Machine (SVM)</i>	RBF dan SVM dengan akurasi 97,8% mengungguli klasifikasi lainnya
(Bloch dkk., 2020)	Citra termografi IR ayam	Prediksi suhu tubuh ayam	Metode yang digunakan Regresi Lasso	Akurasi $\pm 0,27^{\circ}\text{C}$, mengukur satu ayam setiap 16 menit
(Jia dkk., 2020)	Citra sel dari pasien serviks	Klasifikasi sel untuk skrining dini kanker serviks	Model CNN) dan SVM diusulkan untuk mengklasifikasikan sel dan sel serviks. GLCM dan Gabor dengan ciri - ciri abstrak dari lapisan tersembunyi CNN	Ciri kuat model CNN dan SVM dapat diterapkan dalam klasifikasi sel untuk skrining dini kanker serviks dengan akurasi 99,3%
(Hernández dkk., 2020)	Paparan inframerah pada ayam	Estimasi suhu kloaka ayam	Integrasi <i>fuzzy inference system (FIS) dan fuzzy genetic algorithm (Fuzzy dan GA)</i>	Metode Fuzzy dan GA menunjukkan hasil statistik yang lebih baik daripada FIS manual
(Koklu dkk., 2022)	Citra daun grapevine	Prediksi daun anggur dari 5 spesies	Model pertama, CNN MobileNetv2 saja. Model kedua, MobileNetv2 dan klasifikasi logit dibuat menggunakan berbagai kernel SVM. Model ketiga, MobileNetv2 dengan metode Chi dan Squares dan klasifikasi SVM	CNN MobileNetv2 dari lapisan Logits dan reduksi ciri dengan metode Chi dan Kuadrat serta Kernel Cubic SVM yang paling sukses dengan keberhasilan klasifikasi mencapai 97,60%
(Khairandish dkk., 2022)	Citra dari hasil MRI otak	Deteksi dan klasifikasi tumor otak	Model CNN dan SVM MRI otak untuk mendeteksi dan klasifikasi tumor	Akurasi keseluruhan dari hybrid CNN SVM sebesar 98,4959%
(Ali dan Mallaiah, 2022)	Citra aksara Arab tulisan tangan	Pengenalan aksara Arab tulisan tangan	Model SVM dan CNN untuk klasifikasi teks dalam aksara Arab tulisan tangan	Akurasi klasifikasi CNN dan SVM lebih tinggi dari yang lain
(Xu dkk., 2022)	Citra postur babi berdiri, berbaring dan duduk	Deteksi postur rata-rata babi	Model yang digunakan CNN, SVM dan CNN dan SVM dalam pengenalan postur babi	Akurasi CNN sebesar 90,5396%, SVM 92,2175%, dan CNN dan SVM sebesar 94,6368%

Tabel 2.1 Penelitian sebelumnya yang terkait (lanjutan)

Referensi	Objek	Tujuan	Metode	Hasil
(Cuan dkk., 2022)	Sinyal suara vokal ayam	Deteksi ayam sakit Newcastle disease (tetelo) berdasarkan suara vokal ayam	Metode transformer, CNN, RNN,LSTM dan BILSTM digunakan untuk deteksi ayam sakit tetelo berdasarkan suara vokal ayam	Akurasi tertinggi pada hari pertama, kedua, ketiga dan keempat setelah terinfeksi masing - masing sebesar 82,15%; 90,00%; 93,60%; 98,50%
(Keerthana dkk., 2023)	Citra dermoskopi	Deteksi dan klasifikasi lesi jinak atau melanoma	Model 2 arsitektur CNN hibrid SVM pada lapisan keluaran untuk klasifikasi citra dermoskopi menjadi lesi jinak atau melanoma	Model CNN dan SVM mencapai akurasi 88,02% dan 87,43%, yang masih lebih tinggi dibandingkan model CNN saja
(Ogbuagu dkk., 2023)	Suhu kloaka ayam	Evaluasi efek L dan serine pada variasi sirkadian suhu tubuh ayam	Pengukuran invasif suhu kloaka ayam dan suhu permukaan badan dengan termometer digital secara langsung sebagai dasar pembatasan pakan dan L dan serine	Pembatasan pakan dan L dan serine secara bersamaan dapat menurunkan suhu tubuh ayam, dan mengurangi dampak stres panas pada ayam
(Kunhoth dkk., 2023)	Citra tulisan tangan dari data disgrafia daring	Prediksi citra tulisan tangan disgrafia	Model CNN (DenseNet201) digabungkan dengan SVM, AdaBoost, dan Random forest	Model CNN dan SVM tercapai akurasi tertinggi sebesar 91,7% dan jika ditambahkan fusi ciri akurasi mencapai 97,3%

Berdasarkan beberapa penelitian sebelumnya yang terkait seperti yang ditunjukkan Tabel 2.1 bahwa penelitian deteksi ayam sakit sudah dilakukan sebelumnya, namun masih berdasarkan postur tubuh ayam, suara vokal ayam, kotoran ayam, suhu kloaka ayam (model invasif), dan citra termografi. Metode yang digunakan CNN, RNN, LSTM, SVM, Regresi, Regresi Lasso, dan pengolahan citra. Namun demikian pemantauan kondisi kesehatan ayam yang telah diteliti tersebut belum ditemukan klasifikasi ayam sehat, sakit atau mati berdasarkan citra

inframerah badan ayam dengan model non-invasif menggunakan gabungan CNN dan SVM. Oleh karena itu, kebaruan dari penelitian ini antara lain:

