

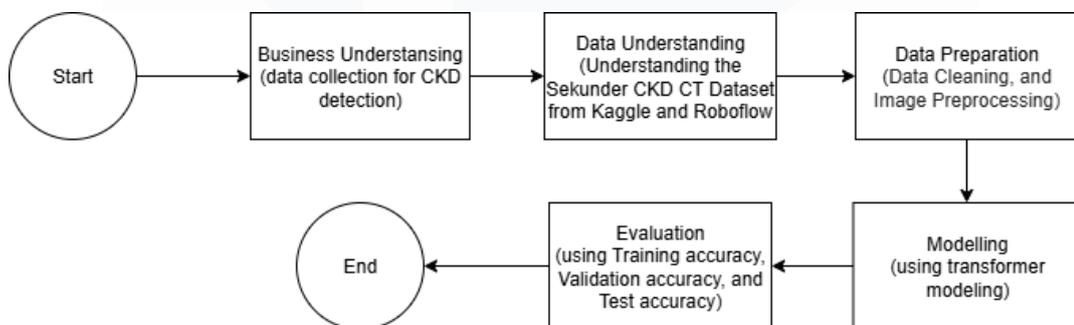
## BAB III

### METODE PENELITIAN

#### 3.1. Metode Penelitian

Penelitian ini menggunakan CRISP-DM karena menjadi salah satu metodologi yang paling populer dan efektif untuk memecahkan permasalahan dalam data mining. CRISP-DM (*C*Ross-*I*ndustry *S*tandard *P*rocess for *D*ata *M*ining) merupakan pendekatan yang paling banyak digunakan untuk melaksanakan proyek-proyek data mining dan data science. CRISP-DM adalah hasil dari para praktisi yang mensintesisasikan pengalaman data mining mereka ke dalam pendekatan yang sistematis dan standar[41]

##### 3.1.1 Alur Penelitian



Gambar 3. 1 Alur Penelitian

#### 3.2 Tahapan Penelitian

##### 3.2.1 Business Understanding

Pada tahap *Business Understanding*, tugas utama yang dilakukan adalah mengumpulkan referensi ilmiah yang relevan untuk membangun teori dan mendukung pengembangan model, dengan melakukan pencarian pada berbagai jurnal internasional yang membahas penerapan *deep learning*, *Computed Tomography Scan* (CTScan), detection, dan penyakit ginjal kronis (CKD) dalam bidang pengolahan citra medis. Fokus utama pencarian adalah jurnal-jurnal yang membahas deteksi penyakit ginjal

kronis (CKD), klasifikasi gambar CT scan, dan penggunaan model ViT, Swin, dan DeiT. Referensi yang ditemukan digunakan untuk memahami metode dan hasil yang sudah ada. Sumber jurnal dipilih dari berbagai platform seperti Google Scholar, ScienceDirect dan aplikasi publish or perish untuk mempermudah dalam mencari jurnal. Jurnal yang dipilih berdasarkan relevansi topik, tahun publikasi terbaru (5 tahun terakhir), dan hasil penelitian yang kuat.

### 3.2.2 Data Understanding

Pada tahap *Data Understanding*, kegiatan utama yang dilakukan mencari dan memahami dataset citra CT scan ginjal yang akan digunakan dalam pelatihan model. Dataset diambil dari dua sumber terbuka, yaitu Kaggle <https://lnk.ink/www.kaggle.com> dan Roboflow <https://lnk.ink/universe.roboflow.com>, yang menyediakan citra medis terkait penyakit ginjal. Dataset kaggle mendapatkan data asli yang dikumpulkan dari Sistem PACS (*Picture Archiving and Communication System*) di berbagai rumah sakit di Dhaka, Bangladesh, namun untuk data asli dari dataset roboflow tidak disebutkan dimana data tersebut di dapatkan. Tahapan ini menggunakan 2 dataset supaya datanya lebih banyak dan lebih beragam sehingga bisa menghindari overfitting pada saat pelatihan, pengambilan data pada dataset kaggle dilakukan pada tahun 2022 dan dataset roboflow pada tahun 2023. Setelah mendapatkan dataset dilakukannya evaluasi untuk memahami struktur data, format gambar, dan informasi label yang tersedia. Bagian ini sangat penting untuk memastikan data yang digunakan memenuhi persyaratan klasifikasi multi-kelas. Dalam proses eksplorasi, ditemukan bahwa dataset yang ditemukan terdiri dari empat kelas, yaitu normal, batu, tumor, dan kista ginjal, serta jumlah dari dataset kaggle (12.446) dan roboflow (13.878). Selain itu proses ini juga mencatat jumlah gambar pada masing-masing kelas untuk mengetahui apakah terdapat ketidakseimbangan data. Tahapan ini menjadi langkah penting sebelum masuk ke tahap selanjutnya. Dengan pemahaman yang baik terhadap data, model dapat dirancang dan dievaluasi secara lebih akurat dan efektif.

