

cek2

by Masjudin masjudin

Submission date: 12-Jun-2025 03:26PM (UTC+0700)

Submission ID: 2697494511

File name: Analisis_Citra_Computerized_Tomography_CT_Scan_Organ_Ginjal.pdf (960.96K)

Word count: 12625

Character count: 79020

8
BAB I
PENDAHULUAN

1.1. Latar Belakang

Ginjal merupakan organ manusia dengan bentuk seperti kacang dan terletak di bagian bawah rusuk (rongga *retroperitoneal*) [1], [2]. Ginjal yang terletak di kiri dan kanan tubuh manusia ini menjadi organ yang memiliki peranan penting dalam sistem ekskresi atau sistem yang mengatur pengeluaran zat racun atau berbahaya dari dalam tubuh [1], [2], [3], [4], [5], [6]. Seperti organ tubuh lainnya, ginjal juga dapat mengalami gangguan yang berakibat buruk pada tubuh manusia. Gangguan ginjal diartikan sebagai suatu kondisi saat fungsi ginjal mengalami penurunan yang tidak dapat kembali lagi dan bersifat progresif [7]. Hal ini menyebabkan tubuh tidak mampu mempertahankan kondisi ideal dari elektrolit, cairan, dan metabolisme [4], [7]. Selain itu, gangguan pada ginjal juga dapat menyebabkan kerusakan secara fisik pada ginjal dan tingginya kadar urea dalam darah yang membahayakan tubuh [7]. Adapun beberapa penyakit yang dapat menyebabkan terjadinya gangguan ginjal, antara lain batu ginjal, tumor ginjal, polikistik ginjal (kista ginjal), hingga berakhir pada Gagal Ginjal Kronis (GGK) [3], [4], [5], [8], [9], [10], [11]. Upaya yang dapat dilakukan dalam mendeteksi adanya gangguan pada ginjal ini salah satunya melalui analisis citra *Computerized Tomography (CT) scan* [5], [8], [9], [10].

CT scan merupakan alat medis yang memiliki fungsi untuk memperoleh citra yang menunjukkan bagian dalam tubuh manusia [1], [12], [13]. Citra yang dihasilkan alat ini merupakan citra keabu-abuan yang mendeskripsikan letak organ, luas massa organ, ukuran organ, dan kelainan pada organ [1], [13]. Hasil citra ini yang digunakan oleh tenaga kesehatan dalam mengklasifikasikan dan mendiagnosis penyakit yang diderita pasien [13], [14]. Seiring perkembangan teknologi, mulai dikembangkannya *Artificial Intelligence (AI)* untuk melakukan klasifikasi dan diagnosis penyakit ginjal melalui citra *CT scan* [1], [2], [5], [8], [9], [10]. Konsep AI yang diaplikasikan dalam diagnosis atau klasifikasi penyakit ginjal melalui citra *CT scan* ini disebut dengan klasifikasi gambar atau *image classification*.

Klasifikasi gambar atau *image classification* merupakan topik penelitian dalam bidang *machine learning* yang memberikan kemampuan pada komputer untuk dapat mengklasifikasikan citra masukan ke dalam beberapa kelas. Proses klasifikasi ini didasari pada pengambilan fitur-fitur penting dalam sebuah gambar dan fitur tersebut digunakan dalam proses klasifikasi [1], [5], [8], [9], [10]. Klasifikasi gambar ini banyak dimanfaatkan dalam klasifikasi objek, deteksi objek, segmentasi objek, dan *computer vision* di segala lini kehidupan manusia [5], [8], [9], [10], [15]. Salah satu penerapan klasifikasi gambar dalam bidang medis yaitu klasifikasi penyakit ginjal melalui analisis citra CT scan organ ginjal [1], [2], [4], [5], [8], [9], [10].

Penerapan AI dalam proses klasifikasi dan diagnosis penyakit ginjal melalui citra CT scan dilakukan dengan mengekstraksi fitur yang ada pada citra [1], [5], [8], [9], [10]. Selanjutnya, fitur-fitur ini akan digunakan pada proses klasifikasi melalui algoritma klasifikasi seperti *Artificial Neural Network* (ANN) dan *Support Vector Machine* (SVM) [9], [15]. Sebelumnya telah dilakukan penelitian klasifikasi penyakit ginjal melalui citra CT scan axial organ ginjal dengan ekstraksi fitur menggunakan *Convolutional Neural Network* (CNN) yang menghasilkan akurasi sebesar 75,17 % dan nilai *f1-score* sebesar 68 % [1]. Pada penelitian lain digunakan *Heterogeneous Modified Artificial Neural Network* (HMANN) dan dihasilkan kesimpulan bahwa pada CT scan masih ditemukan *noise* dan kompleksitas sehingga proses segmentasi dan klasifikasi belum optimal [9]. Berdasarkan penelitian sebelumnya diketahui bahwa permasalahan dalam klasifikasi gambar terutama menggunakan citra CT scan yaitu kualitas model klasifikasi, *noise* pada gambar, dan kompleksitas dari gambar.

Berdasarkan permasalahan ini dilakukan analisis keakuratan model dan keefektifan penggunaan *feature descriptor* dalam proses klasifikasi penyakit ginjal melalui citra CT scan. Pertama, melakukan analisis performa model yang dilatih dengan representasi piksel citra CT scan dan mengidentifikasi permasalahan pada proses klasifikasi tersebut. Kemudian, model terbaik dari analisis tersebut dikombinasikan dengan *feature descriptor* untuk mengetahui keakuratan model dan keefektifan penggunaan *feature descriptor* dalam mengatasi permasalahan yang ada.

1.2. Rumusan Masalah

Berdasarkan latar belakang didapatkan rumusan masalah sebagai berikut.

1. Adanya *noise* dan kompleksitas citra CT scan yang membuat proses klasifikasi tidak optimal.
2. Adanya ketidakakuratan proses klasifikasi penyakit ginjal melalui analisis citra CT scan organ ginjal.

1.3. Tujuan Penelitian

Berdasarkan rumusan masalah didapatkan tujuan penelitian sebagai berikut.

1. Menganalisis keakuratan pada klasifikasi penyakit ginjal melalui analisis citra CT scan organ ginjal.
2. Mengetahui keefektifan penggunaan *feature descriptor* dalam proses klasifikasi penyakit ginjal melalui analisis citra CT scan organ ginjal.

1.4. Manfaat Penelitian

Adapun manfaat dilakukannya penelitian ini sebagai berikut.

1. Bagi akademisi atau peneliti, hasil dari penelitian ini diharapkan dapat dikembangkan dan dijadikan acuan dalam menciptakan arsitektur atau metode pengolahan citra yang lebih baik dan akurat.
2. Bagi masyarakat, hasil dari penelitian ini diharapkan dapat mengatasi masalah kesalahan diagnosis yang mengancam keselamatan masyarakat.
3. Bagi rumah sakit dan lembaga kesehatan, hasil dari penelitian ini diharapkan dapat mengoptimalkan pemanfaatan dari alat CT scan.

1.5. Batasan Masalah

Adapun batasan masalah dalam penelitian ini sebagai berikut.

1. Penelitian ini berfokus pada penyakit ginjal yang dapat dideteksi oleh CT scan, seperti kista ginjal, tumor ginjal, dan batu ginjal.
2. Pada penelitian ini citra medis yang dilakukan analisis dan pengolahan yaitu citra hasil CT scan.

3. Pada penelitian ini digunakan citra CT scan berformat *axial*.
4. Pada penelitian ini digunakan arsitektur *Support Vector Machine* (SVM), *Multi-Layer Perceptron* (MLP), dan *Naive bayes* dalam proses klasifikasi.
5. Pada penelitian ini digunakan *feature descriptor Histogram of Oriented Gradient* (HOG), *Scale Invariant Feature Transform* (SIFT), *Local Binary Pattern* (LBP), *Grey Level Co-occurrence Matrix* (GLCM), dan *Convolutional Neural Network* (CNN).
6. Pada penelitian ini digunakan metode pengolahan untuk *grayscale image*.
7. Pada penelitian ini digunakan citra CT scan organ ginjal yang berasal dari *Picture Archiving Communication System* (PACS) yang dikumpulkan dari beberapa rumah sakit berbeda di Dhaka, Bangladesh dan dapat diakses melalui Kaggle.

1.6.

Sistematika Penulisan

Adapun sistematika penulisan dalam penelitian ini sebagai berikut.

BAB I Pendahuluan

Bab ini berisi latar belakang, rumusan masalah, tujuan penelitian, manfaat penelitian, batasan masalah, dan sistematika penulisan.

BAB II Tinjauan Pustaka

Bab ini menjelaskan tentang dasar teori, referensi, dan komponen pendukung lainnya.

BAB III Metodologi Penelitian

Bab ini membahas tahapan penelitian dari awal hingga akhir yang ditandai dengan didaptkannya data hasil penelitian dan kesimpulan.

BAB IV Hasil dan Pembahasan

Bab ini membahas hasil yang diperoleh dari pengujian dan analisis dari hasil tersebut sesuai dengan tujuan penelitian.

BAB V Penutup


Bab ini berisi kesimpulan dari hasil penelitian yang telah dilakukan dan saran untuk penelitian selanjutnya.

BAB II

TINJAUAN PUSTAKA

2.1. Ginjal

Ginjal merupakan sepasang organ berbentuk seperti kacang yang terletak di bagian bawah rusuk (rongga *retroperitoneal*) dan hanya berukuran segenggam tangan manusia [1], [2]. Ginjal yang terletak di kiri dan kanan tubuh manusia ini menjadi organ yang memiliki peranan penting dalam kelangsungan hidup manusia, salah satunya pada sistem ekskresi [1], [2], [3], [4], [5], [6]. Sistem ekskresi merupakan sebuah proses dalam tubuh manusia yang bertujuan untuk dapat mengeluarkan sampah-sampah hasil metabolisme seperti urea, racun, dan lainnya [1], [2], [4], [5], [6]. Pada sistem ekskresi ini, ginjal berfungsi untuk dapat menyaring darah dari sampah-sampah hasil metabolisme seperti urea sebelum darah dialirkan kembali ke seluruh tubuh [1], [2], [4], [5], [6]. Sampah yang berhasil disaring ini akan dikeluarkan bersamaan dengan dikeluarkannya urine [1]. Adapun letak ginjal pada struktur tubuh manusia dapat diamati pada Gambar 2.1.



Gambar 2.1 Struktur Tubuh Manusia [2]

Selain sebagai organ ekskresi, ginjal juga memiliki peran untuk menjaga keseimbangan metabolisme manusia dengan mengatur kadar garam, PH, dan potasium dalam tubuh [2]. Sehingga saat ginjal mengalami gangguan, maka tubuh akan menerima dampak buruk dari metabolisme tubuh yang tidak seimbang. Selain itu, saat ginjal mengalami gangguan, fungsi penyaringan ginjal menjadi tidak optimal. Hal ini yang menyebabkan munculnya darah yang tercampur dalam urine saat melakukan buang air kecil pada pasien penderita gangguan ginjal.

2.2. Batu Ginjal

Batu ginjal atau *nefrolitiasis* merupakan penyakit yang terjadi pada organ ginjal saat adanya batu atau material keras dalam organ [11]. Material keras ini terbentuk akibat proses kristalisasi atau asam endapan dari kalsium dan oksalat yang menumpuk pada ginjal [11], [16]. Terjadinya kristalisasi ini disebabkan konsentrasi zat pembentuk material telah berada pada konsentrasi tinggi [17].

Faktor penyebab adanya batu ginjal dapat bersumber dari kebiasaan minum air putih yang tidak teratur, serta sering mengonsumsi makanan dan minuman yang mengandung pemanis buatan ataupun gula berlebihan [18]. Adanya batu atau material keras pada organ ginjal dapat memberikan dampak membahayakan pada tubuh penderitanya. Batu ginjal dapat menghambat terjadinya penyerapan kembali air dan elektrolit dalam urine, serta dapat mengakibatkan rasa sakit akibat terhentinya aliran urine [17].

2.3. Tumor Ginjal

Tumor ginjal merupakan salah satu penyakit mematikan yang menyerang organ ginjal manusia. Penyakit ini disebabkan oleh adanya perkembangan sel yang tidak terkendali dan cenderung abnormal pada organ ginjal [3], [19]. Tumor ginjal terbagi menjadi dua jenis yaitu tumor jinak dan tumor ganas [19]. Pada kasus tumor ganas, penyakit ini dapat menyebabkan komplikasi pada organ tubuh lain dan dapat merusak bentuk fisik ginjal sehingga terjadi penurunan fungsi ginjal [20].

Gejala yang dialami pasien penderita tumor ginjal tidak akan terasa hingga berada pada stadium lanjut [3], [20]. Adapun gejala yang dapat menjadi indikasi awal dalam diagnosis penyakit ini yaitu nyeri pinggang dan darah dalam urine [3]. Selain dari gejala yang tampak, deteksi dini tumor ginjal dapat dilakukan melalui pemeriksaan radiologi, salah satunya yaitu pengambilan citra CT *scan* ginjal. Citra CT *scan* ginjal ini digunakan oleh tenaga medis untuk melakukan diagnosis penyakit dari ciri-ciri yang dapat diamati pada citra.

2.4. Kista Ginjal

Kista merupakan sebuah penyakit berupa benjolan atau kantung yang terbentuk pada area tubuh tertentu. Benjolan atau kantung ini berisi udara, cairan,

maupun zat lain dengan ukuran yang bervariasi mulai dari milimeter hingga senti meter. Penyakit kista yang umum terjadi pada ginjal yaitu *Polikistik Kidney Disease* (PKD). PKD merupakan penyakit pada organ ginjal yang disebabkan adanya beberapa kista yang tumbuh di area medula dan korteks [20].

Adanya kista pada ginjal tentu akan berakibat pada terganggunya dan penurunan fungsi pada ginjal. Hal ini akan menyebabkan ginjal bekerja tidak maksimal dan berakibat pada tidak seimbangnya metabolisme dalam tubuh. Saat kista pada ginjal mulai membesar, ginjal dapat mengalami kerusakan jaringan akibat tekanan kista yang membesar [20]. Selain itu, kista ini juga dapat menyebar ke organ lain seperti hati dan akan berpotensi menyebabkan komplikasi.

2.5. ⁴³ **Computerized Tomography (CT) Scan**

Computerized Tomography (CT) scan atau *Computed Tomography (CT) scan* merupakan alat medis yang digunakan dalam memperoleh gambaran kondisi bagian dalam tubuh dengan berdasarkan penyerapan sinar X [12]. *CT scan* ini menghasilkan citra berwarna hitam putih yang menunjukkan letak, ukuran, massa dan kelainan pada organ. Adapun format hasil citra dari alat ini terbagi menjadi tiga yaitu *axial*, *coronal*, dan *sagittal*. *CT scan* ini digunakan oleh tenaga medis sebagai sarana diagnostik karena memiliki kemampuan untuk menyajikan informasi dengan lebih rinci dan akurat.

