

BAB II

LANDASAN TEORI

2.1 Tinjauan Pustaka

Perkembangan teknologi kecerdasan buatan khususnya dalam bidang visi komputer (computer vision) telah memberikan kontribusi besar dalam dunia medis termasuk kedokteran gigi. Salah satu teknologi yang banyak diterapkan adalah Convolutional Neural Network (CNN) terutama saat digunakan dalam sistem identifikasi penyakit gigi berbasis citra medis. CNN memiliki kemampuan dalam mengenali pola dan fitur dalam gambar yang sangat berguna dalam klasifikasi penyakit gigi seperti karies, kalkulus, dan periodontitis (Oroh & Lubis, 2023).

Penelitian yang dilakukan oleh (Oroh & Lubis, 2023) menggunakan CNN dengan dataset dari Kaggle yang diklasifikasikan menjadi tiga kelas: periodontitis, kalkulus, dan karies. Hasil pengujian menunjukkan bahwa model yang mereka bangun mampu mencapai akurasi pelatihan sebesar 95% dan akurasi pengujian sebesar 94% dengan optimizer Adagrad.

Penelitian oleh (Elizabeth, 2023) membandingkan kinerja arsitektur MobileNetV2 dan ResNet50 dalam klasifikasi lesi jinak dan ganas pada rongga mulut. Hasilnya menunjukkan bahwa ResNet50 dengan optimizer Adam memiliki akurasi 94%, sedangkan dengan SGD hanya mencapai 62%.

Sementara itu (Makarim et al., 2023) menggunakan model YOLOv5 untuk mendeteksi lima jenis kondisi gigi dari citra intraoral yakni impaksi, sisa akar,

karies, tambalan, dan gigi normal. Dataset yang digunakan sebanyak 1.767 gambar. Model YOLOv5-M berhasil mencapai akurasi pengujian sebesar 82% dan pelatihan sebesar 84%.

Di bidang pertanian, (Zalvadila, 2023) menggunakan kombinasi metode SVM dan CNN untuk klasifikasi penyakit pada tanaman bawang merah. Penelitian ini menunjukkan bahwa CNN dan SVM dengan kernel linier dan polinomial dapat mencapai akurasi hingga 100%, dengan nilai presisi, recall, dan F1-score masing-masing sekitar 75%, 73%, dan 74%.

Selain itu, penelitian oleh (Ardyansyah & Gunawansyah, 2023) mengembangkan sistem deteksi Diabetic Retinopathy dari citra fundus mata menggunakan CNN. Model ini mampu mengklasifikasikan tingkat keparahan penyakit menjadi lima kategori dan mencapai akurasi hingga 85%, dengan presisi 82% dan recall 80%.

Dari berbagai penelitian di atas dapat disimpulkan bahwa penggunaan CNN baik dalam bidang kedokteran gigi maupun bidang lainnya memberikan kontribusi yang signifikan dalam meningkatkan efisiensi dan akurasi proses identifikasi atau klasifikasi berdasarkan citra. Penggunaan arsitektur seperti MobileNetV2, ResNet50, maupun YOLOv5 memperkuat kemampuan sistem dalam memberikan prediksi yang akurat dan efisien, terutama ketika diterapkan pada aplikasi mobile berbasis Android.

2.1.1. Deep Learning

Deep learning adalah bagian dari *machine learning*, dan prosesnya masih menggunakan berbagai lapisan. Ini karena arsitekturnya yang dapat digabungkan saat proses data baru dijalankan. Secara bertahap *deep learning* ini dapat digunakan untuk melakukan penelitian yang kuat dalam bidang AI untuk menemukan hal-hal yang bagus karena tidak semua *software* memiliki kemampuan untuk merambat ke bidang industri. Saat ini *deep learning* sering dibicarakan di bidang pengajaran mesin karena kemampuan luasnya untuk mengolah data kompleks seperti gambar dan suara. Model *deep learning Convolutional Neural Network (CNN)* ini adalah jenis pembelajaran yang menggunakan mesin untuk mengidentifikasi jenis penyakit gigi. Di sana, sistem akan mengumpulkan dan menganalisis data tentang penyakit karies dan periodontal (Muhammad Haris Diponegoro et al., 2021).