- a. menggunakan citra RGB (*Red Green Blue*) dan citra inframerah ayam dalam kandang,
- b. menggabungkan pengolahan citra, metode CNN-SVM dalam melakukan klasifikasi kondisi kesehatan ayam berdasarkan citra RGB dan inframerah ayam menjadi 3 kelas (normal, tidak normal, dan mati),
- c. mengembangkan sistem pemantauan kondisi kesehatan ayam secara non- invasif menggunakan teknik klasifikasi citra (CNN untuk deteksi objek ayam pada citra dan ekstraksi ciri, augmentasi data untuk memperkaya keragaman data, kelas terbobot untuk mereduksi kelas ketakseimbangan, dan SVM untuk klasifikasi) berdasarkan citra RGB dan inframerah ayam di dalam kandang.


2.3 Landasan Teori

2.3.1 Budidaya Ayam

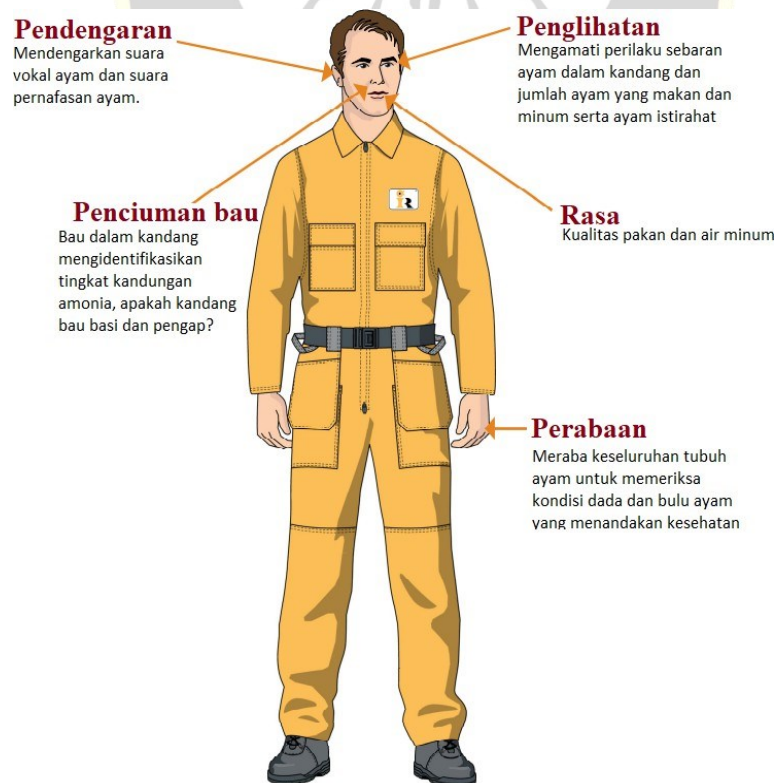
Sebagian besar unit usaha ayam broiler di Indonesia masih dijalankan dalam skala kecil, namun telah terjadi pergeseran ke arah kemitraan dan integrasi vertikal berskala besar dan teknologi modern turut mendominasi. Pada sektor broiler nasional, sekitar 40% usaha masih berskala kecil dan menengah, sementara 60% lainnya telah masuk kategori usaha besar yang menuntut penerapan biosekuriti, manajemen intensif, dan kemitraan dengan integrator. Sebagian besar persediaan daging ayam di wilayah ini berasal dari kalangan kecil bukan dari kalangan industri besar. Keberhasilan budidaya ayam ini tergantung pada penerapan teknologi produksi ayam modern secara terpadu. Beberapa negara seperti Indonesia, Thailand, Malaysia, dan Filipina merupakan negara terkemuka dalam produksi telur wilayah ini, diperkirakan sekitar 2748 ribu ton dan produksi daging ayam diperkirakan sekitar 3970 ekor ribu ton (FAO, 2005).

Ayam yang unggul memiliki tingkat kesehatan fisik, kebugaran kardiovaskular, dan ketahanan terhadap tekanan suhu. Pencapaian kinerja budidaya ayam perlu memperhatikan berbagai aspek dalam budidaya ayam meliputi kualitas bibit ayam, kondisi kesehatan, pemberian pakan, minuman, dan nutrisi, pengaturan

suhu, ventilasi, pencahayaan kandang, kepadatan/sebaran ayam, serta vaksinasi seperti ditunjukkan pada Gambar 2.13.



Gambar 2.13 Faktor yang berpengaruh terhadap pertumbuhan ayam (An Aviagen Brand, 2018)



Gambar 2.14 Pemantauan kesehatan ayam dengan panca indra (An Aviagen Brand, 2018)