Dalam pengaplikasiannya, *CT scan* ⁵³ memiliki kelebihan dan kekurangan jika dibandingkan dengan metode radiografi lainnya. Kelebihan yang dimiliki *CT scan* yaitu citra *CT scan* yang disajikan dalam bentuk 3D, dapat digunakan dalam mempelajari aliran darah dan kandungan mineral, serta memiliki resolusi kontras yang sangat baik [12]. Adapun keterbatasan yang dimiliki *CT scan* yaitu sulit memperoleh citra saat pada tubuh pasien terdapat bahan metal, memiliki dosis radiasi tinggi pada setiap bagian tubuh, dan keterbatasan saat melakukan pencitraan pada organ yang dikelilingi tulang seperti sum-sum tulang belakang [12].

2.6. **Artificial Intelligence**

Artificial Intelligence (AI) atau kecerdasan buatan merupakan suatu metode atau teknologi yang memungkinkan komputer memiliki kemampuan layaknya

manusia [21]. AI dapat berpikir dan mengambil keputusan layaknya manusia dari proses belajar melalui sekumpulan data dan pelatihan. Dalam proses pembelajarannya, AI dapat memahami data yang diberikan, menentukan hubungan dari data, dan memperbaiki kesalahan pemahaman pada data. Sehingga dengan proses ini, AI dapat menjadi alat berperforma tinggi dalam menyelesaikan Permasalahan manusia.

AI saat ini telah banyak diaplikasikan dalam segala lini kehidupan manusia. Bidang-bidang pengaplikasian AI meliputi transportasi, medis, Pendidikan, media, hingga bisnis [21]. Pada penelitian ini, AI dimanfaatkan dalam bidang medis untuk melakukan klasifikasi penyakit berdasarkan citra CT *scan* yang diberikan. Citra CT *scan* yang berlaku sebagai data digunakan AI untuk mempelajari fitur untuk setiap kelas. Sehingga komputer dapat mengklasifikasikan citra CT *scan* ke dalam 4 kelas berbeda yaitu batu ginjal, tumor ginjal, dan kista ginjal.

2.7. ² Machine Learning

Machine learning (ML) atau pembelajaran mesin merupakan cabang dari AI yang memiliki kemampuan untuk mempelajari data dan membuat prediksi atas data yang telah dipelajari [22]. Dalam ML, proses belajar terdiri dari dua tahapan yaitu pelatihan dan pengujian. Proses pelatihan diawali saat algoritma menerima sekumpulan data dan mempelajari fitur-fitur yang berguna dalam kasus yang hendak diselesaikan. Kemudian, proses pengujian dilakukan untuk mengetahui kualitas dari model yang telah dilatih. Proses pengujian ini dapat dilakukan secara internal selagi proses pelatihan seperti *cross validation* maupun eksternal setelah pelatihan melalui *testing*.

ML terbagi menjadi tiga cabang yaitu *supervised learning*, *unsupervised learning*, dan *reinforcement learning* [22], [23]. *Supervised learning* merupakan cabang ML yang belajar dari sejumlah besar data yang telah dilabeli, seperti klasifikasi dan regresi [22], [23]. Kemudian, *unsupervised learning* merupakan cabang ML yang belajar dari sejumlah besar data yang tidak dilabeli, seperti *clustering* dan asosiasi [22], [23]. Terakhir, *reinforcement learning* merupakan cabang ML yang belajar melalui konsep “*trial and error*” yang akan menerima

reward saat berhasil dan menerima *punishment* saat gagal [22]. Contoh penerapan algoritma *reinforcement learning* adalah *lunar lander*.

Pada penelitian ini digunakan cabang ML *supervised learning*. *Dataset* yang digunakan pada penelitian berupa citra CT scan ginjal yang telah dilabeli dan terbagi ke dalam empat kelas. Adapun kelas atau kategori yang digunakan pada penelitian ini yaitu batu ginjal, tumor ginjal, kista ginjal, dan ginjal normal. Fitur-fitur pada citra di setiap label dipelajari oleh algoritma dan menentukan fitur penting yang membedakan antara satu kelas dengan kelas yang lain. Sehingga saat dilakukan pengujian dengan data baru, algoritma dapat mengategorikan citra masukan ke dalam 4 kelas tersebut.

2.8. Computer Vision

Computer vision atau visi komputer merupakan salah satu cabang dari *machine learning* yang memberikan kemampuan pada komputer untuk melihat layaknya manusia. Selain itu, visi komputer juga digunakan dalam proses pengumpulan informasi dari sebuah gambar ataupun video [24]. Proses identifikasi ini dilakukan oleh komputer dengan mengamati pola pada *pixel representation* suatu gambar atau video. Selanjutnya, hasil identifikasi ini dapat digunakan dalam berbagai aplikasi seperti klasifikasi objek, deteksi objek, hingga segmentasi objek.

Pada penelitian ini, konsep visi komputer digunakan dalam proses klasifikasi penyakit ginjal melalui analisis citra CT Scan ginjal. Visi komputer digunakan dalam mengidentifikasi pola atau fitur yang membedakan citra CT scan ke dalam 4 kelas yaitu batu ginjal, tumor ginjal, kista ginjal, dan ginjal normal. Dalam penelitian ini, visi komputer dioptimalkan dengan penggunaan *feature descriptor* agar menghasilkan representasi fitur yang sederhana dan bersih dari *noise*.

2.9. Grayscale Image

Citra merupakan gambaran atau representasi dari sebuah objek yang terbentuk dari unsur penyusunnya seperti titik, garis, bidang, dan bentuk. Citra digunakan pada banyak aplikasi untuk mengabadikan atau memperoleh informasi dari suatu objek. Salah satu bidang yang memanfaatkan citra adalah bidang medis

dan komputer. Citra dalam bidang medis dimanfaatkan untuk menampilkan informasi dan kondisi pasien melalui pencitraan *CT scan* atau metode radiografi lainnya. Selanjutnya, citra medis hasil proses pencitraan dikonversi menjadi citra digital dan dilakukan analisis melalui komputer. Salah satunya melalui pemanfaatan AI dalam proses diagnosis dan klasifikasi penyakit.

Citra digital merupakan citra yang tersusun atas sekumpulan piksel dengan ukuran dan koordinat tertentu. Piksel didefinisikan sebagai unit yang memberikan warna pada gambar berdasarkan nilai representasi pikselnya. Berdasarkan pewarnaan ini, citra terbagi menjadi tiga yaitu citra warna, citra *grayscale*, dan citra biner [25]. Citra warna merupakan citra yang tersusun atas tiga lapisan yaitu *Red*, *Green*, dan *Blue* (RGB) dengan nilai representasi piksel berkisar 0-255 untuk format citra 8 bit. Kemudian, citra *grayscale* merupakan citra yang tersusun dari satu lapisan dengan nilai representasi piksel berkisar 0-255. Pada citra *grayscale*, semakin tinggi nilai representasi piksel maka akan semakin mendekati warna putih dan sebaliknya saat nilai representasi piksel semakin rendah maka akan semakin mendekati warna hitam. Selanjutnya, citra biner didefinisikan sebagai citra yang hanya memiliki satu lapisan dengan nilai representasi piksel hanya 0 atau 1. Nilai representasi piksel 0 mewakili warna hitam dan nilai representasi piksel 1 mewakili warna putih. Adapun penampakan citra warna, citra *grayscale*, dan citra biner dapat diamati pada Gambar 2.2.



Gambar 2.2 (a) Citra Warna, (b) Citra *Grayscale*, (c) Citra Biner [26]

2.10. Bahasa Pemrograman *Python*

Bahasa pemrograman *Python* merupakan salah satu Bahasa pemrograman *open-source* yang saat ini populer digunakan oleh para *programmer* di seluruh dunia. Bahasa pemrograman *Python* pertama kali diciptakan oleh Guido van Rossum asal belanda pada tahun 1990 [26], [27]. Awalnya Bahasa pemrograman *Python* ini dibuat sebagai bahasa pemrograman tingkat tinggi untuk sistem operasi

Amoeba [26]. Namun seiring perkembangan teknologi, bahasa pemrograman *Python* merambah ke segala bidang pemrograman seperti *software development*, *web development*, hingga AI.

Bahasa pemrograman *Python* memegang tiga prinsip utama yaitu *coherence*, *power*, dan *scope* [26]. Prinsip *coherence* berarti bahasa *Python* dapat dengan mudah ditulis, dibaca, dan dilakukan pemeliharaan [26]. Kemudian, prinsip *power* berarti bahasa *Python* dapat digunakan pada fungsi yang tidak terbatas [26]. Selanjutnya, prinsip *scope* berarti bahasa *Python* dapat diaplikasikan dalam setiap bidang pemrograman [26].

2.11. *Image Classification*

Klasifikasi merupakan suatu kegiatan mengelompokkan sebuah objek ke dalam beberapa kategori berdasarkan ciri atau fitur tertentu yang membedakannya. Proses klasifikasi tidak dapat dipisahkan dari kehidupan manusia, baik pada objek yang tampak maupun tidak. Klasifikasi objek yang tampak seperti membedakan antara kucing dengan tikus, sedangkan klasifikasi objek yang tidak tampak seperti membedakan antara perilaku baik dan buruk. Kemampuan klasifikasi pada manusia dapat diaplikasikan juga pada komputer melalui algoritma AI salah satunya sebagai klasifikasi gambar.

Klasifikasi gambar diartikan sebagai suatu proses yang membedakan dan mengelompokkan objek dari beberapa kategori berdasarkan ciri dan fitur yang dimilikinya. Kemudian, proses klasifikasi menggunakan algoritma AI berhubungan erat dengan salah satu cabang ML yaitu *supervised learning* [22], [23]. Pada proses klasifikasi dengan *supervised learning*, algoritma mempelajari ciri dan fitur yang mewakili sekaligus membedakan antara objek dalam satu kelas dengan kelas lain dari data yang telah dilabeli. Sehingga saat program menerima masukan berupa gambar baru, maka algoritma tersebut dapat mengelompokkannya ke dalam suatu kelas sesuai dengan hasil pelatihan. Contoh dari penerapan klasifikasi gambar menggunakan AI yaitu klasifikasi penyakit ginjal citra CT scan organ ginjal, klasifikasi keaslian gambar, serta klasifikasi identitas [28], [29].

2.12. *Image Processing*

Pengolahan citra atau *image processing* merupakan sebuah proses yang dilakukan untuk tujuan tertentu melalui pengolahan pada piksel citra yang menyusun gambar [30]. Pada awalnya, pengolahan citra ditujukan untuk memperoleh gambaran citra yang lebih baik untuk dilakukan analisis [30]. Namun seiring perkembangan zaman, pengolahan citra digunakan dalam proses pengambilan informasi yang terkandung dalam gambar [30].

Pengolahan citra yang ditujukan untuk memperoleh gambar yang lebih baik contohnya penggunaan *image enhancement technique* dan *image sharpened technique*. Penggunaan kedua teknik ini ditujukan untuk memperoleh gambar yang lebih jelas dan tajam. Hasil dari proses ini dapat diaplikasikan pada proses lain, salah satunya deteksi garis tepi (*edge detection*). Kemudian, pengolahan citra yang ditujukan untuk memperoleh informasi dari sebuah gambar dapat dilakukan melalui proses ekstraksi fitur. Proses ekstraksi fitur ini mengambil informasi-informasi penting dalam gambar melalui penggunaan *feature descriptor* seperti HOG dan LBP.

2.13. *Feature Descriptor*

Feature descriptor merupakan representasi angka dari fitur sebuah citra atau objek yang diperoleh dari proses pengolahan citra. Penggunaan *feature descriptor* bertujuan untuk merangkum karakteristik fitur dari sebuah citra [31]. Karakteristik yang fitur yang berhasil dirangkum dikonversi ke dalam bentuk representasi angka yang lebih sederhana. Kemudian, hasil representasi angka dari fitur yang berhasil diekstraksi dari sebuah citra dapat digunakan pada proses pencocokan, klasifikasi, dan analisis.

Feature descriptor yang baik memiliki dua karakteristik utama yaitu kekhasan dan ketahanan [32]. Karakteristik kekhasan menyatakan bahwa *descriptor* yang baik yaitu *descriptor* yang mampu menghasilkan representasi berbeda pada objek atau citra yang berbeda [32]. Sebagai contoh pada rekognisi wajah, representasi angka dari *descriptor* menghasilkan pola yang berbeda antara wajah A dan wajah B. Selanjutnya, karakteristik ketahanan menyatakan bahwa *descriptor* yang baik yaitu *descriptor* yang mampu bertahan atas transformasi dan

perubahan geometrik objek atau citra [32]. Perubahan ini meliputi ukuran, rotasi, kemiringan, dan posisi. Adapun contoh dari *feature descriptor* yaitu *Histogram of Oriented Gradient* (HOG), *Local Binary Pattern* (LBP), *Scale-Invariant Feature Transform* (SIFT), dan *Speed-Up Robust Feature* (SURF).

2.14. ⁴¹ *Histogram of Oriented Gradient* (HOG)

Histogram of Oriented Gradient (HOG) merupakan salah satu dari *descriptor* yang diciptakan oleh Dalal dan Trigs pada tahun 2005 [33], [34]. *Descriptor* HOG mampu mendeskripsikan dan merepresentasikan suatu objek atau citra melalui orientasi objek dan distribusi intensitas objek [33], [34]. Pada awalnya, *descriptor* ini dibuat untuk menyelesaikan Permasalahan deteksi manusia pada latar belakang yang memiliki banyak *noise* [34]. Namun saat ini, HOG telah diaplikasikan luas pada bidang ML, klasifikasi daun, klasifikasi penyakit kanker payudara, dan klasifikasi penyakit ginjal [33], [34].