2.1.2. Machine Learning

Machine learning adalah proses mengumpulkan banyak data tentang penyakit dalam bentuk data besar dan menyimpannya dalam file, sehingga data dapat diakses kapan saja jika diperlukan. Jika digunakan dalam proses penelitian medis, pengajaran mesin menggunakan teknik data akan cepat menentukan jenis kerusakan pada gigi. Tujuan penelitian ini adalah untuk mengevaluasi kinerja jenis klasifikasi tertentu. Mempunyai proses, yaitu pelatihan, pembelajaran, menjadikan *machine learning* ini membutuhkan data yang dapat dipelajari dan dilatih. Salah satu metode pengajaran mesin adalah proses klasifikasi, yang menggunakan mesin untuk memilih dan mengklasifikasikan suatu objek berdasarkan ciri yang

disesuaikan dengan cara manusia mencoba jenis objek dengan jenis objek lainnya (Nirmal Kumar et al., 2022).

2.1.3. Convolutional Neural Network (CNN)

Convolution Neural Network ini berasal dari *Multiplayer Perceptron* (MLP) dan merupakan salah satu metode *Deep Learning*. CNN ini berfungsi sebagai sistem yang proses melalui pengolahan data dua dimensi. Selain itu melalui penggunaan data yang dilatih dan variable yang ditargetkan, metode pengajaran yang diawasi dapat digunakan untuk klasifikasi data yang terlabel. Tujuan dari metode ini adalah untuk mengelompokkan jenis data ke dalam data sebelumnya. Ini adalah CNN *deep learning* yang sering digunakan. Salah satu kelebihan CNN ini dibandingkan dengan versi sebelumnya adalah kemampuan secara otomatis untuk menemukan fitur relevan tanpa pengawasan manusia. Pemrosesan suara, pengenalan wajah, dan visi komputer adalah beberapa industri di mana CNN ini sangat digunakan. (Oroh & Lubis, 2023)

2.1.4. MobileNetV2

MobileNetV2 adalah arsitektur CNN yang ringan dan efisien yang dikhususkan untuk perangkat *mobile*. Terdiri dari dua bagian, *MobileNet* ini terbukti sangat efektif untuk berbagai aplikasi jenis komputer, seperti klasifikasi gambar, deteksi objek, dan penghapusan data, dll. Komponen *depthwise separable convolutions* dan *inverted residuals* memiliki kemampuan untuk mengurangi jumlah parameter yang harus dikorbankan melalui akurasi. Di sisi lain, *inverted residuals* memiliki kemampuan untuk meningkatkan jenis efisiensi dan akurasi model

MobileNet. Saat melakukan klasifikasi, MobilNet ini juga sangat digunakan. (ANHAR & PUTRA, 2023).

2.1.5. TensorFlow

Tensorflow adalah platform pembelajaran mesin sumber terbuka yang memiliki alat, perpustakaan, dan sumber daya komunitas yang luas yang memungkinkan peneliti pembelajaran mesin dan tim pengembangan membuat dan menerapkan aplikasi berbasis pembelajaran mesin dengan mudah. Arsitekturnya yang dapat disesuaikan memungkinkan penggunaannya di berbagai platform seperti desktop, tablet, dan ponsel. API pendeteksi objek Tensorflow memudahkan pengembangan aplikasi pembelajaran mendalam dan perangkat lunak pendeteksi objek. Anda dapat membuat, melatih, dan menerapkan model deteksi objek dengan framework sumber terbuka Tensorflow Object Detection. (Prastika & Zuliarso, 2021)

2.1.6. Pemodelan Sistem UML

Unified Modeling Language (UML) merupakan standar bahasa pemodelan yang digunakan untuk mendefinisikan, memvisualisasikan, membangun, dan mendokumentasikan elemen-elemen dalam sistem perangkat lunak. UML menyediakan beragam jenis diagram yang berfungsi mendukung proses desain sistem, seperti Use Case Diagram, Activity Diagram, Sequence Diagram, dan Class Diagram. Menurut (Wayahdi & Ruziq, 2023), jenis-jenis diagram UML yang dimanfaatkan meliputi Use Case Diagram untuk menggambarkan interaksi antara aktor dan sistem, Activity Diagram untuk menunjukkan alur aktivitas, Sequence Diagram untuk memodelkan interaksi antar objek berdasarkan waktu, dan Class Diagram untuk mendeskripsikan struktur kelas dalam sistem.