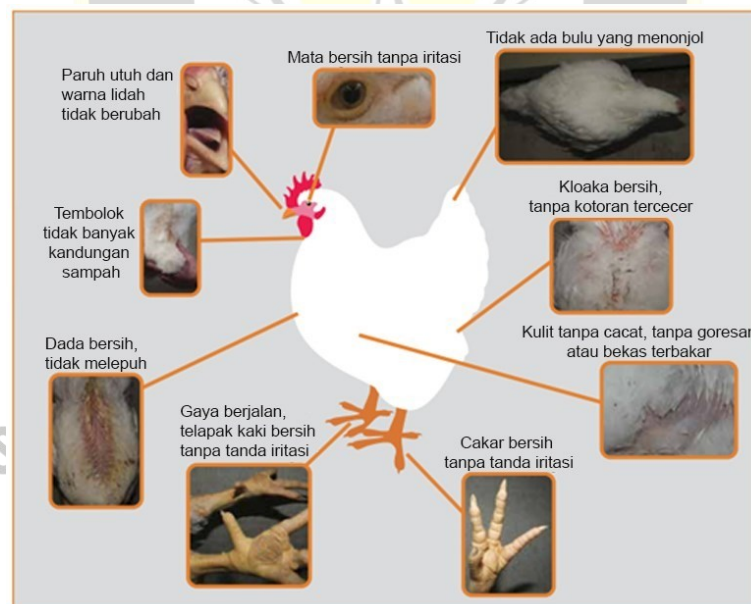
Dalam budidaya ayam, pemantauan kesehatan ayam yang dilakukan secara manual didasarkan pada panca dan indera manusia seperti yang ditunjukkan pada Gambar 2.14. Perubahan pada hasil pemantauan tersebut akan berdampak terhadap produksi ayam maupun sisi keuangan. Peningkatan kepadatan tebar berdampak pertumbuhan ayam harian lebih rendah dan memperburuk *Feed Conversion Ratio* (FCR). Oleh karena itu, peningkatan jumlah ayam meskipun terlihat menarik secara finansial tapi perlu dievaluasi secara tepat dengan mempertimbangkan penurunan pertumbuhan, kinerja yang lebih bervariasi, biaya pakan yang lebih tinggi, dan daging yang lebih rendah. Kesehatan ayam pedaging yang baik merupakan pelengkap dari kinerja komersial yang baik. Ayam yang dirawat dengan baik akan seragam dan memiliki bobot hidup yang dapat diprediksi, sehingga mampu memenuhi target bobot ayam. Produksi ayam pada fase pertumbuhan ayam merupakan salah satu bagian dari keseluruhan proses produksi daging terpadu, yang meliputi pabrik pakan, peternakan induk, tempat pembenihan, peternakan ayam pedaging, pengolah, pengecer dan konsumen.



Gambar 2.15 Pengukuran suhu badan ayam dengan cara invasif
(An Aviagen Brand, 2018)

Rekomendasi suhu lingkungan, kelembapan, dan kecepatan udara yang diberikan bersatu dengan benar untuk menghasilkan suhu tubuh anak ayam yang ideal selama 4 hingga 5 hari pertama setelah menetas yaitu sebesar 39,4°C hingga 40,5°C. Pengukuran suhu seperti yang ditunjukkan pada Gambar 2.15, dilakukan pada 10 anak ayam dari 5 kandang yang berbeda untuk 4 hari pertama sampai 5 hari setelah penempatan (An Aviagen Brand, 2018). Rentang suhu yang sempit biasanya dicerminkan oleh batas atas dan bawah ritme sirkadian suhu tubuh bagian dalam. Pada ayam yang diberi makan cukup, maka tidak terjadi pembuangan panas ke

lingkungan atau memperoleh panas dari lingkungan pada batas atas ritme sirkadian sekitar $41,5^{\circ}\text{C}$ dan batas bawah sekitar $40,5^{\circ}\text{C}$. Saat terkena lingkungan yang panas atau melakukan aktivitas fisik berat, suhu tubuh dapat meningkat sebesar 1°C atau 2°C saat panas tersimpan. Penyimpanan panas tidak dapat dilanjutkan untuk waktu yang lama sebelum suhu tubuh meningkat melewati batas yang sesuai kehidupan. Sebaliknya bila ayam dihadapkan pada lingkungan yang sangat dingin, panas lolos dari tubuh ayam, suhu tubuh akan menurun hingga ayam tidak berdaya bahkan dapat menimbulkan kematian. Pertimbangan pengaruh suhu lingkungan telah disintesis menjadi terminologi yang umum digunakan untuk berdiskusi terkait tanggapan perilaku hewan terhadap perubahan lingkungan suhu (Daghir, 2020). Pemantauan kesehatan ayam pedaging secara visual dapat dilakukan berdasarkan tanda-tanda pada anatomi dan fisiologi ayam. Anatomi ayam pedaging yang dapat dijadikan tanda terkait kondisi kesehatan seperti ditunjukkan pada Gambar 2.16.



Gambar 2.16 Pemantauan kesehatan ayam pedaging berdasarkan anatomi (An Aviagen Brand, 2018)

Pada ayam pedaging yang sehat, paruh dan lidah tidak mengeluarkan cairan dari hidung (atau makanan menempel di paruh) dan tidak ada tanda - tanda perubahan warna lidah. Selain itu, bagian mata bersih tidak ada tanda - tanda iritasi, bulu bersih tanpa ada yang lengket, kloaka luar (*vent*) bersih tanpa ada kotoran yang