Proses deskripsi fitur menggunakan HOG diawali dengan dilakukannya normalisasi gambar untuk mengatur intensitas cahaya agar citra memiliki kontras seimbang. Kemudian, gambar dilakukan pengukuran gradien pada arah x dan y. Selanjutnya, hasil pengukuran gradien pada arah x dan y digunakan untuk melakukan perhitungan magnitudo dan orientasi. Gradien dapat dihitung pada arah x dan y melalui persamaan sebagai berikut.

$$G_x = P * D_x ; G_y = P * D_y \quad (2.1)$$

$$|G| = \sqrt{G_x^2 + G_y^2} \quad (2.2)$$

$$\theta = \arctan2(G_y/G_x) \quad (2.3)$$

Persamaan 2.1 memiliki variabel di antaranya gradien sumbu x (G_x), gradien sumbu y (G_y), piksel (P), dan kernel (D_x dan D_y) [35]. Persamaan 2.1 digunakan untuk melakukan pengukuran gradien piksel dalam arah x untuk G_x dan dalam arah y untuk G_y [34]. Kemudian, persamaan 2.2 digunakan untuk menghitung nilai magnitudo gradien dari setiap piksel dalam sel [34], [35]. Selanjutnya, persamaan 2.3 digunakan untuk menghitung arah orientasi gradien setiap piksel [34], [35]. Informasi dari proses pengukuran dan perhitungan ini diekstraksi ke dalam


distribusi orientasi dan magnitudo. Lalu, citra di bagi menjadi sel-sel yang lebih besar. Kemudian, pada arah gradien setiap sel dibagi ke dalam 9 bin dengan 1 bin sama dengan perubahan 20° . Terakhir dilakukan normalisasi blok pada setiap sel agar lebih tahan terhadap iluminasi dan pembayangan. Adapun gambar citra hasil pengolahan menggunakan *descriptor* HOG dapat diamati pada Gambar 2.3.



Gambar 2.3 Visualisasi Citra HOG [35]

2.15. *Scale Invariant Feature Transform (SIFT)*

Scale Invariant Feature Transform (SIFT) merupakan salah satu *descriptor* yang bekerja berdasarkan gradien lokal [36]. *Descriptor* jenis ini bekerja dengan cara menghitung dan mengamati area lokal pada gambar yang berupa histogram arah gradien. *Descriptor* ini pertama kali dikembangkan pada tahun 1999 dan disempurnakan pada tahun 2004 oleh David Lowe [36]. Kemampuan dari *descriptor* ini dalam mengekstraksi fitur pada gambar yaitu dapat mendeteksi dan menggambarkan pola fitur suatu gambar berdasarkan posisi, skala, dan rotasi [36]. Adapun proses ekstraksi fitur SIFT divisualisasikan pada Gambar 2.4.



Gambar 2.4 Ruang Skala *Gaussian* pada SIFT [36]

2.16. ³² Local Binary Pattern (LBP)


Local Binary Pattern (LBP) merupakan salah satu ³³ dari *descriptor* yang diciptakan oleh Ojala ³⁴ untuk mengekstraksi tekstur dari sebuah gambar [37]. *Descriptor* ini bekerja menggunakan matriks ukuran 3x3 dengan membandingkan piksel yang berperan sebagai *threshold* dengan piksel tetangganya. Proses perbandingan ini menghasilkan nilai biner lokal dan nilai desimal. Adapun nilai biner lokal dapat ditentukan melalui persamaan sebagai berikut.

$$LBP_{PR} = \sum_{p=0}^{P-1} s(g_p - g_e)2^p \quad (2.4)$$

$$s(x) = \begin{cases} 1, & \text{if } x \geq 0; \\ 0, & \text{otherwise} \end{cases} \quad (2.5)$$

Persamaan 2.4 digunakan dalam perhitungan nilai LBP (LBP_{PR}) untuk setiap piksel tetangga (g_p) dengan piksel pusat (g_e) sebagai *threshold* [37]. Hasil dari perhitungan nilai LBP ini dibandingkan dengan ketentuan pada persamaan 2.5 [37]. Saat nilai LBP pada sebuah piksel bernilai lebih dari sama dengan 0, maka piksel bernilai 1. Sedangkan, saat nilai LBP pada sebuah piksel bernilai kurang dari 0, maka piksel tersebut bernilai 0.

Cara lain yang dapat digunakan untuk memperoleh pola biner LBP yaitu dengan membandingkan piksel tetangga dengan piksel pusat sebagai *threshold*. Kemudian, saat ³⁵ nilai piksel tetangga lebih besar sama dengan nilai piksel pusat maka akan menghasilkan nilai 1. Sedangkan saat ³⁶ nilai piksel tetangga lebih kecil dari piksel pusat, maka akan menghasilkan nilai 0. Adapun visualisasi pembentukan pola biner LBP dapat diamati pada Gambar 2.5.



Gambar 2.5 Visualisasi Pola Biner LBP

Kemudian, dari pola biner LBP dapat diperoleh nilai akhir LBP berupa nilai desimal dengan menjumlahkan hasil kali nilai *threshold* dengan nilai piksel yang sesuai.

Sehingga diperoleh visualisasi nilai akhir LBP yang dapat diamati pada Gambar 2.6.


2	3	14	21	30
5	3	4	7	25
4	5	2	11	12
7	8	24	7	8
8	24	5	10	9

		255		

Gambar 2.6 Visualisasi Nilai Akhir LBP

2.17. **Gray Level Co-occurrence Matrix (GLCM)**

Gray Level Co-occurrence Matrix (GLCM) merupakan salah satu *descriptor* yang bekerja untuk mengekstraksi fitur tekstur berdasarkan intensitas gambar. *Descriptor* ini banyak digunakan dalam aplikasi ekstraksi fitur, termasuk ekstraksi fitur pada citra CT Scan [9]. Hasil dari proses ekstraksi fitur GLCM dapat digunakan untuk klasifikasi gambar, analisis pola gambar, dan juga rekognisi pola gambar [38]. Visualisasi ekstraksi fitur GLCM dapat diamati pada Gambar 2.7.




Gambar 2.7 Proses Ekstraksi Fitur dengan GLCM [9]

Proses ekstraksi fitur citra menggunakan GLCM hingga diperoleh hasil fitur dilakukan dalam empat tahapan [39]. Pertama, membaca gambar dan mengubahnya menjadi citra skala keabuan. Kedua, menentukan nilai jarak dan sudut yang akan digunakan *descriptor* dalam menganalisis suatu gambar [39]. Ketiga, menghitung nilai GLCM dan mengekstraksi fitur dari gambar [39]. Keempat, hasil dari GLCM berupa nilai *contrast*, *homogeneity*, *energy*, dan *correlation* yang dapat digunakan untuk kebutuhan pelatihan model [39].

2.18. ³⁷ Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu *descriptor* yang bekerja berdasarkan pembelajaran. CNN mampu mempelajari pola representasi pada gambar melalui struktur yang tersusun secara sekuensial [36]. Susunan CNN yang terdiri dari beberapa lapis ini yang menjadikannya salah satu representasi dari algoritma *deep learning*. Semakin dalam struktur CNN yang dibuat, maka semakin kompleks pula fitur yang diekstraksi pada gambar [40]. Fitur yang berhasil di ekstraksi nantinya akan digunakan oleh model untuk proses klasifikasi. Adapun salah satu aplikasi CNN dapat diamati pada arsitektur *transfer learning* Gambar 2.8.




Gambar 2.8 Arsitektur Transfer Learning VGG16 [36]

Pada gambar 2.8 dapat diamati salah satu algoritma yang memanfaatkan CNN sebagai *feature extraction*. Pada arsitektur di atas, CNN bertindak untuk mengekstraksi fitur dari representasi piksel gambar masukan. Ekstraksi fitur setidaknya berlangsung pada 3 jenis lapisan yaitu lapisan konvolusi dan lapisan *pooling* [40]. Lapisan konvolusi berfungsi sebagai ekstraksi fitur dari data masukan sebanyak kedalaman yang ditentukan pada arsitektur. Lalu, untuk lapisan *pooling* berfungsi untuk mereduksi dimensi dari fitur dengan tetap mempertahankan informasi yang ada di dalamnya. Dalam lapisan konvolusi juga dikenal istilah *activation function* yang berfungsi untuk memperkenalkan non-linearitas pada model.

2.19. ⁷²Multi Layer Perceptron (MLP)

²⁹Multi Layer Perceptron (MLP) merupakan salah satu algoritma AI yang banyak diaplikasikan dalam regresi, klasifikasi, dan rekognisi. Pengaplikasian ini didasari oleh kemampuan MLP dalam melakukan penyesuaian bobot dan meminimalkan *error* sehingga menghasilkan komputasi yang optimal [33]. MLP memiliki keunggulan dalam menyelesaikan Permasalahan dengan data *non-linear*, *non-deterministik*, dan berdimensi tinggi [33]. Kemudian berdasarkan strukturnya, MLP terbagi menjadi tiga bagian yaitu lapisan *input*, lapisan tersembunyi, dan lapisan *output* [33].

Pada penelitian ini, ketiga bagian MLP digunakan dalam proses klasifikasi citra CT scan ginjal ke dalam empat kelas. Lapisan *input* sebagai lapisan pertama dalam MLP berfungsi untuk menerima data masukan dan setiap *node* dalam lapisan tersebut merepresentasikan fitur dari data masukan. Kemudian, fitur dari data masukan akan diproses dalam lapisan tersembunyi yang berada di antara lapisan *input* dan lapisan *output*. pada lapisan tersembunyi dilakukan penyesuaian bobot dan penggunaan *activation function* dalam upaya memodelkan hubungan dari data masukan. Selanjutnya, hasil dari proses pada lapisan *output* digunakan dalam mengklasifikasikan data masukan ke dalam beberapa kelas berdasarkan fitur-fitur yang berhasil diidentifikasi pada lapisan tersembunyi. Adapun visualisasi dari arsitektur MLP dapat diamati pada Gambar 2.9.



Gambar 2.9 Arsitektur Dasar Multi Layer Perceptron [33]

2.20. ² **Support Vector Machine (SVM)**

Support Vector Machine (SVM) merupakan salah satu algoritma *machine learning* yang baik digunakan dalam proses klasifikasi. Algoritma ini mampu memisahkan dan memetakan kelompok data ke dalam beberapa kategori [41]. Pemisahan ini dilakukan dengan membuat celah selebar mungkin atau menentukan garis pemisah antar kelas [41]. Sehingga saat terdapat data masukan, maka data tersebut dapat diklasifikasikan ke dalam kelas tertentu berdasarkan area yang dipisahkan celah atau garis [41].

Proses klasifikasi menggunakan algoritma SVM diawali dengan proses pemetaan data masukan ke dalam pelatihan positif dan negatif berdasarkan atribut yang dimiliki data masukan. kemudian, dari pemetaan tersebut dilakukan perhitungan garis pemisah atau *hyperlane* yang memisahkan setiap kelas dari data. Garis pemisah antar kelompok ini ditentukan berdasarkan margin garis ke vektor data pelatihan positif dan negatif terdekat.

2.21. ⁷³ **Naive Bayes**

Naive bayes merupakan salah satu model klasifikasi tradisional yang bekerja dengan dasar metode probabilitas [40]. Model *naive bayes* bekerja dengan cara menghitung kemiripan antara data pelatihan dengan data baru [40]. Proses perhitungan probabilitas pada *naive bayes* menggunakan *bayes theorem* [40]. *Bayes theorem* telah banyak digunakan dalam aplikasi *machine learning* karena memiliki kemampuan yang baik dalam mempelajari data pelatihan dengan adanya prediksi maksimum yang dapat diuji [42]. Adapun persamaan matematis dari *bayes theorem* adalah sebagai berikut.

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (2.6)$$

Dengan $P(A|B)$ yaitu probabilitas terjadinya peristiwa A, setelah peristiwa B terjadi; $P(B|A)$ yaitu probabilitas terjadinya peristiwa terjadinya B, setelah peristiwa A terjadi; $P(A)$ yaitu probabilitas terjadinya A; dan $P(B)$ yaitu probabilitas terjadinya B [42].

2.22. Kajian Pustaka

Penelitian klasifikasi penyakit ginjal melalui analisis citra CT *scan* organ ginjal telah banyak dilakukan dengan memvariasikan beberapa variabel. Adapun beberapa penelitian sebelumnya yang dijadikan landasan pada penelitian ini adalah sebagai berikut.

Pada penelitian sebelumnya digunakan algoritma *Convolutional Neural Network* (CNN) sebagai fitur ekstraksi dalam klasifikasi penyakit ginjal berbasis web [1]. Penelitian ini menggunakan dataset yang sama dengan dataset yang digunakan pada penelitian yang diusulkan yaitu citra CT *scan* ginjal sebanyak 12.446 gambar yang terbagi menjadi 9334 gambar untuk pelatihan dan 3112 gambar untuk validasi [1]. Dataset ini selanjutnya terbagi ke dalam empat kelas yaitu batu ginjal, tumor ginjal, kista ginjal, dan ginjal normal. Pada penelitian ini diperoleh akurasi pelatihan sebesar 75,17 % dan nilai akurasi f1 skornya sebesar 68% [1]. Pada penelitian ini pula ditemukan bias pada proses klasifikasi untuk kelas ginjal tumor dan ginjal batu sehingga menimbulkan kesalahan klasifikasi [1].

Pada penelitian yang menggunakan konsep *transfer learning* untuk ekstraksi fitur dan klasifikasi citra CT *scan* organ ginjal [43]. Model *transfer learning* yang digunakan dalam penelitian ini yaitu EANet, CCT, Swin Transformers, Resnet, VGG16, dan Inception V3 [43]. Dataset yang digunakan pada penelitian ini sama dengan dataset yang digunakan pada penelitian yang diusulkan yaitu citra CT *scan* ginjal sebanyak 12,446 citra CT *scan* ginjal dengan format *axial* dan *radial* [43]. Pada penelitian ini diperoleh hasil bahwa model Swin Transformers memiliki akurasi yang paling tinggi sebesar 99,3% dan memiliki kecepatan pelatihan yang lebih singkat dibandingkan model lain yang digunakan [43]. Kemudian, pada penelitian ini diketahui bahwa VGG16 memiliki kemampuan yang lebih baik dalam menunjukkan abnormalitas anatomi jika dibandingkan model lain seperti Resnet50 dan Inception V3 [43].

Pada penelitian yang menggunakan konsep *transfer learning* untuk ekstraksi fitur menggunakan DenseNet-201 sebagai ekstraksi fitur dan *Random Forest Classifier* sebagai algoritma klasifikasi [10]. Dataset yang digunakan pada penelitian ini sama dengan dataset yang digunakan pada penelitian yang di usulkan

berupa citra CT *scan* ginjal sebanyak 12.446 yang terbagi ke dalam empat kelas (batu ginjal, tumor ginjal, kista ginjal, dan ginjal normal) [10]. Pada penelitian diperoleh akurasi sebesar 99.44% dari model-model lain [10]. Perbandingan model pada penelitian ini dilakukan dengan beberapa model pada penelitian referensi [10].