Tabel 3. 1 jumlah data kaggle dan roboflow

Dataset	Jumlah Dataset	Kelas			
		Normal	Batu	Tumor	Kista
Kaggle	12.446	5,077	1,377	2,283	3,709
Roboflow	13.878	2,998	3,230	5,049	2,601
Total Dataset	26.324				

Tabel diatas menunjukkan jumlah data dari setiap kelas pada dataset kaggle dan roboflow

### 3.2.3 Data Preparation

Data *preparation* menjadi tahapan yang penting dalam proses analisis data, terutama dalam pengolahan data dan gambar. Tahapan ini dilakukan untuk menyediakan gambar dalam format yang sesuai untuk pelatihan model setelah proses data cleaning selesai. tahapan ini berguna untuk mengubah gambar ke dalam format yang lebih sesuai dengan meningkatkan ukuran gambar (224x224), random rotasi sebesar 10, gangguan warna dengan keterangan dan kontras sebesar 0,2, Tahapan ini berguna untuk memudahkan model dalam belajar dan mengenali pola atau fitur pada gambar dengan lebih akurat serta memastikan semua gambar memiliki format dan ukuran yang sesuai dengan kebutuhan input model, sehingga pelatihan dapat dilakukan dengan lancar.

### 3.2.4 Modelling

Pada tahapan *modeling*, data dibagi menjadi tiga bagian, data pelatihan (training), validasi (validation), dan pengujian (test). Pembagian ini dilakukan supaya model dapat dilatih, diuji performanya selama proses pelatihan, dan dievaluasi secara objektif pada data yang belum pernah dilihat sebelumnya untuk mendapatkan hasil yang bagus. Data pelatihan membantu model mengenali pola dari masing-masing kelas, dan data validasi memantau performa model pada setiap titik waktu dan membantu mencegah overfitting.

Arsitektur transformer dengan variannya yaitu Vision Transformer (ViT), Swin Transformer, dan Data-efficient Image Transformer (DeiT) digunakan sebagai arsitektur model dalam penelitian ini. Ketiga model ini dilatih dengan konfigurasi dan parameter yang disesuaikan untuk mendapatkan hasil yang optimal. Pelatihan dilakukan secara bertahap hingga model memiliki tingkat keakuratan dan kehilangan yang paling rendah. Selama pelatihan, metrik penting seperti akurasi, dan kehilangan dicatat. Model yang memiliki performa terbaik pada data validasi akan dievaluasi dengan data pengujian. Tahapan modeling ini sangat penting untuk menilai keberhasilan model dalam mendeteksi penyakit ginjal kronis melalui gambar CT scan.

Tabel 3. 2 Optimation Hyperparameter

Model	Batch Size	Optimation	Total Parameter
DeiT	32	Lr = 1e-4	86572268
Swin	32	Lr = 1e-4	-
ViT	32	Lr = 1e-4	-

Tabel 3.2 menunjukkan konfigurasi pelatihan dari tiga model deep learning berbasis arsitektur transformer yang digunakan dalam penelitian ini, yaitu DeiT, Swin, dan ViT. Dalam pelatihan, setiap model dilatih dengan ukuran batch 32 gambar, Learning rate (Lr) sebesar 1e-4 adalah optimizer yang digunakan. Hal ini adalah nilai yang cukup umum untuk pelatihan model transformer supaya mencapai hasil yang stabil. Konfigurasi ini dibuat seragam supaya hasil evaluasi antar model dapat dibandingkan secara adil. Jumlah parameter model DeiT sebanyak 86.572.268 menunjukkan betapa kompleksnya arsitekturnya. Namun, pada model Swin Transformer dan ViT, tabel tidak mencantumkan jumlah parameter total karena belum dihitung atau belum tersedia saat dokumen disusun. Namun, pendekatan transfer learning digunakan untuk seluruh model. Hal ini berarti bobot awal model berasal dari model yang telah dilatih sebelumnya.