menempel, kulit tidak cacat tanpa goresan atau bekas luka bakar, cakar bersih tanpa tanda ada iritasi, sela-sela cakar bersih tanpa iritasi, dada tidak cacat dan tidak melepuh, tembolok terisi cukup makanan (An Aviagen Brand, 2018). Pada ayam yang diberi pakan dengan baik tidak membuang panas ke lingkungan atau memperoleh panas dari lingkungan, batas atas ritme sirkadian biasanya sekitar $41,5^{\circ}\text{C}$ dan batas bawah sekitar $40,5^{\circ}\text{C}$. Pengukuran suhu tubuh ayam ini hanya salah satu cara memantau kesehatan ayam. Sebab untuk memantau kesehatan ayam secara komunal biasanya dengan memantau tingkah laku ayam, memeriksa kotoran ayam di *litter*/alas kotoran, suara ayam dan yang lain. Salah satu ukuran status inframerah dari ayam yaitu suhu kloaka yang diukur dengan termometer, namun metode ini membutuhkan penanganan ayam secara invasif sehingga resiko dapat menyebabkan ayam menjadi stres bahkan hingga mati. Model pengukuran suhu secara invasif ini pernah dilakukan dalam penelitian analisis pengaruh pembatasan pakan untuk menurunkan suhu kloaka dan suhu permukaan tubuh pada ayam selama musim panas (Ogbuagu dkk., 2023). Penelitian dengan model invasif lainnya yaitu mengukur suhu ayam kalkun pada permukaan payudara (*tbreast*), sayap (*twing*), paha (*tdrum*), kepala (*thead*), dan betis (*tshank*) dengan selang waktu 20 menit menggunakan kamera inframerah, sementara pencatat data inframerah mengukur suhu permukaan kulit di bawah sayap (*tlogger*) pada selang waktu 30 detik. Suhu kloaka (*tcare*) diukur menggunakan termometer medis di awal dan akhir periode paparan (Mayes dkk., 2015).

Perilaku serta respons fisiologis ayam (laju pernapasan dan suhu kloaka) dapat menjadi indikasi kenyamanan inframerah atau ketidaknyamanan ayam. Pendekatan tersebut dapat digunakan sebagai model non-invasif dengan memperkirakan suhu kloaka (CT) ayam menggunakan algoritma genetik dan *Fuzzy Inference System* (FIS). Metode gabungan ini dikenal Fuzzy dan GA yang digunakan dalam penelitian prediksi suhu kloaka ayam dalam menanggapi intensitas dan durasi paparan panas selama satu minggu pertama kehidupan. Eksperimen dilakukan di dalam terowongan angin dengan pengatur suhu. Data percobaan terdiri atas 114 pengamatan berbasis laboratorium. Penelitian ini

mengusulkan kerangka teoritis untuk pengembangan sistem Fuzzy dan GA melalui dua pendekatan yang berbeda yaitu pendekatan Mogul dan pendekatan Pittsburgh. Hasil eksperimen menunjukkan bahwa nilai CT yang diprediksi oleh kedua model (FIS dan Fuzzy dan GA) mirip dengan nilai CT yang diamati secara eksperimental. Namun model Fuzzy dan GA menunjukkan hasil statistik yang lebih baik daripada FIS manual dalam hal kemampuan memprediksi CT. Dengan demikian, model berbasis *Fuzzy* dan GA dapat digunakan untuk memprediksi CT pada ayam yang terpapar tantangan inframerah, karena itu dapat membantu dalam proses pengambilan keputusan. Penerapan metode optimalisasi seperti algoritma genetik ini terbukti mampu meningkatkan kinerja metode *reasoning* seperti FIS dalam memprediksi suhu kloaka pada ayam (Hernández dkk., 2020).

Salah satu model non-invasif yang telah diterapkan adalah dengan menggunakan metode pengolahan citra berdasarkan termografi kamera inframerah. Pada awal proses pengolahan citra, metode filter *Gaussian* digunakan untuk menghaluskan citra. Metode ambang otomatis *Otsu* digunakan untuk menentukan ambang skala abu - abu serta segmentasi kepala dan kaki ayam. Metode *watershed* digunakan untuk segmentasi citra ayam yang tumpang tindih. Penyaringan area digunakan untuk identifikasi bagian kepala ayam di antara bagian yang tersegmentasi. Metode pelabelan digunakan untuk menghitung jumlah ayam dalam setiap citra. Hasil eksperimen berhasil mengidentifikasi kepala ayam dan analisis suhu sekawanan ayam berdasarkan citra ayam dari ketinggian 160 cm dan sudut 30° dapat mencapai akurasi identifikasi hingga 91,3% (Shen dkk., 2016). Di dalam penelitian lain, pengukuran suhu tubuh ayam dengan pengolahan citra inframerah dan regresi Lasso juga dilakukan untuk memprediksi suhu. Prototipe dengan menggunakan metode ini dibangun dan diuji di kandang penelitian lebih dari 21 hari (umur 14 dan 35 hari) untuk 15 ekor ayam. Suhu tubuh ayam yang diprediksi dibandingkan dengan suhu tubuh aktual yang diukur dengan pencatat suhu yang ditanamkan di rongga perut. Akurasi $\pm 0,27^{\circ}\text{C}$ dalam mengukur satu ayam setiap 16 menit rata - rata (Bloch dkk., 2020). Teknologi termografi inframerah merupakan metode non-invasif yang digunakan untuk menunjukkan perubahan panas secara

biologis. Perubahan panas pada metabolisme hewan dapat diakibatkan peningkatan suhu tubuh dan perubahan aliran darah sebagai respons terhadap kondisi lingkungan atau fisiologis. Teknologi ini dapat digunakan sebagai metode yang bermanfaat sebagai indikator stres ayam serta dapat juga menunjukkan adanya proses inflamasi, nyeri dan penyakit. Dalam penerapan produksi hewan, penggunaan teknologi ini dapat mengatasi aspek panas dan stres fisiologis, metabolisme, nutrisi, proses inflamasi, penyakit, deteksi ektoparasit dan reproduksi (McManus dkk., 2016).