Pada penelitian yang menggunakan algoritma *deep learning* untuk deteksi batu ginjal melalui citra CT *scan* organ ginjal dengan format *coronal* [8]. Model yang digunakan dalam penelitian ini yaitu model jaringan *cross-residual* (XResNet-50) [8]. Kemudian, pada penelitian ini diperoleh nilai akurasi sebesar 96,82% dengan 433 data subjek [8]. Sehingga berdasarkan hasil ini disimpulkan bahwa model *deep learning* yang diusulkan dapat digunakan untuk membantu radiologi mendeteksi batu ginjal [8].


Pada penelitian yang menggunakan algoritma *deep learning Heterogeneous Modified Artificial Neural Network* (HMANN) dalam deteksi dan diagnosis penyakit ginjal [9]. Penelitian ini menggunakan algoritma klasifikasi SVM, MLP, dan *Artificial Neural Network* (ANN) dengan data masukan berupa citra CT *scan* organ ginjal dengan format *axial* [9]. Hasil penelitian ini menunjukkan bahwa dalam citra CT *scan* terdapat *noise* dan kompleksitas yang mengganggu proses segmentasi objek [9]. Sehingga pada penelitian ini digunakan metode HMANN yang dapat mereduksi *noise* dan membantu identifikasi organ ginjal [9]. Selain itu, peningkatan akurasi deteksi gagal ginjal kronis juga diperoleh melalui pengurangan fitur [9].

Berdasarkan hasil penelitian sebelumnya, penelitian ini akan menganalisis tiga model klasifikasi untuk menentukan model terbaik berdasarkan matriks performa akurasi, hasil uji klasifikasi, dan waktu komputasi pada proses pelatihan. Adapun model yang digunakan pada penelitian ini meliputi MLP, SVM, dan *naive bayes*. Kemudian, model terbaik yang dipilih akan dikombinasikan dengan lima *feature descriptor* yaitu HOG, SIFT, LBP, GLCM, dan CNN. Kombinasi ini dilakukan untuk mengetahui keefektifan dari penggunaan *feature descriptor* pada model klasifikasi terbaik dalam proses klasifikasi penyakit ginjal melalui citra CT *scan*. Keefektifan ditinjau berdasarkan matriks performa, hasil uji klasifikasi, dan waktu komputasi saat pelatihan model.

METODOLOGI PENELITIAN

3.1. Alur Penelitian

Pada suatu penelitian diperlukan perencanaan dan tahapan yang perlu dilakukan dalam mencapai tujuan penelitian. Perencanaan penelitian dibuat berdasarkan tujuan penelitian dan disesuaikan dengan metode penelitian yang digunakan. Perencanaan dan tahapan penelitian ini dapat disajikan dalam bentuk diagram alir. Diagram alir penelitian ini dapat diamati pada Gambar 3.1.



Gambar 3.1 Diagram Alir Penelitian

Adapun penjelasan langkah-langkah penelitian pada Gambar 3.1 adalah sebagai berikut.


1. Studi Literatur

Pada proses studi literatur dilakukan pengumpulan data sekunder yang berasal dari berbagai jurnal dan *proceeding* terkait permasalahan yang diteliti yaitu adanya ketidakakuratan pada proses klasifikasi penyakit ginjal melalui analisis citra CT scan ginjal akibat adanya *noise* dan kompleksitas pada gambar. Pada proses ini juga diperoleh informasi terkait *feature descriptor*, batu ginjal, tumor ginjal, kista ginjal, *naive bayes*, SVM, dan MLP. Kemudian, data yang diperoleh pada proses ini selanjutnya digunakan sebagai referensi penelitian dan perbandingan hasil penelitian dengan penelitian sebelumnya yang serupa.

2. Data Acquisition (Akuisisi Data)

Pada proses *data acquisition* (akuisisi data) dilakukan pengambilan data berupa citra CT scan ginjal dengan format *axial*. Citra CT scan ginjal ini terbagi menjadi empat kelas yaitu batu ginjal, tumor ginjal, kista ginjal, dan ginjal normal. Adapun data yang digunakan pada penelitian ini bersumber dari data pihak ketiga yang disediakan oleh Kaggle. Dataset yang digunakan berjudul “CT Kidney Dataset: Normal-Cyst-Tumor and Stone” yang berisi dataset CT scan organ ginjal berformat *axial* dan *coronal*. Dataset ini berasal dari *Picture Archiving Communication System* (PACS) yang dikumpulkan dari beberapa rumah sakit berbeda di Dhaka, Bangladesh. Dataset ini berisi 12.446 gambar terbagi menjadi empat kelas dengan persebaran 1.377 gambar untuk batu ginjal, 2.283 gambar untuk tumor ginjal, 3.709 gambar untuk kista ginjal, dan 5.077 gambar untuk ginjal normal. Dataset yang digunakan pada penelitian ini dapat diakses melalui tautan <https://www.kaggle.com/datasets/nazmul0087/ct-kidney-dataset-normal-cyst-tumor-and-stone> dengan pembaruan terakhir pada 1 November 2021. Dataset ini juga digunakan oleh penelitian “Kidney Disease Classification using Hybrid Transfer-Learning DenseNet201-Based and Random Forest Classifier” oleh Abdalbasit Mohammed Qadir dan Dana Faiq Abd pada *Kurdistan Journal of Applied Research* (KJAR) tahun 2022. Kemudian, dataset ini digunakan pula pada penelitian “Vision Transformer and Explainable Transfer Learning Models for Auto Detection of Kidney Cyst, Stone, and Tumour from CT-radiography” oleh Md

Nazmul Islam dan kawan-kawan pada jurnal *Scientific Report* tahun 2022. Selanjutnya, *dataset* ini juga digunakan dalam penelitian “Implementasi Algoritma Convolutional Neural Network untuk Mendeteksi Penyakit Ginjal” oleh Fahri Aulia Alfari Harahap dan kawan-kawan pada Jurnal Teknologi Informasi, Komputer dan Aplikasinya (JTika) tahun 2021. Adapun sampel *dataset* yang digunakan dapat diamati pada Gambar 3.2.



Gambar 3.2 *Dataset* Citra CT Scan Organ Ginjal

Pada Gambar 3.2 dapat diamati sampel *dataset* citra CT Scan organ ginjal yang digunakan pada penelitian ini meliputi kelas batu ginjal, kelas kista ginjal, kelas ginjal normal, dan kelas tumor ginjal. Dasar penegakan diagnosis batu ginjal yaitu pada CT scan akan tampak objek dengan gambaran putih akibat adanya peningkatan radio opasitas saat objek dengan densitas tinggi tersebut menyerap lebih banyak sinar X. Objek ini dapat ditemui di bagian ginjal, kandung kemih, atau saluran empedu. Kemudian, dasar penegakan diagnosis kista ginjal yaitu pada CT

scan akan tampak objek dengan gambaran lebih kehitaman akibat adanya objek *hipodens* yang berupa kantung berisi cairan. Selanjutnya, dasar penegakan diagnosis tumor ginjal yaitu pada CT *scan* akan tampak pepadatan jaringan yang memiliki ukuran tidak normal dan bentuk yang tidak jelas.

3. *Data Preprocessing* (Pra-pemrosesan Data)

Pada tahapan ini dilakukan pemrosesan awal pada *dataset* yang digunakan dengan tujuan agar dihasilkan data yang bersih, sesuai format, dan terintegrasi. Pada tahap awal pemrosesan data yaitu dilakukan pembersihan data pada duplikasi data dan data yang tidak valid. Pada tahap ini dihilangkan gambar yang memiliki penampakan serupa dan gambar yang berformat *coronal* untuk menghindari bias model selama pelatihan. Kemudian, tahap kedua pemrosesan data yaitu dilakukan integrasi data. Pada tahapan ini data diintegrasikan dalam folder *training*. Folder *training* bersisi empat folder sesuai banyaknya kelas yaitu folder batu ginjal, folder tumor ginjal, folder kista ginjal, dan folder ginjal normal. Folder *training* berfungsi sebagai data pada proses pelatihan yang selanjutnya akan dilakukan pembagian untuk *training dataset* dan *test dataset* dengan perbandingan 7:3. Terakhir, pada tahap ketiga pemrosesan data yaitu pengurangan jumlah gambar pada folder *training*. Pengurangan gambar bertujuan untuk memperoleh kecepatan komputasi yang baik selama proses pelatihan.

4. Penyusunan Model

Pada tahapan penyusunan model dilakukan pembuatan model untuk tujuan penentuan model terbaik yang menggunakan citra *grayscale* (citra mentah) dan kombinasi model terbaik dengan lima *feature descriptor*. Pada peninjauan keakuratan model klasifikasi yang menggunakan citra *grayscale* digunakan tiga model di antaranya *naive bayes*, MLP, dan SVM. Kemudian, model terbaik yang dipilih dari ketiga model pada akan dikombinasikan dengan *feature descriptor*. Adapun *feature descriptor* yang digunakan pada penelitian ini diantaranya *descriptor* berbasis gradien lokal (HOG dan SIFT), *descriptor* berbasis intensitas gambar (LBP dan GLCM), dan *descriptor* berbasis pembelajaran (CNN). Pada penyusunan ini digunakan beberapa library utama seperti *sickit-learn*, *scikit-image*, *tensorflow*, *matplotlib*, *numpy*, *PIL*, *imutils*, dan *os*.

5. Pelatihan Model

Pada tahapan ini dilakukan pelatihan model dari enam kombinasi arsitektur yang telah dilakukan perancangan. Model dilatih dengan menggunakan *training dataset* dengan jumlah *dataset* sebanyak 2400 gambar. *Training dataset* ini kemudian dilakukan *split* untuk *training* dan validasi dengan perbandingan 7:3. Hasil dari tahapan ini adalah model yang telah terlatih untuk dilakukan pengujian sesuai tujuan penelitian.

6. Pengujian Model

Proses pengujian model dilakukan dengan menggunakan *test data/validation data* dari 30% data pelatihan. Hasil dari pengujian ini berupa *confusion matrix* dan *classification report*. Kemudian, pengujian dilanjutkan dengan menggunakan empat citra dari data eksternal sebagai data uji keandalan model pada empat kelas prediksi. Lalu, pengujian juga diukur berdasarkan waktu komputasi model pada saat pelatihan model.

7. Analisis Hasil Penelitian

Pada penelitian ini, analisis dilakukan sebanyak dua tahap yaitu menganalisis keakuratan dari model yang menggunakan citra *grayscale* (tanpa *descriptor*) dari CT scan. Adapun analisis dilakukan berdasarkan *confusion matrix*, *classification report*, hasil uji klasifikasi, dan waktu komputasi pada pelatihan model. Berdasarkan analisis ini, salah satu model dipilih sebagai model terbaik dan digunakan pada analisis selanjutnya. Analisis selanjutnya yaitu dengan mengombinasikan model terbaik dengan *feature descriptor* untuk mengetahui keefektifan penggunaannya pada peningkatan keakuratan model dalam klasifikasi penyakit ginjal melalui citra CT scan. Adapun analisis dilakukan berdasarkan *confusion matrix*, *classification report*, hasil uji klasifikasi, dan waktu komputasi pada pelatihan model. Pada analisis kedua ditentukan batas minimal akurasi sebesar lebih dari sama dengan 95%. Sehingga perlu setidaknya satu kombinasi yang dapat memenuhi kriteria agar penelitian dapat berlanjut pada pembuatan laporan.

8. Pembuatan Laporan

Pada tahapan pembuatan laporan dilakukan dokumentasi tertulis dari awal hingga akhir penelitian dalam format skripsi. Pembuatan laporan ini bertujuan

untuk dapat mendokumentasikan hasil dari skripsi dan dapat dipergunakan oleh akademisi lain sebagai dasar pembuatan model arsitektur yang lebih baik.

3.2. Komponen Penelitian

Dalam pelaksanaan penelitian ini digunakan beberapa komponen penelitian berupa perangkat keras (*hardware*) dan perangkat lunak (*software*). Adapun komponen penelitian ini adalah sebagai berikut.

3.2.1. Perangkat Keras

Perangkat keras yang digunakan dalam penelitian ini adalah sebagai berikut.

1. Laptop HP 14s

Laptop HP 14s merupakan laptop seri 14 inci yang dikeluarkan perusahaan HP dengan spesifikasi ram 4 GB, memori internal *harddisk* 1 TB, *processor* AMD Ryzen 3 3300U, dan kartu grafis AMD Radeon Vega 6. Laptop yang digunakan pada penelitian ini telah ditingkatkan menjadi ram 8 GB, serta memori internal *harddisk* 1 TB dan *solid-state drive* 256 GB. Pada penelitian ini, laptop digunakan sebagai penyimpan data dan proses komputasi model.

2. Casio fx-991EX

Casio fx-991EX merupakan salah satu produk kalkulator yang dikeluarkan oleh Casio dengan kemampuan perhitungan yang cukup tinggi. Pada penelitian ini, kalkulator Casio fx-991EX digunakan dalam analisis data dan pembuatan arsitektur model.

3. Canon ip2770

Canon ip2770 merupakan printer yang dikeluarkan oleh Canon dengan kemampuan untuk mencetak dokumen berwarna. Pada penelitian ini, printer digunakan dalam mencetak dokumen dan skripsi.

4. Redmi Note 10 2022

Redmi Note 10 2022 merupakan salah satu *smartphone* keluaran perusahaan teknologi Xiaomi. Pada penelitian ini, *smartphone* digunakan dalam proses komunikasi selama penelitian.

3.2.2. Perangkat Lunak

Perangkat lunak yang digunakan dalam penelitian ini adalah sebagai berikut.

1. Sistem Operasi Windows 11 Tipe 64 Bit

Windows 11 Tipe 64 Bit merupakan salah satu sistem operasi yang dikeluarkan perusahaan Microsoft. Pada penelitian ini, sistem operasi digunakan dalam mengoperasikan perangkat lunak yang ada pada laptop.

2. Google Chrome

Google Chrome merupakan salah satu perangkat lunak dengan fungsi peramban web yang dikeluarkan oleh Google. Pada penelitian ini, Google Chrome digunakan dalam proses pencarian informasi dan referensi yang digunakan selama penelitian.

3. Jupyter Notebook

Jupyter Notebook merupakan perangkat lunak berbasis *website* dengan kemampuan untuk membuat kode, perhitungan statistik, dan *machine learning*. Pada penelitian ini, Jupyter Notebook digunakan untuk melakukan *preprocessing data*, perancangan algoritma, pelatihan algoritma, dan pengujian keandalan sistem.

4. Microsoft Office 365

Microsoft Office 365 merupakan platform berlangganan yang meliputi berbagai perangkat lunak seperti Microsoft Words, Microsoft Excel, dan Microsoft Visio. Pada penelitian ini, Microsoft Office 365 digunakan dalam pembuatan laporan akhir skripsi, pembuatan *flowchart*, dan analisis data.

5. Git


Git merupakan *version control system* yang diciptakan oleh Linus Torvalds.