1.1.1.1. Use Case

Use Case Diagram adalah salah satu jenis diagram dalam *Unified Modeling Language* (UML) yang digunakan untuk menggambarkan fungsionalitas sistem dari perspektif pengguna (aktor). Diagram ini berfungsi untuk menjelaskan bagaimana pengguna (aktor) berinteraksi dengan sistem serta menggambarkan layanan yang diberikan sistem kepada aktor. Menurut (Wayahdi & Ruziq, 2023) terdapat beberapa komponen utama dalam sebuah Use Case Diagram, yaitu:

- 1) **Aktor (Actor)** Aktor adalah entitas eksternal yang berinteraksi langsung dengan sistem. Aktor bisa berupa pengguna manusia, sistem lain, atau perangkat eksternal yang berperan dalam proses bisnis sistem.
- 2) **Use Case** Use case menggambarkan fungsi atau layanan yang diberikan sistem kepada aktor.
- 3) **Asosiasi (Association)** Merupakan hubungan antara aktor dengan use case. Digambarkan dengan garis lurus yang menghubungkan aktor ke use case yang digunakannya.
- 4) **Sistem Boundary (Batas Sistem)** Batas sistem adalah kotak yang membungkus semua use case, menunjukkan mana proses yang merupakan bagian dari sistem dan mana yang berada di luar sistem.
- 5) **Relasi Include dan Extend** Include digunakan ketika suatu use case selalu melibatkan use case lain sebagai bagian dari prosesnya. Extend digunakan untuk menunjukkan bahwa suatu use case dapat diperluas dengan perilaku tambahan pada kondisi tertentu.

1.1.1.2. Diagram Activity

Diagram activity merupakan salah satu jenis diagram dalam *Unified Modeling Language* (UML) yang digunakan untuk merepresentasikan alur kerja atau aktivitas dalam sistem secara terstruktur. Diagram ini memodelkan urutan aktivitas yang dilakukan oleh sistem atau pengguna dari awal hingga akhir. Menurut (Wayahdi & Ruziq, 2023) activity diagram sangat berguna untuk menggambarkan logika proses system. Adapun komponen-komponen utama dari activity diagram adalah:

- 1) Initial Node (Titik Awal) Digambarkan dengan lingkaran berisi titik hitam, sebagai tanda dimulainya suatu alur proses.
- 2) Action/Activity (Tindakan/Aktivitas) Menunjukkan pekerjaan atau proses yang dilakukan, biasanya digambarkan dengan persegi panjang bersudut tumpul.
- 3) Decision Node (Keputusan) Menandakan titik percabangan alur berdasarkan kondisi tertentu, digambarkan dengan belah ketupat.
- 4) Merge Node (Penggabungan) Digunakan untuk menggabungkan beberapa alur menjadi satu kembali.
- 5) Fork dan Join Node (Pecahan dan Penggabungan Paralel) Fork membagi alur menjadi beberapa jalur paralel, sedangkan Join menyatukannya kembali.
- 6) Final Node (Titik Akhir) Digambarkan sebagai lingkaran dengan lingkaran kecil di dalamnya, yang menunjukkan akhir dari proses

2.2 Kajian Penelitian Terdahulu

Penelitian terkait dan yang relevan dengan topik “Pengembangan Model Deteksi Penyakit Gigi Berbasis Visi Komputer dengan Arsitektur MobileNetV2 (CNN) pada Poli Gigi Klinik Mitra Sehat Karawang” Berikut beberapa paper penelitiannya:

2.2.1 Paper 1

Jurnal ini berjudul "Klasifikasi Penyakit Periodontal Pada Citra Panoramik Gigi Menggunakan Deep Learning Berbasis ResNet50". Ditulis oleh (Syaripudin et al., 2025). Dipublikasikan di Sisinfo: Jurnal Sistem Informasi dan Informatika, Volume 7 No. 1, Februari 2025. Jurnal ini terindeks SINTA 4