Pengukuran suhu ayam berdasarkan termografi inframerah juga bertujuan untuk evaluasi hubungan antara suhu kloaka dan suhu permukaan kulit. Sebanyak 648 anak ayam digunakan dalam 2 fase berbeda, fase I (minggu 1 dan 6) dan fase II (minggu 7 dan 17). Suhu kloaka dan suhu permukaan tubuh untuk 8 bagian (kepala, mata, sisir, dada, punggung, sayap, kaki, area kepala) dan diperoleh data setiap minggu dari 4 hingga 2 ekor per perawatan, masing - masing selama fase II. Tidak ada efek untuk interaksi antara 2 fase percobaan untuk kloaka dan suhu permukaan bagian tubuh, namun ada korelasi yang kuat ($P < 0,001$) antara kloaka suhu dan masing - masing suhu bagian tubuh. Suhu kloaka mengikuti respon kuadrat perubahan suhu udara lingkungan. Ayam petelur dara yang dikenakan suhu $35^{\circ}\text{C}/20^{\circ}\text{C}$ dan $30^{\circ}\text{C}/20^{\circ}\text{C}$ memiliki suhu tubuh tertinggi dibandingkan dengan 2 perlakuan lainnya ($P < 0,05$). Suhu permukaan kaki adalah terbesar di semua pengujian, dan suhu pada dada yang terendah. Regresi antara kloaka dan suhu bagian tubuh memiliki akurasi prediksi 95% lebih baik dari $0,4^{\circ}\text{C}$, dengan pengukuran suhu kloaka secara langsung (Cândido dkk., 2020).

Salah satu model non-invasif yang diterapkan pada pengukuran suhu ayam adalah menggunakan metode regresi *Lasso* berdasarkan termografi kamera inframerah (Bloch dkk., 2020). Selain itu, cara alternatif penilaian status suhu ayam yang ditujukan dalam analisis respon suhu tubuh terhadap perubahan suhu lingkungan dapat dilakukan dengan pendekatan visi komputer. Cara ini mengintegrasikan pengolahan citra dengan metode pembelajaran mesin untuk regresi maupun klasifikasi telah terbukti dapat memberikan kinerja yang akurat untuk memantau kondisi kesehatan ayam secara non-invasif (Shen dkk., 2016).

2.3.2 Prapengolahan Citra

Data citra merupakan data tidak terstruktur sehingga tidak dapat diolah langsung oleh metode pembelajaran mesin untuk keperluan klasifikasi, regresi/estimasi, klusterisasi, asosiasi, dan lainnya. Data yang tidak terstruktur harus ditransformasi menjadi data yang terstruktur lebih dahulu agar dapat dipahami dan diolah dengan metode pembelajaran mesin. Transformasi data tidak terstruktur (seperti data citra) menjadi data terstruktur sehingga memiliki ciri-ciri disebut dengan pendekatan ekstraksi ciri (Santoso dkk., 2020b). Selanjutnya beberapa tindak lanjut dari data yang telah terstruktur yang bertujuan untuk meningkatkan kinerja dari model pembelajaran mesin antara lain seleksi ciri, pengurangan dimensi data, pembobotan atribut/ciri, serta penggabungan ciri.

Seleksi ciri, pengurangan dimensi data, pembobotan atribut/ciri bertujuan untuk meningkatkan kinerja dari suatu model *Machine Learning*, sedangkan ekstraksi ciri tidak bertujuan untuk itu, melainkan hanya untuk transformasi data menjadi terstruktur. Pada prinsipnya, setiap ciri bersifat bebas atau tidak saling berkorelasi/terikat, ciri masukan hanya terikat dengan ciri keluaran, namun dalam banyak kasus, asumsi tersebut tidak selalu tepat (Santoso dkk., 2020b).

Oleh karena itu, ketika terjadi korelasi sehingga mengakibatkan redundansi pada atribut - atribut (ciri masukan), maka solusi untuk mengurangi, menggabungkan, membuang, atau memberikan bobot pada atribut-atribut menjadi efisien dan efektif untuk dilakukan. Proses ini juga memastikan bahwa model dapat beroperasi secara lebih stabil dan tidak terpengaruh oleh atribut yang bersifat noise atau kurang informatif. Selain itu, optimasi ciri yang dilakukan secara sistematis dapat meningkatkan generalisasi model ketika diaplikasikan pada data baru. Hal ini pada akhirnya berkontribusi pada peningkatan ketepatan dan keandalan sistem klasifikasi berbasis pembelajaran mesin.

Beberapa metode yang dapat digunakan untuk pengurangan dimensi, antara lain *Principal Component Analysis (PCA)*, *Singular Value Decomposition (SVD)*, *Independent Component Analysis (ICA)*, *Generalized Hebbian Algorithm (GHA)*, dan *Self Organizing Map (SOM)*. Beberapa metode yang dapat digunakan untuk

seleksi ciri dan pembobotan atribut antara lain *Forward Selection*, *Backward Elimination*, *Bruto Force Weight dan Guided*, *Genetic Algorithm*, *Particle Swarm Optimization* (PSO), dan metode optimalisasi lainnya. Metode tersebut dapat pula digunakan untuk ekstraksi ciri.