Diharapkan model akan belajar lebih cepat dan menghasilkan akurasi yang bagus dengan pengaturan ini. Tabel ini memberikan gambaran awal tentang struktur pelatihan yang konsisten antar model. Informasi ini penting dalam menjelaskan kondisi eksperimen sebelum masuk ke tahap evaluasi performa.



### 3.2.5 Evaluation

Tabel 3. 3 Hasil Akurasi Model deteksi CKD dengan Transformer based

<b>Dataset</b>	<b>Model</b>	<b>Epoch</b>	<b>Train Accuracy</b>	<b>Val Accuracy</b>	<b>Test Accuracy</b>
<b>Kaggle</b>	Vit	26	84.09%	86.03%	97.91%
	Swin	20	97.19%	97.52%	99.76%
	Deit	30	98.24%	96.82%	98.80%
<b>Roboflow</b>	Vit	63	76.82%	81.20%	97.86%
	Swin	25	96.94%	98.39%	99.87%
	Deit	17	99.14%	99.11%	99.33%
<b>Kaggle and Roboflow</b>	Vit	40	83.58%	84.32%	98.48%
	Swin	18	97.57%	98.51%	99.81%
	Deit	51	89.62%	76.72%	97.11%

Tabel 3. 4 Optimasi Hyperparameter

<b>Dataset</b>	<b>Model</b>	<b>Epoch</b>	<b>Train Accuracy</b>	<b>Val Accuracy</b>	<b>Test Accuracy</b>
<b>Kaggle</b>	Vit	81	98.42%	98.76%	85.00%
	Swin	29	99.14%	99.47%	100%
	Deit	28	99.91%	99.82%	99.92%
<b>Roboflow</b>	Vit	70	99.12%	99.71%	100%
	Swin	24	99.51%	99.80%	100%
	Deit	37	99.76%	100%	100%
<b>Kaggle and Roboflow</b>	Vit	68	98.44%	99.13%	99.96%
	Swin	21	99.37%	99.82%	99.92%
	Deit	27	99.71%	99.90%	100.00%

N U S A N T A R A

Tabel 3.3 dan 3.4 menunjukkan hasil akurasi yang berbeda beda. sebelum dilakukannya optimasi hyperparameter, model ViT menunjukkan peningkatan yang signifikan pada akurasi pelatihan dan validasi pada dataset Kaggle. Sebelum dioptimalkan, keakuratan pelatihan ViT hanya 84,09% dan keakuratan validasi 86,03%; namun, keakuratan keduanya meningkat menjadi 98,42% dan 98,76% setelah dioptimalkan. Meskipun demikian, test accuracy justru turun dari 97.91% menjadi 85.00%, yang kemungkinan besar menunjukkan overfitting. Model Swin menunjukkan hasil yang sangat baik, dengan train accuracy meningkat dari 97.19% menjadi 99.14%, dan test accuracy meningkat dari 99.76% menjadi 100%. Sementara itu, DeiT, yang sebelumnya memiliki train accuracy 98,24% dan test accuracy 98,80%, naik menjadi 99.91% dan 99.92%, masing-masing, menunjukkan peningkatan yang signifikan dan konsisten.

Pada dataset Roboflow, model ViT, yang sebelumnya memiliki akurasi paling rendah 76.82% train dan 81.20% validasi, mengalami peningkatan besar setelah dioptimasi menjadi 99.12% dan 99.71%. Akurasi pengujian model Swin juga meningkat dari 96.94% train dan 98.39% val menjadi 99.51% dan 99.80%, akurasi pengujian model DeiT juga meningkat dari 99.87% menjadi 100%, yang menunjukkan bahwa pengoptimalan mampu mengatasi masalah underfitting.

Pada dataset Kaggle dan Roboflow (gabungan), ViT mengalami peningkatan akurasi pelatihan dari 83.58% ke 98.44%, serta validasi dari 84.32% ke 99.13%. Akurasi tes ViT juga meningkat dari 98.48% ke 99.96%, yang menunjukkan bahwa optimasi dan gabungan dataset memiliki dampak yang signifikan. Swin sebelumnya memiliki hasil yang baik train 97,57%, dan test 99,81%, setelah di optimalkan, hasilnya meningkat menjadi 99,37% train dan 99.92% test. Sementara model DeiT awalnya memiliki validasi yang rendah 76,72% dan test accuracy 97,11%, tetapi hasilnya meningkat drastis menjadi 99.90% validasi dan 100% tes akurasi. Peningkatan ini menunjukkan bahwa DeiT sangat responsif terhadap pengoptimalan parameter pada data gabungan.