2.2.1.1 Tujuan Penelitian

Bertujuan untuk mengembangkan dan mengevaluasi model klasifikasi berbasis deep learning menggunakan arsitektur ResNet50 untuk mendeteksi penyakit periodontal dan non-periodontal dari citra rontgen panoramik gigi. Selain itu, penelitian ini juga bertujuan untuk mengatasi keterbatasan diagnosis manual yang bersifat subjektif dengan menghadirkan solusi otomatis berbasis kecerdasan buatan, sehingga dapat meningkatkan akurasi, efisiensi, dan konsistensi dalam proses diagnosis klinis penyakit periodontal. Model yang dikembangkan diharapkan dapat mengenali pola-pola visual spesifik pada citra medis dan mendukung tenaga medis dalam pengambilan keputusan berbasis data, khususnya dalam mendeteksi dini penyakit seperti kalkulus dan gingivitis.

2.2.1.2 Metodologi yang Digunakan

Metodologi dalam penelitian ini menggunakan pendekatan transfer learning dengan arsitektur ResNet50 yang telah dilatih sebelumnya (pre-trained) untuk memanfaatkan kemampuan ekstraksi fitur secara optimal. Dataset citra panoramik gigi diperoleh dari platform Kaggle dan melalui beberapa tahapan penting, yaitu preprocessing berupa normalisasi nilai piksel agar berada dalam rentang $[0,1]$, serta augmentasi data seperti rotasi, zoom, dan flipping guna meningkatkan variasi dan mencegah overfitting. Dataset kemudian dibagi menjadi tiga bagian, yakni 70% untuk pelatihan, 20% untuk validasi, dan 10% untuk pengujian. Arsitektur ResNet50 dimodifikasi dengan menyesuaikan top layer agar sesuai dengan tugas klasifikasi dua kelas (penyakit-periodontal dan non-periodontal). Evaluasi performa model dilakukan menggunakan metrik akurasi, precision, recall, serta analisis confusion matrix untuk menilai efektivitas dan generalisasi model dalam klasifikasi citra.

2.2.1.3 Temuan Utama

Temuan utama dalam penelitian ini menunjukkan bahwa akurasi keseluruhan model hanya mencapai 56%, yang mengindikasikan performa klasifikasi yang masih perlu ditingkatkan. Untuk kelas non-periodontal, model menunjukkan precision sebesar 0.53 dan recall sempurna sebesar 1.00, yang berarti model berhasil mengidentifikasi semua kasus non-periodontal namun dengan banyak prediksi positif yang salah. Sementara itu, untuk kelas periodontal, precision mencapai 1.00 namun recall sangat rendah yakni 0.12, yang menandakan bahwa model sering gagal mendeteksi sebagian besar kasus periodontal. Analisis

confusion matrix memperkuat temuan ini dengan menunjukkan adanya bias kuat model terhadap kelas non-periodontal, yang tercermin dari tingginya jumlah false negative dalam klasifikasi penyakit periodontal.

2.2.1.4 Kesimpulan Penelitian

Model ResNet50 dalam penelitian ini mampu memproses citra rontgen panoramik gigi dan mengklasifikasikan antara penyakit periodontal dan non-periodontal dengan mengenali pola-pola visual tertentu. Namun, performa model masih belum optimal, khususnya dalam mendeteksi penyakit periodontal, yang ditunjukkan oleh rendahnya nilai recall dan tingginya false negative. Oleh karena itu, diperlukan upaya perbaikan seperti penyeimbangan dataset, augmentasi data yang lebih kompleks, serta fine-tuning model agar akurasi dan kemampuan generalisasi dapat ditingkatkan, sehingga model dapat lebih efektif dan andal dalam mendukung diagnosis klinis penyakit periodontal.

2.2.2 Paper 2

Jurnal ini berjudul “System Deteksi Gingivitis Gigi Menggunakan Certainty Factor” oleh (Rianti et al., 2021) dari Universitas Putra Indonesia YPTK Padang. Artikel ini dipublikasikan dalam Jurnal Teknologi Informasi (JITEKIN), Volume 11, Nomor 2, Tahun 2021, dan terindeks SINTA 4.