Pada penelitian ini, Git digunakan sebagai dokumentasi perubahan pada setiap kode program. Kemudian, fungsi dari Git Bash pada Git juga digunakan dalam proses penggunaan Jupyter Notebook.

3.3. Metode Penelitian

Berdasarkan rumusan masalah dan tujuan penelitian, penelitian ini menganalisis kinerja dari pengaplikasian *feature descriptor* dalam proses klasifikasi penyakit ginjal melalui citra CT scan organ ginjal dengan

membandingkan performa setiap kombinasi model. Proses analisis ini mengacu pada nilai performa yang ditunjukkan oleh *classification report* dan *confusion matrix* yang bersifat matematis dan terukur, serta divalidasi dengan tabel uji klasifikasi. Sehingga penelitian ini menggunakan metode penelitian kuantitatif dalam pencarian, penjabaran dan perumusan data/hasil penelitian. Adapun diagram blok penelitian dan analisis dapat diamati pada Gambar 3.3.



Gambar 3.3 Diagram Blok Metodologi Penelitian

Pada Gambar 3.3 dapat diamati diagram blok metodologi penelitian sebagai proses pengolahan citra dan penjabaran rinci pada tahap pelatihan model hingga diperoleh hasil dari pengujian model seperti pada Gambar 3.1. Adapun penjelasan metode penelitian pada Gambar 3.3 adalah sebagai berikut.

1. Citra CT scan

Pada penelitian ini digunakan citra CT scan sebagai dataset pelatihan dan pengujian model. Data citra CT scan yang digunakan memiliki format pencitraan

axial. Data ini diperoleh dari pemrosesan awal data melalui tahapan pembersihan data, integrasi data, dan pengurangan jumlah data. Pada penelitian ini digunakan data citra CT *scan* sebanyak 2400 gambar.

2. Pemrosesan Awal Gambar.

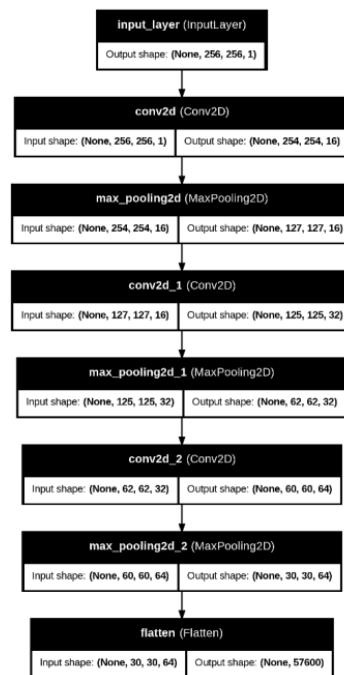
Setelah dilakukan perancangan, data hasil pemrosesan digunakan dalam penelitian melalui dua bagian utama yaitu pelatihan dan pengujian model. Proses pelatihan diawali dengan pemrosesan awal gambar melalui tiga tahapan yaitu *resize*, normalisasi, dan konversi. Tahapan *resize* berfungsi mengubah ukuran gambar menjadi seragam dengan ukuran sebesar 256×256 piksel. Proses ini berfungsi untuk menghindari konflik ukuran data masukan pada model. Selanjutnya, pada tahapan normalisasi, nilai-nilai piksel pada gambar dilakukan normalisasi atau pengubahan skala dengan membagi nilai piksel dengan 255. Skala nilai piksel sebelum proses ini sebesar 0-255 dan setelah melewati normalisasi sebesar 0-1. Proses ini berfungsi untuk membuat model lebih cepat konvergen. Kemudian, pada tahapan konversi gambar, konversi dilakukan dari gambar berwarna ke gambar keabuan (*grayscale*). Proses ini berfungsi untuk menyederhanakan komputasi dengan hanya berfokus pada skala keabuan pada gambar. Setelah dilakukan pemrosesan awal gambar, *dataset* akan dibagi ke *training dataset* dan *test dataset* dengan perbandingan 7:3.

3. Ekstraksi Fitur

Pada penelitian ini dilakukan ekstraksi fitur pada percobaan pengaplikasian *feature descriptor* dalam klasifikasi penyakit ginjal melalui citra CT *scan* organ ginjal. Proses ekstraksi fitur dilakukan dengan menggunakan *feature descriptor* yang menghasilkan keluaran fitur dan/atau citra. Fitur yang dihasilkan dari pengaplikasian *descriptor* berbentuk vektor fitur 1 dimensi (1D). Vektor fitur ini yang digunakan model dalam mengidentifikasi suatu citra atau vektor fitur ke dalam empat kelas. Proses ekstraksi fitur dilakukan pada analisis kedua yang menggunakan kombinasi antara model klasifikasi dan *feature descriptor*. Adapun *feature descriptor* yang digunakan memiliki parameter seperti pada Tabel 3.1 dan Gambar 3.4.

Tabel 3.1 Parameter Feature Descriptor

Feature Descriptor	Parameter
HOG	Piksel per sel = 8×8 ; Sel per blok = 2×2 ; Orientasi (bins) = 9; Blok Normalisasi = L2
SIFT	sift.detectAndCompute()
LBP	Radius = 3; Titik = 24; Metode = uniform; Bins = 26; Normalisasi = L1
GLCM	Jarak = 1 ; Sudut = $[0^\circ, 45^\circ, 90^\circ, 135^\circ]$



Gambar 3.4 Arsitektur CNN

4. Pelatihan Model

Pada penelitian ini dilakukan pelatihan model dengan citra *grayscale* atau fitur yang telah diekstraksi dari citra CT *scan*. Proses pelatihan dilakukan dengan

mengaplikasikan algoritma klasifikasi MLP, SVM, dan *naive bayes*. Adapun untuk arsitektur yang digunakan pada ketiga model tersebut adalah sebagai berikut.

Tabel 3.2 Parameter Model Klasifikasi

Model	Parameter
MLP	65536 Dense Input Layer; 256 Dense Hidden Layer 1; Activation Function "ReLU"; 64 Dense Hidden Layer 2; Activation Function "ReLU"; 4 Dense Output Layer; Activation Function "Softmax"
SVM	Kernel = Linear; C = 1
Naive Bayes	Tipe = "Gaussian"

5. Evaluasi Model

Pada penelitian ini dilakukan evaluasi terhadap kinerja model dari masing-masing kombinasi model pada proses klasifikasi gambar. Proses evaluasi dilakukan dengan memprediksi *test data* menggunakan model yang dilatih oleh *train data*. proses evaluasi divisualisasikan melalui *confusion matrix* dan *classification report*. Kedua media ini bertujuan untuk menunjukkan performa dari model yang dibuat.

Confusion matrix merupakan sebuah metrik yang digunakan dalam mengevaluasi model klasifikasi dengan menunjukkan prediksi yang benar dan salah terhadap suatu kelas. Pada matriks ini dikenal istilah *True Positif (TP)*, *True Negatif (TN)*, *False Positif (FP)*, dan *False Negatif (FN)*. Kondisi TP yaitu saat model memprediksi masukan sebagai kelas A dan masukan memang berada pada kelas A. Kondisi TN yaitu saat model memprediksi masukan yang bukan kelas A sebagai bukan kelas A. Kondisi FP yaitu saat model memprediksi masukan sebagai kelas A, namun masukan bukan berada pada kelas A. Kondisi FN yaitu saat model memprediksi masukan bukan sebagai kelas A, namun masukan berada pada kelas A. Adapun visualisasi dari *confusion matrix* (Tabel 3.1) adalah sebagai berikut.

Tabel 3.3 Confusion Matrix

	Positif (1)	Negatif (0)
Positif (1)	TP	FN
Negatif (0)	FP	TN

Berdasarkan *confussion matrix* dapat diketahui *classification report* dari sebuah model yang dilakukan evaluasi. *Classification report* merupakan metrik yang dapat menunjukkan kinerja dari model klasifikasi yang digunakan. *Classification report* dapat menginformasikan nilai akurasi, presisi, *f1 score*, *recall*, dan *support* untuk setiap kelas yang diklasifikasikan. Adapun persamaan perhitungan nilai akurasi, presisi, *f1 score*, *recall*, dan *support* adalah sebagai berikut.

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.1)$$

$$\text{Presisi} = \frac{TP}{TP+FP} \quad (3.2)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (3.3)$$

$$\text{F1 Score} = \frac{2 \times \text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \quad (3.4)$$

Dengan TP yaitu *true positive*; TN yaitu *true negative*; FP yaitu *false positive*, dan FN yaitu *false negative*. Pada persamaan 3.1 diketahui persamaan nilai akurasi sebagai nilai yang menyatakan rasio kebenaran dari prediksi yang dilakukan terhadap keseluruhan data. Kemudian, pada persamaan 3.2 diketahui persamaan nilai presisi sebagai nilai yang menyatakan presentasi kebenaran dari prediksi terhadap keseluruhan prediksi positif. Selanjutnya pada persamaan 3.3 diketahui persamaan nilai *recall* sebagai nilai yang menyatakan presentasi kebenaran dari prediksi terhadap keseluruhan data yang benar. Lalu, pada persamaan 3.4 diketahui persamaan nilai *f1 score* sebagai nilai komparasi antara nilai presisi dan *recall*. Terakhir, pada Persamaan 3.5 dapat diketahui nilai *support* sebagai nilai yang menunjukkan banyaknya sampel yang digunakan dari setiap kelas.

Selain dari matriks performa model, pengujian dilakukan pula berdasarkan hasil uji klasifikasi dan pengukuran waktu komputasi model pada saat pelatihan. Hasil uji klasifikasi diperoleh dari pengujian klasifikasi dari model yang telah dilatih menggunakan data eksternal. Proses ini dilakukan sebanyak empat kali dengan empat citra pada kelas yang berbeda. Lalu, proses pengukuran waktu pelatihan model dilakukan dengan mengamati *wall-time* pada eksekusi program dari penggunaan *command* “*%time*”.

BAB IV


ANALISIS DAN HASIL

4.1. Hasil Pelatihan dan Pengujian Model

Pada penelitian ini dilakukan pengambilan data berupa hasil pelatihan dan pengujian pada 8 model dengan jumlah *dataset* 2400 gambar. Adapun hasil dari pelatihan dan pengujian keenam model tersebut adalah sebagai berikut.

4.1.1. Model MLP dengan Citra *Grayscale*

Model MLP dilakukan pelatihan dengan menggunakan data pelatihan berupa representasi piksel dari citra CT *scan*. Waktu komputasi yang dibutuhkan untuk melatih model selama 552 detik. Setelah dilakukan pelatihan, model dilakukan pengujian dengan data tes yang menghasilkan matriks performa berupa *confusion matrix* dan *classification report*. Adapun *confusion matrix* model ini dapat diamati pada Gambar 4.1.



Gambar 4.1 *Confusion Matrix* Model MLP dengan Citra *Grayscale*

Pada Gambar 4.1 dapat diamati jika hasil evaluasi kinerja model MLP dengan citra *grayscale* menunjukkan hasil yang sangat baik. Sebanyak 181 gambar pada kelas aktual batu ginjal, seluruhnya berhasil diprediksi sebagai batu ginjal. Kemudian, sebanyak 166 gambar pada kelas aktual kista ginjal, seluruhnya berhasil diprediksi sebagai kista ginjal. Lalu, sebanyak 177 gambar pada kelas aktual ginjal normal, seluruhnya berhasil diprediksi sebagai ginjal normal. Selanjutnya, sebanyak 196 gambar pada kelas aktual tumor ginjal, seluruhnya berhasil diprediksi sebagai tumor ginjal. Berdasarkan informasi pada *confusion matrix* ini, matriks performa akurasi, presisi, *recall*, *f1-score*, dan *support* dapat ditentukan melalui *classification report*. Adapun *classification report* model ini dapat diamati pada Gambar 4.2.

720/720 [=====] - 4s 5ms/step				
	precision	recall	f1-score	support
1	1.00	1.00	1.00	181
2	1.00	1.00	1.00	166
3	1.00	1.00	1.00	177
4	1.00	1.00	1.00	196
accuracy			1.00	720
macro avg	1.00	1.00	1.00	720
weighted avg	1.00	1.00	1.00	720

Gambar 4.2 *Classification Report* Model MLP dengan Citra *Grayscale*

Pada Gambar 4.2 dapat diamati matriks performa berupa *classification report* model MLP dengan citra *grayscale*. Pada gambar diketahui bahwa model MLP dengan citra *grayscale* memiliki akurasi keseluruhan sebesar 1 pada pengujian data tes sebanyak 720 gambar. Kemudian, berdasarkan nilai *f1-score*, model ini memiliki *weighted average f1-score* sebesar 1 dan juga bernilai 1 untuk setiap kelas prediksi. Lalu, berdasarkan nilai presisi, model ini memiliki *weighted average* presisi sebesar 1 dan juga bernilai 1 untuk setiap kelas prediksi. Selanjutnya, berdasarkan nilai presisi, model ini memiliki *weighted average* presisi sebesar 1 dan juga bernilai 1 untuk setiap kelas prediksi. Kemudian, setelah dilakukan pengujian menggunakan data tes, model juga diuji dengan menggunakan data tes eksternal melalui hasil uji klasifikasi. Adapun hasil uji klasifikasi kurang

sempurna dengan mengalami satu kesalahan prediksi pada kelas aktual tumor ginjal yang diprediksi sebagai kista ginjal.

4.1.2. Model SVM dengan Citra *Grayscale*

Model SVM dilakukan pelatihan dengan menggunakan data pelatihan berupa representasi piksel dari citra CT *scan*. Waktu komputasi yang dibutuhkan untuk melatih model selama 58,5 detik. Setelah dilakukan pelatihan, model dilakukan pengujian dengan data tes yang menghasilkan matriks performa berupa *confusion matrix* dan *classification report*.

Pada lampiran Gambar B.3 dapat diamati jika hasil evaluasi kinerja model SVM dengan citra *grayscale* menunjukkan hasil yang sangat baik. Sebanyak 174 gambar pada kelas aktual batu ginjal, seluruhnya berhasil diprediksi sebagai batu ginjal. Kemudian, sebanyak 182 gambar pada kelas aktual kista ginjal, seluruhnya berhasil diprediksi sebagai kista ginjal. Lalu, sebanyak 180 gambar pada kelas aktual ginjal normal, seluruhnya berhasil diprediksi sebagai ginjal normal. Selanjutnya, sebanyak 184 gambar pada kelas aktual tumor ginjal, seluruhnya berhasil diprediksi sebagai tumor ginjal. Berdasarkan informasi pada *confusion matrix* ini, matriks performa akurasi, presisi, *recall*, *f1-score*, dan *support* dapat ditentukan melalui *classification report*.