Selain masalah pada ciri masukan, masalah dapat pula terjadi pada ciri keluaran seperti kelas ketidakseimbangan. Data yang memiliki keluaran atau kelas yang tidak seimbang jumlahnya, bisa berdampak buruk terhadap kinerja model *Machine Learning*. Metode *ensemble* seperti *Bagging* dan *Stacking* dapat digunakan untuk mengatasi masalah kelas ketidakseimbangan (Santoso dkk., 2020b). Namun pendekatan yang lebih sederhana adalah dengan memberikan bobot pada setiap kelas, diistilahkan dengan kelas terbobot. Pendekatan ini mengambil nilai median dari distribusi frekuensi kelas yang dibagi dengan distribusi frekuensi kelas tersebut, lebih jelas ditunjukkan pada Persamaan (2.1) (Moola dkk., 2021).

$$w_c = \frac{\text{median}\left(\frac{\sum_{i=1}^n x_{i=c}}{\sum_{i=1}^n x_i}\right)}{\sum_{i=1}^n x_{i=c}} \quad (2.1)$$

Sedangkan masalah yang biasa terjadi pada data, khususnya pada model yang direkomendasikan untuk mengolah data yang besar seperti *Deep Learning* adalah kurangnya pola atau keragaman pada data. Masalah ini dapat pula berdampak buruk terhadap kinerja model. Untuk mengatasinya, pendekatan augmentasi data dapat diterapkan. Pendekatan ini dapat memperkaya informasi pada data sehingga dapat menghasilkan model yang lebih kuat/akurat dalam pengenalan pola. Selain itu, pendekatan ini juga dapat menurunkan gejala *overfitting* (Moola dkk., 2021).

Secara sederhana, metode yang dapat digunakan untuk augmentasi data adalah transformasi umum seperti rotasi yang membuat transformasi citra yang diputar secara acak dengan derajat sudut tertentu. Skala mengubah ukuran citra menggunakan faktor rentang tertentu yang dipilih secara acak dalam arah horizontal dan vertikal yang sama. Translasi menggeser citra secara horizontal dan vertikal

dengan jarak yang dipilih secara acak dalam rentang piksel tertentu. Penerapan *synthetic Gaussian blur* secara acak pada citra dengan menentukan jumlah penghalusan tertentu. Derau sintesis membuat bias buatan pada citra, pemangkasan citra, pewarnaan pada citra, pencerminan membuat refleksi pada citra, dan membuat pergeseran objek pada citra (Moola dkk., 2021).

2.3.3 Pembelajaran Mesin (*Machine Learning/ML*)

Artificial Intelligence (AI) memungkinkan suatu program bersifat adaptif terhadap informasi yang baru, mampu melakukan pembelajaran, penalaran, serta memiliki pengetahuan. Saat ini, pembelajaran mesin merupakan salah satu bagian dari AI. Pendekatan pembelajaran mesin hadir untuk mengatasi kendala aturan dan aturan yang tidak selalu bisa didefinisikan secara benar dan lengkap. Pembelajaran mesin mampu mengatasi masalah yang sangat kompleks, dan memiliki toleransi terhadap data yang tidak tepat. Dengan begitu pula, pendekatan pembelajaran mesin dapat membuat sistem semakin lebih cerdas dari sebelumnya. *State of the art* metode pembelajaran mesin untuk menangani masalah klasifikasi dan regresi antara lain: *Artificial Neural Network* (ANN), SVM, C 4.5, *K - Nearest Neighbor* (KNN), dan *Naive Bayes* (NB) (Lin dkk., 2017). Standarnya, ANN dan SVM dapat digunakan untuk klasifikasi dan regresi. SVM untuk regresi disebut *Support Vector Regression* (SVR). Sedangkan C4.5, KNN, dan NB dapat digunakan untuk klasifikasi.

Secara standar/umum ANN dapat diformulasikan pada persamaan (2.2). Dalam SVM, fungsi tujuannya adalah untuk meminimalkan persamaan (2.3) dengan syarat (2.4), untuk memprediksi keluaran menggunakan persamaan (2.5). Dalam C4.5, *Entropy* (E) dapat didefinisikan pada persamaan (2.6), *Information Gain* (IG) pada persamaan (2.7). *Gain* (G) pada persamaan (2.8), dan *Gain Ratio* (GR) pada persamaan (2.9). Dalam KNN, keluaran yang diprediksi ditentukan menggunakan persamaan (2.10). Dalam NB, prediksi keluaran menggunakan persamaan (2.11), dan metode *Gaussian* dapat didistribusikan apabila data atribut bertipe numerik (Lin dkk., 2017).

$$y = b_j + f\left(\sum_{j=1}^m x_j w_j\right) \quad (2.2)$$

$$\min_{\vec{w} \rightarrow} \tau(\underline{w}) = \frac{1}{2} \|\vec{w} \rightarrow\|^2 \quad (2.3)$$

$$t(w \cdot x_i + b) \geq 1 \quad (2.4)$$

$$y_i = \text{sign}(y_i)$$

$$y = \begin{cases} +1, & \text{jika } w \cdot z + b > 0 \\ -1, & \text{jika } w \cdot z + b < 0 \end{cases} \quad (2.5)$$

$$E(j) = -\sum_{i=1}^n P(w_i|j) \text{Log}_2 P(w_i|j) \quad (2.6)$$

$$IG(j) = \sum_{i=1}^n P(w_i|j) E(j_i) \quad (2.7)$$

$$G(j) = E(j) - IG(j_i) \quad (2.8)$$

$$GR(j) = \frac{G(j)}{E(j)} \quad (2.9)$$

$$y = \underset{v}{\text{argmax}} \sum_{D \in D_z}^k I(v = t_c) \quad (2.10)$$

$$y = \underset{t_k}{\text{argmax}} P(t_k) \prod_{j=1}^m P(x_j|t_k) \quad (2.11)$$