2.2.2.1 Tujuan Penelitian

Penelitian ini bertujuan untuk mengembangkan sistem pakar berbasis teknologi informasi yang dapat membantu pasien dalam mendiagnosis penyakit gingivitis secara mandiri tanpa harus berkonsultasi langsung dengan dokter,

memberikan solusi awal sebagai acuan sebelum penanganan lebih lanjut, serta meningkatkan edukasi dan kesadaran masyarakat mengenai pentingnya menjaga kesehatan gigi dan mulut guna mencegah terjadinya penyakit gingivitis yang sering kali dianggap sepele.

2.2.2.2 Metodologi Yang Digunakan

Penelitian menggunakan metode Certainty Factor, dengan pengumpulan data melalui pakar (dokter gigi), serta pengkodean gejala dan jenis gingivitis (akut, sub-akut, rekuren, kronis). Sistem dibangun menggunakan pendekatan rule-based dan mesin inferensi untuk menghasilkan tingkat keyakinan diagnosis berdasarkan input gejala dari pengguna.

2.2.2.3 Temuan Utama

Sistem berhasil mengidentifikasi jenis gingivitis dengan tingkat keyakinan hingga 95%, berdasarkan input gejala dari pengguna. Sistem dinilai cukup akurat karena data dan aturan diagnosis berasal langsung dari pakar, dan mampu memberikan konsultasi awal tanpa pasien perlu bertemu langsung dengan dokter.

2.2.2.4 Kesimpulan Penelitian

Sistem pakar ini efektif sebagai sarana konsultasi awal bagi pasien untuk mendiagnosa gingivitis, memberikan informasi penyakit serta solusi awal sebelum pengobatan lebih lanjut. Dengan akurasi tinggi dan metode certainty factor, sistem ini berpotensi menjadi layanan pendukung diagnosis berbasis IT yang praktis dan efisien.

2.2.3 Paper 3

Jurnal ini berjudul "Implementasi Metode Naïve Bayes Pada Sistem Pakar Diagnosa Penyakit Gigi Berbasis Web" oleh (Firdaus & Yanti, 2022) dari Universitas Pamulang. Penelitian ini dipublikasikan dalam jurnal Dinamika Informatika, Vol. 14 No. 2, Oktober 2022, yang terindeks SINTA 4.

2.2.3.1 Tujuan Penelitian

Penelitian ini bertujuan untuk mengembangkan sistem pakar berbasis web menggunakan metode Naïve Bayes yang dapat membantu masyarakat dalam mendiagnosis berbagai penyakit gigi secara mandiri, memberikan solusi awal yang dapat digunakan sebagai acuan sebelum mendapatkan penanganan medis lanjutan, serta meningkatkan kesadaran masyarakat akan pentingnya menjaga kesehatan gigi dan mulut, mengingat masih terbatasnya jumlah dokter gigi serta tingginya biaya konsultasi yang menjadi kendala bagi sebagian besar masyarakat untuk mendapatkan layanan kesehatan gigi secara langsung.

2.2.3.2 Metodologi yang Digunakan

Penelitian ini menggunakan metode Naïve Bayes untuk mengklasifikasikan penyakit gigi berdasarkan gejala-gejala yang diinputkan oleh pengguna. Data gejala dan penyakit dikumpulkan melalui wawancara dan observasi di Klinik Gigi Amaliyah 3. Sistem dibangun dengan bahasa pemrograman PHP dan database MySQL, serta diuji secara manual dan otomatis untuk mengukur akurasi diagnosa.

2.2.3.3 Tujuan Utama

Hasil uji coba terhadap 10 pasien secara acak menunjukkan bahwa 8 dari 10 hasil diagnosa sistem sesuai dengan diagnosa pakar (dokter gigi), sehingga tingkat akurasi sistem mencapai 80%, menunjukkan sistem cukup akurat dan dapat digunakan sebagai alat bantu diagnosis awal.

2.2.3.4 Kesimpulan Penelitian

Sistem pakar berbasis web yang dibangun dengan metode Naïve Bayes ini mampu mengidentifikasi penyakit gigi berdasarkan gejala dengan cukup akurat. Sistem ini dapat menjadi alternatif konsultasi awal bagi masyarakat, memberikan solusi awal, dan meningkatkan pemahaman tentang kesehatan gigi tanpa harus mengeluarkan biaya untuk berkonsultasi langsung.