Pada lampiran Gambar B.4 dapat diamati matriks performa berupa *classification report* model SVM dengan citra *grayscale*. Pada gambar diketahui bahwa model SVM dengan citra *grayscale* memiliki akurasi keseluruhan sebesar 1 pada pengujian data tes sebanyak 720 gambar. Kemudian, berdasarkan nilai *f1-score*, model ini memiliki *weighted average f1-score* sebesar 1 dan juga bernilai 1 untuk setiap kelas prediksi. Lalu, berdasarkan nilai presisi, model ini memiliki *weighted average* presisi sebesar 1 dan juga bernilai 1 untuk setiap kelas prediksi. Selanjutnya, berdasarkan nilai presisi, model ini memiliki *weighted average* presisi sebesar 1 dan juga bernilai 1 untuk setiap kelas prediksi. Kemudian, setelah dilakukan pengujian menggunakan data tes, model juga diuji dengan menggunakan data tes eksternal melalui hasil uji klasifikasi. Adapun hasil uji klasifikasi kurang sempurna dengan mengalami satu kesalahan prediksi pada kelas aktual tumor ginjal yang diprediksi sebagai ginjal normal.

4.1.3. Model *Naive Bayes* dengan Citra *Grayscale*

Model *naive bayes* dilakukan pelatihan dengan menggunakan data pelatihan berupa representasi piksel dari citra CT *scan*. Waktu komputasi yang dibutuhkan untuk melatih model selama 4.54 detik. Setelah dilakukan pelatihan, model dilakukan pengujian dengan data tes yang menghasilkan matriks performa berupa *confusion matrix* dan *classification report*.

Pada lampiran Gambar B.5 dapat diamati jika hasil evaluasi kinerja model *naive bayes* dengan citra *grayscale* menunjukkan hasil yang sangat baik. Sebanyak 177 gambar pada kelas aktual batu ginjal, 176 gambar berhasil diprediksi sebagai kelas batu ginjal dan 1 gambar diprediksi sebagai kista ginjal. Kemudian, sebanyak 189 gambar pada kelas aktual kista ginjal, 186 gambar berhasil diprediksi sebagai kelas kista ginjal dan 3 gambar diprediksi sebagai ginjal normal. Lalu, sebanyak 184 gambar pada kelas aktual ginjal normal, seluruhnya berhasil diprediksi sebagai ginjal normal. Selanjutnya, sebanyak 170 gambar pada kelas aktual tumor ginjal, 167 gambar berhasil diprediksi sebagai tumor ginjal dan 2 gambar diprediksi sebagai kista ginjal. Berdasarkan informasi pada *confusion matrix* ini, matriks performa akurasi, presisi, *recall*, *f1-score*, dan *support* dapat ditentukan melalui *classification report*.

Pada lampiran Gambar B.6 dapat diamati matriks performa berupa *classification report* model *naive bayes* dengan citra *grayscale*. Pada gambar diketahui bahwa model SVM dengan citra *grayscale* memiliki akurasi keseluruhan sebesar 0.99 pada pengujian data tes sebanyak 720 gambar. Kemudian, berdasarkan nilai *f1-score*, model ini memiliki *weighted average f1-score* sebesar 0,99, serta bernilai 1 untuk kelas batu ginjal, 0.98 untuk kelas kista ginjal, 0.99 untuk kelas ginjal normal, dan 0.99 untuk kelas tumor ginjal. Lalu, berdasarkan nilai presisi, model ini memiliki *weighted average presisi* sebesar 0,99, serta bernilai 1 untuk kelas batu ginjal, 0.98 untuk kelas kista ginjal, 0.98 untuk kelas ginjal normal, dan 1 untuk kelas tumor ginjal. Selanjutnya, berdasarkan nilai *recall*, model ini memiliki *weighted average presisi* sebesar 0,99, serta bernilai 0,99 untuk kelas batu ginjal, 0.98 untuk kelas kista ginjal, 1 untuk kelas ginjal normal, dan 0.99 untuk kelas tumor ginjal. Kemudian, setelah dilakukan pengujian menggunakan data tes,

model juga diuji dengan menggunakan data tes eksternal melalui hasil uji klasifikasi. Adapun hasil uji klasifikasi kurang sempurna dengan mengalami satu kesalahan prediksi pada kelas aktual tumor ginjal yang diprediksi sebagai kista ginjal.

4.1.4. Model SVM dengan Fitur HOG

Model SVM dilakukan pelatihan dengan menggunakan data pelatihan berupa vektor fitur *descriptor* HOG dari citra CT scan. Waktu komputasi yang dibutuhkan untuk melatih model selama 50,3 detik. Setelah dilakukan pelatihan, model dilakukan pengujian dengan data tes yang menghasilkan matriks performa berupa *confusion matrix* dan *classification report*.

Pada lampiran Gambar B.7 dapat diamati jika hasil evaluasi kinerja model SVM dengan fitur HOG menunjukkan hasil yang sangat baik. Sebanyak 182 gambar pada kelas aktual batu ginjal, seluruhnya berhasil diprediksi sebagai batu ginjal. Kemudian, sebanyak 174 gambar pada kelas aktual kista ginjal, seluruhnya berhasil diprediksi sebagai kista ginjal. Lalu, sebanyak 174 gambar pada kelas aktual ginjal normal, seluruhnya berhasil diprediksi sebagai ginjal normal. Selanjutnya, sebanyak 190 gambar pada kelas aktual tumor ginjal, seluruhnya berhasil diprediksi sebagai tumor ginjal. Berdasarkan informasi pada *confusion matrix* ini, matriks performa akurasi, presisi, *recall*, *f1-score*, dan *support* dapat ditentukan melalui *classification report*.

Pada lampiran Gambar B.8 dapat diamati matriks performa berupa *classification report* model SVM dengan fitur HOG. Pada gambar diketahui bahwa model SVM dengan fitur HOG memiliki akurasi keseluruhan sebesar 1 pada pengujian data tes sebanyak 720 gambar. Kemudian, berdasarkan nilai *f1-score*, model ini memiliki *weighted average f1-score* sebesar 1 dan juga bernilai 1 untuk setiap kelas prediksi. Lalu, berdasarkan nilai presisi, model ini memiliki *weighted average* presisi sebesar 1 dan juga bernilai 1 untuk setiap kelas prediksi. Selanjutnya, berdasarkan nilai presisi, model ini memiliki *weighted average* presisi sebesar 1 dan juga bernilai 1 untuk setiap kelas prediksi. Kemudian, setelah dilakukan pengujian menggunakan data tes, model juga diuji dengan menggunakan data tes eksternal melalui hasil uji klasifikasi. Adapun hasil uji klasifikasi model ini

sempurna dengan berhasil memprediksi setiap gambar uji klasifikasi ke dalam empat kelas prediksi.

4.1.5. Model SVM dengan Fitur SIFT

Model SVM dilakukan pelatihan dengan menggunakan data pelatihan berupa vektor fitur *descriptor* SIFT dari citra CT scan. Waktu komputasi yang dibutuhkan untuk melatih model selama 0,716 detik. Setelah dilakukan pelatihan, model dilakukan pengujian dengan data tes yang menghasilkan matriks performa berupa *confusion matrix* dan *classification report*.

Pada lampiran Gambar B.9 dapat diamati jika hasil evaluasi kinerja model SVM dengan fitur SIFT menunjukkan hasil yang cukup baik. Sebanyak 190 gambar pada kelas aktual batu ginjal memiliki hasil prediksi 151 gambar berhasil diprediksi sebagai kelas batu ginjal, 15 gambar diprediksi sebagai kista ginjal, 11 gambar diprediksi sebagai ginjal normal, dan 13 gambar diprediksi sebagai tumor ginjal. Kemudian, sebanyak 179 gambar pada kelas aktual kista ginjal memiliki hasil prediksi 140 gambar berhasil diprediksi sebagai kelas kista ginjal, 27 gambar diprediksi sebagai batu ginjal, 5 gambar diprediksi sebagai ginjal normal, dan 7 gambar diprediksi sebagai tumor ginjal. Lalu, sebanyak 178 gambar pada kelas aktual ginjal normal memiliki hasil prediksi 137 gambar berhasil diprediksi sebagai kelas ginjal normal, 20 gambar diprediksi sebagai batu ginjal, dan 21 gambar diprediksi sebagai tumor ginjal. Selanjutnya, sebanyak 173 gambar pada kelas aktual tumor ginjal memiliki hasil prediksi 128 gambar berhasil diprediksi sebagai kelas kista ginjal, 19 gambar diprediksi sebagai batu ginjal, 11 gambar diprediksi sebagai kista ginjal, dan 15 gambar diprediksi sebagai ginjal normal. Berdasarkan informasi pada *confusion matrix* ini, matriks performa akurasi, presisi, *recall*, *f1-score*, dan *support* dapat ditentukan melalui *classification report*.

Pada lampiran Gambar B.10 dapat diamati matriks performa berupa *classification report* model SVM dengan fitur SIFT. Pada gambar diketahui bahwa model SVM dengan fitur SIFT memiliki akurasi keseluruhan sebesar 0.77 pada pengujian data tes sebanyak 720 gambar. Kemudian, berdasarkan nilai *f1-score*, model ini memiliki *weighted average f1-score* sebesar 0,77, serta bernilai 0,74 untuk kelas batu ginjal, 0.81 untuk kelas kista ginjal, 0.79 untuk kelas ginjal normal,

dan 0.75 untuk kelas tumor ginjal. Lalu, berdasarkan nilai presisi, model ini memiliki *weighted average* presisi sebesar 0,78, serta bernilai 0,70 untuk kelas batu ginjal, 0.84 untuk kelas kista ginjal, 0.82 untuk kelas ginjal normal, dan 0,76 untuk kelas tumor ginjal. Selanjutnya, berdasarkan nilai *recall*, model ini memiliki *weighted average* presisi sebesar 0,77, serta bernilai 0,79 untuk kelas batu ginjal, 0.78 untuk kelas kista ginjal, 0,77 untuk kelas ginjal normal, dan 0.74 untuk kelas tumor ginjal. Kemudian, setelah dilakukan pengujian menggunakan data tes, model juga diuji dengan menggunakan data tes eksternal melalui hasil uji klasifikasi. Adapun hasil uji klasifikasi kurang sempurna dengan mengalami satu kesalahan prediksi pada kelas aktual ginjal normal yang diprediksi sebagai batu ginjal.

4.1.6. Model SVM dengan Fitur LBP

Model SVM dilakukan pelatihan dengan menggunakan data pelatihan berupa vektor fitur *descriptor* LBP dari citra CT *scan*. Waktu komputasi yang dibutuhkan untuk melatih model selama 0,259 detik. Setelah dilakukan pelatihan, model dilakukan pengujian dengan data tes yang menghasilkan matriks performa berupa *confusion matrix* dan *classification report*.

Pada lampiran Gambar B.11 dapat diamati jika hasil evaluasi kinerja model SVM dengan fitur LBP menunjukkan hasil yang tidak baik. Sebanyak 176 gambar pada kelas aktual batu ginjal memiliki hasil prediksi 84 gambar berhasil diprediksi sebagai kelas batu ginjal, 29 gambar diprediksi sebagai kista ginjal, 28 gambar diprediksi sebagai ginjal normal, dan 35 gambar diprediksi sebagai tumor ginjal. Kemudian, sebanyak 200 gambar pada kelas aktual kista ginjal memiliki hasil prediksi 154 gambar berhasil diprediksi sebagai kelas kista ginjal, 4 gambar diprediksi sebagai batu ginjal, 10 gambar diprediksi sebagai ginjal normal, dan 32 gambar diprediksi sebagai tumor ginjal. Lalu, sebanyak 162 gambar pada kelas aktual ginjal normal memiliki hasil prediksi 38 gambar berhasil diprediksi sebagai kelas ginjal normal, 43 gambar diprediksi sebagai batu ginjal, 71 gambar diprediksi sebagai kista ginjal, dan 10 gambar diprediksi sebagai tumor ginjal. Selanjutnya, sebanyak 182 gambar pada kelas aktual tumor ginjal memiliki hasil prediksi 34 gambar berhasil diprediksi sebagai kelas tumor ginjal, 19 gambar diprediksi sebagai batu ginjal, 126 gambar diprediksi sebagai kista ginjal, dan 3 gambar diprediksi

sebagai ginjal normal. Berdasarkan informasi pada *confusion matrix* ini, matriks performa akurasi, presisi, *recall*, *f1-score*, dan *support* dapat ditentukan melalui *classification report*.

Pada lampiran Gambar B.12 dapat diamati matriks performa berupa *classification report* model SVM dengan fitur LBP. Pada gambar diketahui bahwa model SVM dengan fitur LBP memiliki akurasi keseluruhan sebesar 0.43 pada pengujian data tes sebanyak 720 gambar. Kemudian, berdasarkan nilai *f1-score*, model ini memiliki *weighted average f1-score* sebesar 0.40, serta bernilai 0.52 untuk kelas batu ginjal, 0.53 untuk kelas kista ginjal, 0.32 untuk kelas ginjal normal, dan 0.23 untuk kelas tumor ginjal. Lalu, berdasarkan nilai presisi, model ini memiliki *weighted average* presisi sebesar 0.44, serta bernilai 0.56 untuk kelas batu ginjal, 0.41 untuk kelas kista ginjal, 0.48 untuk kelas ginjal normal, dan 0.31 untuk kelas tumor ginjal. Selanjutnya, berdasarkan nilai *recall*, model ini memiliki *weighted average* presisi sebesar 0.43, serta bernilai 0.48 untuk kelas batu ginjal, 0.77 untuk kelas kista ginjal, 0.23 untuk kelas ginjal normal, dan 0.19 untuk kelas tumor ginjal. Kemudian, setelah dilakukan pengujian menggunakan data tes, model juga diuji dengan menggunakan data tes eksternal melalui hasil uji klasifikasi. Adapun hasil uji klasifikasi kurang baik dengan mengalami tiga kesalahan prediksi. Kesalahan prediksi model ini yaitu saat kelas aktual batu ginjal diprediksi sebagai tumor, kelas aktual ginjal normal diprediksi sebagai batu ginjal, kelas aktual tumor ginjal diprediksi sebagai batu ginjal.

4.1.7. Model SVM dengan Fitur GLCM

Model SVM dilakukan pelatihan dengan menggunakan data pelatihan berupa vektor fitur *descirptor* GLCM dari citra *CT scan*. Waktu komputasi yang dibutuhkan untuk melatih model selama 0,199 detik. Setelah dilakukan pelatihan, model dilakukan pengujian dengan data tes yang menghasilkan matriks performa berupa *confusion matrix* dan *classification report*.