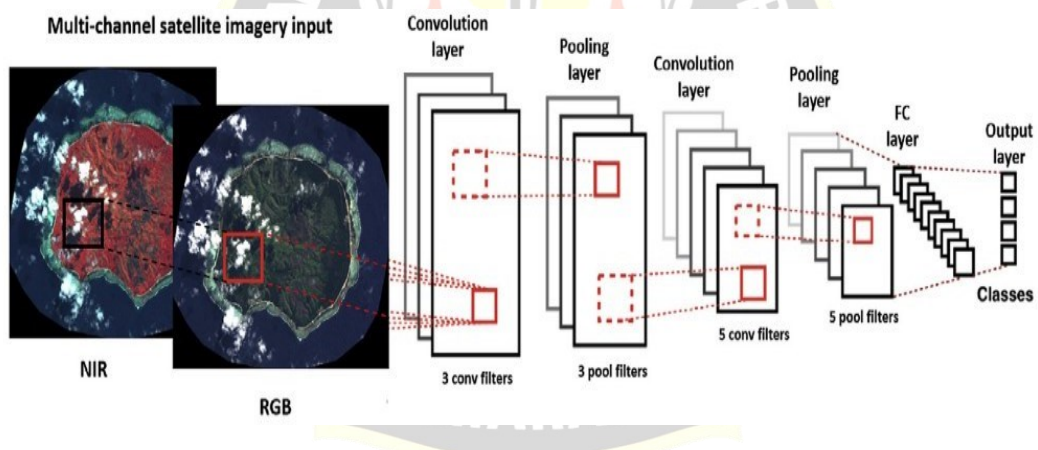
SEKOLAH PASCASARJANA

Keterangan:


x adalah masukan, t adalah target (*actual output*), j adalah variabel/atribut, i adalah *instance*, b adalah bias, w adalah bobot, f adalah fungsi aktivasi, P adalah probabilitas, v adalah jumlah kelas, $d(x', x_j)$ adalah jarak antara data uji/prediksi ke setiap data latih yang disimpan dalam D , z adalah masukan yang belum diketahui keluaran (data uji/prediksi), dan y adalah keluaran yang diprediksi.

2.3.4 Jaringan Syaraf Konvolusional (*Convolutional Neural Network/CNN*)

Metode pembelajaran mesin sering membutuhkan pengolahan citra untuk melakukan ekstraksi ciri. CNN merupakan salah satu metode *Deep Learning* yang paling umum digunakan. Melalui penyaring konvolusi, ekstraksi ciri dapat dilakukan sendiri (Rozenhaimer dkk., 2020). CNN dapat mencerna citra tanpa membutuhkan metode ekstraksi ciri karena arsitektur pada lapisan masukan dan lapisan tersembunyi terdiri dari *neurons* yang disusun dalam tiga dimensi, yaitu lebar, tinggi, dan kedalaman agar sesuai untuk pengolahan citra skala besar seperti pada Gambar 2.17 dan Gambar 2.18 (Rzenhaimer dkk., 2020), sehingga lebih tepat untuk menangani data tidak terstruktur seperti citra dan data besar.




Gambar 2.17 Arsitektur jaringan CNN untuk klasifikasi citra (Rozenhaimer dkk., 2020)



Gambar 2.18 Arsitektur jaringan CNN (Rozenhaimer dkk., 2020)]

Selain itu, CNN dapat pula mengatasi masalah yang sering dihadapi ANN, seperti redundansi yang tinggi, *overfitting*, dan kesulitan dalam konvergensi. Dengan pendekatan konvolusi, *neurons* dalam lapisan – lapisan dapat dikurangi dimensi sehingga tentu saja mengurangi kompleksitas komputasi dan redundansi. Kelebihan parameter penyaring CNN dibandingkan penyaring konvensional adalah adanya proses pembelajaran selama tahap pelatihan pada penyaring konvolusi dan *pooling* (Rozenhaimer dkk., 2020).



Gambar 2.19 CNN untuk klasifikasi citra (Moola dkk., 2021)

Secara umum CNN dapat digunakan untuk klasifikasi citra diperlihatkan pada Gambar 2.19. Pada pendekatan klasifikasi citra, CNN memprediksi suatu citra secara keseluruhan sebagai suatu kelas tertentu seperti diperlihatkan pada Gambar 2.14. Model konvolusi warna berbasis CNN digunakan untuk mengekstraksi ciri warna, ruang dan kemudian digabungkan dengan citra RGB asli untuk dilatih. Ekstraksi ciri mendalam dilakukan dengan membangun arsitektur *Deep Learning* bersama dengan ciri buatan tangan untuk deteksi mitosis. Untuk mengatasi konsumsi waktu, metode *Transfer Learning* digunakan untuk melatih model jaringan.