Pada lampiran Gambar B.13 dapat diamati jika hasil evaluasi kinerja model SVM dengan fitur LBP menunjukkan hasil yang tidak baik. Sebanyak 190 gambar pada kelas aktual batu ginjal memiliki hasil prediksi 150 gambar berhasil diprediksi sebagai kelas batu ginjal, 19 gambar diprediksi sebagai kista ginjal, 13 gambar

diprediksi sebagai ginjal normal, dan 8 gambar diprediksi sebagai tumor ginjal. Kemudian, sebanyak 181 gambar pada kelas aktual kista ginjal memiliki hasil prediksi 136 gambar berhasil diprediksi sebagai kelas kista ginjal, 23 gambar diprediksi sebagai batu ginjal dan 22 gambar diprediksi sebagai tumor ginjal. Lalu, sebanyak 187 gambar pada kelas aktual ginjal normal memiliki hasil prediksi 113 gambar berhasil diprediksi sebagai kelas ginjal normal, 25 gambar diprediksi sebagai batu ginjal, 9 gambar diprediksi sebagai kista ginjal, dan 40 gambar diprediksi sebagai tumor ginjal. Selanjutnya, sebanyak 162 gambar pada kelas aktual tumor ginjal memiliki hasil prediksi 137 gambar berhasil diprediksi sebagai kelas tumor ginjal, 2 gambar diprediksi sebagai batu ginjal, 12 gambar diprediksi sebagai kista ginjal, dan 11 gambar diprediksi sebagai ginjal normal. Berdasarkan informasi pada *confusion matrix* ini, matriks performa akurasi, presisi, *recall*, *f1-score*, dan *support* dapat ditentukan melalui *classification report*.

Pada lampiran Gambar B.14 dapat diamati matriks performa berupa *classification report* model SVM dengan fitur GLCM. Pada gambar diketahui bahwa model SVM dengan fitur GLCM memiliki akurasi keseluruhan sebesar 0.74 pada pengujian data tes sebanyak 720 gambar. Kemudian, berdasarkan nilai *f1-score*, model ini memiliki *weighted average f1-score* sebesar 0,74, serta bernilai 0,77 untuk kelas batu ginjal, 0.76 untuk kelas kista ginjal, 0.70 untuk kelas ginjal normal, dan 0.74 untuk kelas tumor ginjal. Lalu, berdasarkan nilai presisi, model ini memiliki *weighted average* presisi sebesar 0,76, serta bernilai 0,75 untuk kelas batu ginjal, 0.77 untuk kelas kista ginjal, 0.82 untuk kelas ginjal normal, dan 0,66 untuk kelas tumor ginjal. Selanjutnya, berdasarkan nilai *recall*, model ini memiliki *weighted average* presisi sebesar 0,74, serta bernilai 0,79 untuk kelas batu ginjal, 0.75 untuk kelas kista ginjal, 0,60 untuk kelas ginjal normal, dan 0.85 untuk kelas tumor ginjal. Kemudian, setelah dilakukan pengujian menggunakan data tes, model juga diuji dengan menggunakan data tes eksternal melalui hasil uji klasifikasi. Adapun hasil uji klasifikasi kurang baik dengan mengalami tiga kesalahan prediksi. Hanya kelas aktual batu ginjal saja yang berhasil diprediksi dengan benar dan sisa kelas prediksi mengalami kesalahan prediksi menjadi batu ginjal.

4.1.8. Model SVM dengan Fitur CNN

Model SVM dilakukan pelatihan dengan menggunakan data pelatihan berupa vektor fitur CNN dari citra CT *scan*. Waktu komputasi yang dibutuhkan untuk melatih model selama 28,2 detik. Setelah dilakukan pelatihan, model dilakukan pengujian dengan data tes yang menghasilkan matriks performa berupa *confusion matrix* dan *classification report*.

Pada lampiran Gambar B.15 dapat diamati jika hasil evaluasi kinerja model SVM dengan fitur CNN menunjukkan hasil yang sangat baik. Sebanyak 167 gambar pada kelas aktual batu ginjal, seluruhnya berhasil diprediksi sebagai batu ginjal. Kemudian, sebanyak 180 gambar pada kelas aktual kista ginjal, seluruhnya berhasil diprediksi sebagai kista ginjal. Lalu, sebanyak 198 gambar pada kelas aktual ginjal normal, seluruhnya berhasil diprediksi sebagai ginjal normal. Selanjutnya, sebanyak 175 gambar pada kelas aktual tumor ginjal, seluruhnya berhasil diprediksi sebagai tumor ginjal. Berdasarkan informasi pada *confusion matrix* ini, matriks performa akurasi, presisi, *recall*, *f1-score*, dan *support* dapat ditentukan melalui *classification report*.


Pada lampiran Gambar B.16 dapat diamati matriks performa berupa *classification report* model SVM dengan fitur CNN. Pada gambar diketahui bahwa model SVM dengan fitur CNN memiliki akurasi keseluruhan sebesar 1 pada pengujian data tes sebanyak 720 gambar. Kemudian, berdasarkan nilai *f1-score*, model ini memiliki *weighted average f1-score* sebesar 1 dan juga bernilai 1 untuk setiap kelas prediksi. Lalu, berdasarkan nilai presisi, model ini memiliki *weighted average* presisi sebesar 1 dan juga bernilai 1 untuk setiap kelas prediksi. Selanjutnya, berdasarkan nilai presisi, model ini memiliki *weighted average* presisi sebesar 1 dan juga bernilai 1 untuk setiap kelas prediksi. Kemudian, setelah dilakukan pengujian menggunakan data tes, model juga diuji dengan menggunakan data tes eksternal melalui hasil uji klasifikasi. Adapun hasil uji klasifikasi model ini kurang sempurna dengan mengalami satu kesalahan pada kelas aktual tumor ginjal yang diprediksi sebagai ginjal normal.

4.2. Analisis Hasil Pelatihan dan Pengujian Model

Pada penelitian ini, analisis dilakukan sebanyak dua tahapan yaitu untuk menganalisis performa model saat tanpa *descriptor* dan menganalisis performa model dengan *descriptor*. Adapun analisis pada penelitian ini adalah sebagai berikut.

4.2.1. Analisis Model dengan Citra Grayscale

Hasil pelatihan dan pengujian model dengan citra *grayscale* dilakukan perbandingan untuk menentukan model terbaik yang digunakan pada analisis tahap dua. Perbandingan dilakukan dengan berdasar pada hasil evaluasi model berupa *classification report* sebagai representasi numerik dari *confusion matrix*, hasil uji klasifikasi, dan waktu komputasi saat pelatihan. Adapun perbandingan performa model berdasarkan matriks performa *classification report* dapat diamati pada Gambar 4.3.



Gambar 4.3 Grafik Matriks Performa Model dengan Citra *Grayscale*

Pada gambar 4.3 dapat diamati grafik matriks performa model dengan citra *grayscale*. berdasarkan grafik tersebut dapat diamati nilai *f1-score*, *recall*, *precision*, dan *accuracy*. Analisis matriks performa berdasar pada nilai *f1-score* sebagai nilai harmonisasi untuk *recall* dan *precision*. Dalam bidang medis, nilai *recall* yang merepresentasikan nilai *false negative* menjadi nilai penting dalam

mengevaluasi kesalahan diagnosis pasien sakit sebagai normal atau penyakit yang lain. Kemudian, nilai presisi merepresentasikan *nilai false positive* yang merepresentasikan kebenaran diagnosis dari keseluruhan diagnosis yang dilakukan. Berdasarkan Gambar 4.3 dapat diamati jika model MLP dan SVM menjadi model dengan nilai *f1-score*, *recall*, dan *precision* terbaik berdasarkan *weighted average* yaitu bernilai 1. Sedangkan, untuk model naive bayes memiliki nilai lebih rendah dengan nilai *weighted average f1-score*, *recall*, dan *precision* bernilai 0,99. Berdasarkan analisis ini, model *naive bayes* dieliminasi dan analisis dilanjutkan untuk model MLP dan SVM berdasarkan hasil uji klasifikasi. Adapun hasil uji klasifikasi model MLP dan SVM dapat diamati pada Tabel 4.1.

Tabel 4.1 Hasil Uji Klasifikasi Model dengan Citra Grayscale

Kelas Aktual	Kelas Prediksi	
	GS+MLP	GS+SVM
Batu	Batu	Batu
Kista	Kista	Kista
Normal	Normal	Normal
Tumor	Kista	Normal

Pada Tabel 4.1 dapat diamati tabel hasil uji klasifikasi model dengan citra *grayscale*. Model dilakukan perbandingan dengan menggunakan data eksternal yang tidak digunakan dalam proses pelatihan dan pengujian. Pada pengujian yang dilakukan, model MLP dan model SVM mengalami kesalahan prediksi pada satu kelas aktual yaitu tumor. Model MLP mengalami kesalahan prediksi kelas aktual tumor sebagai kelas kista ginjal. Sedangkan, model SVM mengalami kesalahan prediksi kelas aktual tumor sebagai ginjal normal. Berdasarkan hasil ini, model yang dilatih dengan menggunakan representasi piksel dari citra *grayscale* mengalami kesulitan dalam mengidentifikasi kelas tumor secara sempurna yang menandakan adanya permasalahan keakuratan akibat kompleksitas representasi citra CT scan. Selain itu, berdasarkan hasil ini analisis dilanjutkan berdasarkan waktu komputasi saat pelatihan model. Adapun waktu komputasi saat pelatihan model dapat diamati pada Tabel 4.2.


Tabel 4.2 Waktu Pelatihan Model dengan Citra *Grayscale*

Model Klasifikasi	Waktu Pelatihan Model
MLP	552 detik
SVM	58,5 detik

Pada Tabel 4.2 dapat diamati waktu pelatihan model MLP dan SVM dengan citra *grayscale*. Berdasarkan tabel tersebut diketahui model MLP memiliki waktu pelatihan model yang lebih lama yaitu 552 detik jika dibandingkan dengan model SVM yang memiliki waktu yaitu 58,5 detik. Perbedaan waktu pelatihan yang terjadi disebabkan oleh perbedaan proses klasifikasi pada setiap model. Model MLP memiliki waktu pelatihan model lebih lama disebabkan oleh proses klasifikasi yang berdasarkan pada penyesuaian bobot dari lapisan secara iteratif, pada penelitian ini digunakan 100 *epochs* untuk proses pelatihan yang membuatnya lebih lama. Sedangkan, model SVM memiliki proses klasifikasi dengan menentukan *hyperplane* berdasarkan *support vector* saja. Berdasarkan analisis ini pula dipilih model SVM sebagai model terbaik untuk analisis tahap dua dengan kombinasi *feature descriptor*.

4.2.2. Analisis Model dengan *Feature Descriptor*

Hasil pelatihan dan pengujian model dengan fitur *descriptor* dilakukan perbandingan untuk menganalisis keakuratan dan mengetahui keefektifan penggunaan *feature descriptor* dibandingkan dengan model tanpa *descriptor*. Perbandingan dilakukan dengan berdasar pada hasil evaluasi model berupa *classification report* sebagai representasi numerik dari *confusion matrix*, hasil uji klasifikasi, dan waktu komputasi saat pelatihan. Adapun perbandingan performa model berdasarkan matriks performa *classification report* dapat diamati pada Gambar 4.4.



Gambar 4.4 Grafik Matriks Performa Model dengan *Feature Descriptor*

Pada gambar 4.3 dapat diamati grafik matriks *perfoma* model dengan citra *grayscale*. berdasarkan grafik tersebut dapat diamati nilai *f1-score*, *recall*, *precision*, dan *accuracy*. Analisis matriks performa berdasar pada nilai *f1-score* sebagai nilai harmonisasi untuk *recall* dan *precision*. Berdasarkan grafik tersebut diketahui bahwa model yang menggunakan fitur HOG dan model yang menggunakan fitur CNN menjadi model dengan *f1-score*, *recall*, dan presisi tertinggi yaitu bernilai 1. Kemudian, model yang menggunakan fitur SIFT memiliki performa sedikit lebih rendah dengan nilai *f1-score*, *recall*, dan presisi berdasarkan *weighted average* berturut-turut 0,77, 0,77, dan 0,78. Lalu, model yang menggunakan fitur GLCM memiliki *perfoma* sedikit lebih rendah dari SIFT dengan nilai *f1-score*, *recall*, dan presisi berdasarkan *weighted average* berturut-turut 0,74, 0,74, dan 0,76. Selanjutnya, model yang menggunakan fitur LBP menjadi model dengan matriks performa terburuk dengan nilai *f1-score*, *recall*, dan presisi berdasarkan *weighted average* berturut-turut 0,40, 0,43, dan 0,44. Berdasarkan analisis ini diketahui bahwa model kombinasi dengan matriks performa terbaik adalah model SVM yang menggunakan fitur HOG dan fitur CNN. Analisis dilanjutkan berdasarkan uji klasifikasi dengan hasil pada tabel 4.3.

Tabel 4.3 Hasil Uji Klasifikasi Model dengan *Feature Descriptor*

Kelas Aktual	Kelas Prediksi				
	HOG+SVM	SIFT+SVM	LBP+SVM	GLCM+SVM	CNN+SVM
Batu	Batu	Batu	Tumor	Batu	Batu
Kista	Kista	Kista	Kista	Batu	Kista
Normal	Normal	Batu	Batu	Batu	Normal
Tumor	Tumor	Tumor	Batu	Batu	Normal

Pada Tabel 4.3 dapat diamati hasil uji klasifikasi model dengan fitur *descriptor* dengan *dataset* eksternal. Berdasarkan hasil uji klasifikasi diketahui model yang menggunakan fitur HOG memiliki hasil uji klasifikasi sempurna. Kemudian, model yang menggunakan fitur SIFT dan model yang menggunakan fitur CNN menjadi model yang baik dengan hanya mengalami satu kesalahan prediksi. Model yang menggunakan fitur SIFT mengalami kesalahan pada kelas aktual ginjal normal sebagai batu ginjal dan model yang menggunakan fitur CNN mengalami kesalahan pada aktual tumor ginjal sebagai ginjal normal. Selanjutnya, model yang menggunakan fitur LBP dan model yang menggunakan fitur GLCM menjadi yang terburuk dari hasil uji klasifikasi dengan mengalami tiga kesalahan kelas aktual. Model yang menggunakan fitur LBP dan fitur GLCM mengalami bias terhadap kelas batu. Berdasarkan analisis ini diketahui bahwa model dengan uji klasifikasi terbaik adalah model yang menggunakan fitur HOG. Analisis dilanjutkan berdasarkan waktu ekstraksi fitur dengan hasil pada Tabel 4.4.

Tabel 4.4 Waktu Pelatihan Model dengan *Feature Descriptor*

Model Klasifikasi	Waktu Pelatihan Model
HOG+SVM	50,3 detik
SIFT+SVM	0,716 detik
LBP+SVM	0,259 detik
GLCM+SVM	0,199 detik
CNN+SVM	28,2 detik

Pada Tabel 4.4 dapat diamati waktu pelatihan model dengan fitur *descriptor*. Pada tabel tersebut diketahui model yang menggunakan fitur GLCM menjadi model dengan waktu pelatihan model tersingkat yaitu 0,199 detik. Kemudian, model yang

menggunakan fitur LBP memiliki waktu pelatihan model sedikit lebih lama yaitu 0,259 detik. Lalu, model yang menggunakan fitur SIFT memiliki waktu pelatihan model 0,716 detik. Selanjutnya, model yang menggunakan CNN memiliki waktu pelatihan model 28.2 detik. Kemudian, model yang menggunakan fitur HOG menjadi yang terlama yaitu 50,3 detik. Sehingga model yang memiliki waktu pelatihan model tercepat adalah model yang menggunakan fitur LBP.

Berdasarkan perbandingan ini dapat dilakukan analisis terhadap keakuratan pada proses klasifikasi penyakit ginjal melalui citra CT scan dan mengetahui keefektifan penggunaan *feature descriptor* dalam proses klasifikasi penyakit ginjal melalui analisis citra CT scan. Berdasarkan keakuratan, model tanpa *descriptor* diketahui kurang akurat dalam pengujian kelas aktuar tumor yang membuat model mengalami kesalahan klasifikasi pada uji klasifikasi. Meskipun begitu, model tanpa *descriptor* SVM menjadi model terbaik yang mengungguli MLP dan *naïve bayes* dari segi matriks performa dan waktu pelatihan model. Nilai *f1-score* dan proses komputasi yang optimal menjadikan SVM sebagai model analisis dengan kombinasi *feature descriptor*. Selanjutnya, berdasarkan keakuratan model yang menggunakan *feature descriptor*, nilai matriks performa dan uji klasifikasi dari fitur yang berdasar pada intensitas gambar (LBP dan GLCM) tidak direkomendasikan untuk digunakan pada klasifikasi penyakit ginjal melalui citra CT scan dilihat dari performa yang buruk, meskipun memiliki waktu komputasi yang lebih cepat.

Berdasarkan analisis ini pula dapat diketahui keefektifan dari penggunaan *feature descriptor* pada model klasifikasi penyakit ginjal melalui citra CT scan organ ginjal. Model yang menggunakan *feature descriptor* efektif mengatasi permasalahan kesulitan pada klasifikasi data uji kelas tumor ginjal melalui penggunaan fitur HOG pada pelatihan model SVM. Kombinasi model ini memperoleh hasil uji klasifikasi yang sempurna pada empat kelas aktual pada data uji. Kemudian, model yang menggunakan *feature descriptor* memiliki waktu pelatihan model lebih cepat 14%-99.7% jika dibandingkan dengan model tanpa *descriptor*. Hasil ini disebabkan adanya reduksi kompleksitas dari penggunaan *feature descriptor* yang dapat membantu model memiliki waktu pelatihan lebih cepat. Oleh karena itu, penggunaan *feature descriptor* dapat efektif dalam meningkatkan potensi pembelajaran model dan mereduksi waktu komputasi.

BAB V

PENUTUP

5.1. Kesimpulan

Adapun kesimpulan pada penelitian ini adalah sebagai berikut.

1. Model tanpa *feature descriptor* tidak akurat dalam mengklasifikasikan kelas aktual tumor ginjal. Kemudian, model SVM yang dilatih dengan fitur HOG mampu mengatasi permasalahan klasifikasi kelas tumor dengan hasil uji klasifikasi yang sempurna dan rata-rata tertimbang f1 score sebesar 1.
2. Penggunaan *feature descriptor* terbukti efektif dalam membantu model meningkatkan potensi pembelajaran model terutama pada permasalahan klasifikasi data uji kelas tumor ginjal. Kemudian, penggunaan feature descriptor efektif dalam mereduksi waktu komputasi sebanyak 14%-99.7%.

5.2. Saran

Adapun saran pada penelitian ini adalah sebagai berikut.

1. Pada penelitian selanjutnya dapat dilakukan penyesuaian kompleksitas model untuk meningkatkan performa akurasi dan efisiensi sumber daya komputasi.
2. Pada penelitian selanjutnya dapat dilakukan pendalaman pada setiap bias klasifikasi yang terjadi akibat komposisi model atau *descriptor* yang digunakan.
3. Pada penelitian selanjutnya dapat digunakan atau ditambah format CT *scan* lain seperti *coronal* dan *sagittal*.

ORIGINALITY REPORT

12%	11%	4%	5%
SIMILARITY INDEX	INTERNET SOURCES	PUBLICATIONS	STUDENT PAPERS

PRIMARY SOURCES

1	eprints.uad.ac.id Internet Source	1%
2	123dok.com Internet Source	1%
3	ojs.uajy.ac.id Internet Source	1%
4	repository.its.ac.id Internet Source	1%
5	digilib.unila.ac.id Internet Source	<1%
6	www.scribd.com Internet Source	<1%
7	www.mdpi.com Internet Source	<1%
8	docplayer.info Internet Source	<1%
9	Submitted to Universitas Brawijaya Student Paper	<1%
10	repository.ub.ac.id Internet Source	<1%
11	eprints.untirta.ac.id Internet Source	<1%

12	danigunawan.github.io Internet Source	<1 %
13	Submitted to UIN Sultan Syarif Kasim Riau Student Paper	<1 %
14	Submitted to Universitas Gunadarma Student Paper	<1 %
15	febrineldiko.files.wordpress.com Internet Source	<1 %
16	Submitted to Sriwijaya University Student Paper	<1 %
17	repositori.uin-alauddin.ac.id Internet Source	<1 %
18	Submitted to Universitas Nahdlatul Ulama Surabaya Student Paper	<1 %
19	e-repository.perpus.iainsalatiga.ac.id Internet Source	<1 %
20	repository.radenintan.ac.id Internet Source	<1 %
21	text-id.123dok.com Internet Source	<1 %
22	eprints.politeknikpu.ac.id Internet Source	<1 %
23	repositori.usu.ac.id Internet Source	<1 %
24	repository.unhas.ac.id Internet Source	<1 %

25	Internet Source	<1 %
26	repository.upnjatim.ac.id Internet Source	<1 %
27	santozuwh.wordpress.com Internet Source	<1 %
28	Submitted to Middlesex University Student Paper	<1 %
29	adoc.pub Internet Source	<1 %
30	www.dqlab.id Internet Source	<1 %
31	www.ikn.go.id Internet Source	<1 %
32	www.jurnal.iaii.or.id Internet Source	<1 %
33	Sutriawan Sutriawan, Ahmad Zainul Fanani, Farrikh Alzami, Ruri Suko Basuki. "Deep Learning Jaringan Saraf Tiruan Untuk Pemecahan Masalah Deteksi Penyakit Daun Apel", Jurnal Teknologi Informasi dan Komunikasi (TIKomSiN), 2023 Publication	<1 %
34	Submitted to Universitas Pamulang Student Paper	<1 %
35	digilib.uinsby.ac.id Internet Source	<1 %
36	ejournal.unp.ac.id Internet Source	<1 %

37	seminar.ilkom.unsri.ac.id Internet Source	<1 %
38	www.bigdatadba.com Internet Source	<1 %
39	dqlab.id Internet Source	<1 %
40	idoc.pub Internet Source	<1 %
41	iwan.staff.gunadarma.ac.id Internet Source	<1 %
42	sharepaste.blogspot.com Internet Source	<1 %
43	www.draroche.com Internet Source	<1 %
44	www.spiedigitallibrary.org Internet Source	<1 %
45	id.scribd.com Internet Source	<1 %
46	jurnal.fk.umi.ac.id Internet Source	<1 %
47	media.neliti.com Internet Source	<1 %
48	repository.umi.ac.id Internet Source	<1 %
49	www.maxrooted.com Internet Source	<1 %
50	www.researchgate.net Internet Source	<1 %

51	www.science.gov Internet Source	<1 %
52	anzdoc.com Internet Source	<1 %
53	core.ac.uk Internet Source	<1 %
54	ejournal.polbeng.ac.id Internet Source	<1 %
55	pt.scribd.com Internet Source	<1 %
56	repositori.unsil.ac.id Internet Source	<1 %
57	www.ejurnal.stmik-budidarma.ac.id Internet Source	<1 %
58	aguskrisnoblog.wordpress.com Internet Source	<1 %
59	batampos.co.id Internet Source	<1 %
60	danielstephanus.wordpress.com Internet Source	<1 %
61	ejournal.unma.ac.id Internet Source	<1 %
62	hamsmars.wordpress.com Internet Source	<1 %
63	id.123dok.com Internet Source	<1 %
64	jtika.if.unram.ac.id Internet Source	<1 %

65	openlibrarypublications.telkomuniversity.ac.id Internet Source	<1 %
66	openpublichealthjournal.com Internet Source	<1 %
67	pdfcoffee.com Internet Source	<1 %
68	repository.nusamandiri.ac.id Internet Source	<1 %
69	repository.ppns.ac.id Internet Source	<1 %
70	repository.uinjkt.ac.id Internet Source	<1 %
71	repository.unika.ac.id Internet Source	<1 %
72	www.coursehero.com Internet Source	<1 %
73	www.slideshare.net Internet Source	<1 %
74	Ghalyh Wardhana Putra, Hajri Taqin Musthofa, Andriyanto Andriyanto. "DESKRIPSI PENGGUNAAN APLIKASI MICROSOFT TEAMS DALAM PEMBELAJARAN DARING MATA PELAJARAN SEJARAH INDONESIA", Keraton: Journal of History Education and Culture, 2020 Publication	<1 %
75	J. Jenifa Sharon, L. Jani Anbarasi. "An attention enhanced dilated bottleneck network for	<1 %

kidney disease classification", Scientific Reports, 2025

Publication

76	Abdalbasit Mohammed Qadir, Dana Faiq Abd. "Kidney Diseases Classification using Hybrid Transfer-Learning DenseNet201-Based and Random Forest Classifier", Kurdistan Journal of Applied Research, 2023	<1 %
----	---	------

Publication

77	Afrian Hanafi, Adiwijaya Adiwijaya, Widi Astuti. "Klasifikasi Multi Label pada Hadis Bukhari Terjemahan Bahasa Indonesia Menggunakan Mutual Information dan k-Nearest Neighbor", Jurnal Sisfokom (Sistem Informasi dan Komputer), 2020	<1 %
----	--	------

Publication

78	Richky Faizal Amir, Irwan Agus Sobari, Rousyati Rousyati. "Penerapan PSO Over Sampling Dan Adaboost Random Forest Untuk Memprediksi Cacat Software", Indonesian Journal on Software Engineering (IJSE), 2020	<1 %
----	--	------

Publication

79	ouci.dntb.gov.ua Internet Source	<1 %
----	---	------

80	repository.uin-suska.ac.id Internet Source	<1 %
----	---	------

81	garuda.kemdikbud.go.id Internet Source	<1 %
----	---	------

Exclude quotes On

Exclude matches Off

Exclude bibliography On

FINAL GRADE

GENERAL COMMENTS

/100

PAGE 1

PAGE 2

PAGE 3

PAGE 4

PAGE 5

PAGE 6

PAGE 7

PAGE 8

PAGE 9

PAGE 10

PAGE 11

PAGE 12

PAGE 13

PAGE 14

PAGE 15

PAGE 16

PAGE 17

PAGE 18

PAGE 19

PAGE 20

PAGE 21

PAGE 22

PAGE 23

PAGE 24

PAGE 25

PAGE 26

PAGE 27

PAGE 28

PAGE 29

PAGE 30

PAGE 31

PAGE 32

PAGE 33

PAGE 34

PAGE 35

PAGE 36

PAGE 37

PAGE 38

PAGE 39

PAGE 40

PAGE 41

PAGE 42

PAGE 43

PAGE 44

PAGE 45

PAGE 46

PAGE 47

PAGE 48

PAGE 49

PAGE 50

RUBRIC: SHORT ANSWER

CLAIM/FOCUS

State a clear claim/topic sentence and stay focused on supporting it.

MEETS EXPECTATIONS A precise claim/topic sentence based on the topic and/or source(s) is present. The response maintains a strong focus on developing the claim/topic sentence, thoroughly addressing the demands of the task.

APPROACHES EXPECTATIONS A claim/topic sentence based on the topic and/or source(s) is present, but it may not completely address the demands of the task, or the response does not maintain focus on developing it.

DOESN'T MEET EXPECTATIONS The claim/topic sentence is vague, unclear, or missing, and the response does not address the demands of the task.

SUPPORT/EVID

Provide evidence and explain how it supports the claim/topic sentence.

MEETS EXPECTATIONS The response includes sufficient, appropriate evidence to support the claim/topic sentence. Reasoning and understanding of the topic and/or source(s) are demonstrated by thorough explanations of the relationship between claims and support.

APPROACHES EXPECTATIONS The response presents some evidence to support the claim/topic sentence, but it may be insufficient or inappropriate. Some reasoning and understanding of the topic and/or source(s) are demonstrated, but attempts to explain the relationship between claims and support are inadequate.

DOESN'T MEET EXPECTATIONS Evidence is general or largely absent, and explanation of the relationship between claims and support is minimal.

ORGANIZATION

Present ideas in a logical structure that shows the relationships between ideas.

MEETS EXPECTATIONS An effective organizational structure enhances the reader's understanding of the information. The relationships between ideas are made clear with effective transitional phrases.

APPROACHES EXPECTATIONS An organizational structure is evident, but may not be fully developed or appropriate. Transitional phrases may be used but the relationships between ideas are somewhat unclear.

DOESN'T MEET EXPECTATIONS An organizational structure is largely absent and the relationships between ideas are unclear.

LANGUAGE

Communicate ideas using formal language and vocabulary specific to the topic.

MEETS EXPECTATIONS The response has an established, formal style that is maintained throughout. Varied sentence structure, precise language, and domain-specific vocabulary are used to communicate ideas effectively. The response may stray from an objective tone at times, or have some errors that do not interfere with meaning.

APPROACHES EXPECTATIONS The response attempts a formal style that may not be maintained throughout. Sentence structure is somewhat varied and some precise language and/or domain-

specific vocabulary are used. The response contains some errors that may interfere with meaning.

DOESN'T MEET
EXPECTATIONS

The response does not establish a formal style and ideas are unclear at times. There is little variety in sentence structure and language is general throughout. The response contains several errors that interfere with meaning.