2.3.5 Matriks Konfusi

Pengukuran kinerja suatu model klasifikasi dapat diukur dengan pendekatan matriks konfusi untuk 3 kelas dapat dilihat pada Gambar 2.20 dalam memperoleh kinerja akurasi. Matriks Konfusi untuk klasifikasi dengan 3 kelas termasuk dalam klasifikasi kelas banyak untuk mengevaluasi kinerja algoritma pembelajaran mesin

dalam memprediksi kelas dari berbagai *instance* dalam dataset. Tabel ini memberikan informasi tentang sejauh mana model yang diusulkan dapat mengklasifikasikan *instance* ke dalam kelas yang benar. Untuk klasifikasi dengan 3 kelas, terdapat komponen dalam matriks konfusi.

		PREDIKSI		
		Sehat	Sakit	Mati
NILAI AKTUAL	Sehat	TP (Sehat)	FP (Sakit)	FP (Mati)
	Sakit	FN (Sehat)	TP (Sakit)	FP (Mati)
	Mati	FN (Sehat)	FN (Sakit)	TP (Mati)

Gambar 2.20 Matriks konfusi

True Positives (TP): Jumlah *instance* yang benar-benar termasuk dalam kelas yang tepat dan diprediksi dengan benar dalam kelas tersebut. *True Positive* diartikan sebagai positif terprediksi benar.

True Negatives (TN): Jumlah *instance* yang benar-benar tidak termasuk dalam kelas tertentu dan diprediksi dengan benar sebagai bukan kelas tersebut. *True Negative* diartikan sebagai negatif terprediksi benar.

False Positives (FP): Jumlah *instance* yang sebenarnya tidak termasuk dalam kelas tertentu, tetapi diprediksi sebagai kelas tersebut. Ini juga disebut sebagai kesalahan tipe I. *False Positive* diartikan sebagai negatif terprediksi salah sebagai positif.

False Negatives (FN): Jumlah *instance* yang sebenarnya termasuk dalam kelas tertentu, tetapi diprediksi sebagai bukan kelas tersebut. Ini juga disebut sebagai kesalahan tipe II. *False Negative* diartikan sebagai positif terprediksi salah sebagai negatif.

Dalam pembelajaran mesin, akurasi dan presisi merupakan dua metrik evaluasi kinerja model yang penting, terutama dalam konteks klasifikasi. Meskipun sering disalahartikan sebagai sinonim, keduanya mengukur hal yang berbeda dan memiliki implikasi yang berbeda pula, tergantung pada masalah klasifikasi yang sedang dihadapi.

Akurasi (*accuracy*) adalah seberapa dekat hasil pengukuran dengan nilai sebenarnya. Proporsi prediksi yang benar (baik positif maupun negatif) terhadap seluruh prediksi yang dilakukan oleh model.

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN}$$

$$\text{Akurasi} = \frac{\text{jumlah prediksi benar (positif dan negatif)}}{\text{jumlah keseluruhan data}}$$

Presisi (*precision*) adalah seberapa konsisten hasil pengukuran terlepas dari kedekatan dengan nilai sebenarnya. Proporsi prediksi positif yang benar-benar positif. Jadi, seberapa sering model benar saat menyatakan positif. Presisi tinggi berarti model jarang mengira ayam sakit padahal tidak (*false positive* rendah).

$$\text{Presisi} = \frac{\text{True Positive (TP)}}{\text{True Positive (TP)} + \text{False Positive (FP)}}$$

$$\text{Presisi} = \frac{\text{jumlah prediksi benar (positif)}}{\text{prediksi benar (positif) + prediksi salah (positif)}}$$

Recall (juga disebut *Sensitivity* atau *True Positive Rate*) adalah ukuran yang menunjukkan seberapa baik model dalam menemukan atau mengenali seluruh data yang benar-benar termasuk kelas positif. Dengan kata lain, *Recall* mengukur proporsi data positif yang berhasil diprediksi dengan benar oleh model dibandingkan dengan semua data positif yang sebenarnya ada. *Recall* sangat penting pada kasus di mana kesalahan mengabaikan data positif (*False Negative*) memiliki dampak besar. Contohnya pada diagnosis penyakit, deteksi kerusakan, atau sistem keamanan lebih baik mendeteksi terlalu banyak daripada melewatkan

kasus penting. Semakin tinggi nilai *Recall*, semakin baik model dalam menangkap seluruh kasus positif.

$$Recall = \frac{\text{jumlah prediksi benar (positif)}}{\text{jumlah data positif yang sebenarnya}}$$

$$Recall = \frac{True\ Positive\ (TP)}{True\ Positive\ (TP) + False\ Negative\ (FN)}$$

F1-Score adalah metrik evaluasi yang menggabungkan Presisi dan *Recall* ke dalam satu nilai harmonis. *F1-Score* digunakan untuk menilai kinerja model klasifikasi terutama ketika data tidak seimbang (*imbalanced dataset*) atau ketika penting untuk mempertimbangkan keseimbangan antara kemampuan model menghindari prediksi positif yang salah (*False Positive*) dan kemampuan menangkap semua data positif (*False Negative*). *F1-Score* merupakan *harmonic mean* dari Presisi dan *Recall*, sehingga nilainya hanya akan tinggi apabila keduanya juga tinggi. Jika salah satu dari Presisi atau *Recall* rendah, maka nilai *F1-Score* akan turun secara signifikan. Metrik ini sangat berguna pada kasus seperti deteksi penyakit, deteksi anomali, atau sistem klasifikasi dengan distribusi kelas yang tidak seimbang.

$$F1-Score = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}}$$