



**PROPOSAL
PROYEK AKHIR**

**DETEKSI PENDARAHAN OTAK (INTRACRANIAL HEMORRHAGE)
BERDASARKAN CT-SCAN IMAGE DENGAN METODE VISION
TRANSFORMER (ViT)**

Muhammad Nur Faiz

NRP. 3120600028

DOSEN PEMBIMBING

Tessy Badriyah, S.Kom., M.Kom., Ph.D.

NIP. 197009142001122001

Selvia Ferdiana Kusuma, S.Kom., M.Kom.

NIP. 199107222022032005

**PROGRAM STUDI D4 TEKNIK INFORMATIKA
DEPARTEMEN TEKNIK INFORMATIKA DAN KOMPUTER
POLITEKNIK ELEKTRONIKA NEGERI SURABAYA**

2023

BAB 1

PENDAHULUAN

1.1. LATAR BELAKANG

Cedera kepala merupakan penyebab mortalitas dan morbiditas terbanyak di negara-negara maju maupun berkembang. Cedera kepala dapat terjadi akibat benturan langsung maupun tidak langsung pada kepala. Hal ini biasanya menyebabkan pendarahan (*patologis*) yang terjadi di dalam kranium, yang mungkin ekstradural, subdural, subaraknoid, atau serebral (parenkimatosa), yang sering disebut dengan pendarahan otak atau Intracranial Hemorrhage (ICH). Pendarahan otak dapat terjadi pada semua umur dan juga akibat trauma kepala seperti kapitis, tumor otak dan lain-lain. Sekitar 8-13% ICH menjadi penyebab terjadinya stroke dan kelainan dengan spektrum yang luas. Bila dibandingkan dengan stroke iskemik atau pendarahan subaraknoid, ICH umumnya lebih banyak mengakibatkan kematian atau cacat mayor. ICH yang disertai dengan edema akan mengganggu atau mengkompresi jaringan otak sekitarnya, menyebabkan disfungsi neurologis. Perpindahan substansi parenkim otak dapat menyebabkan peningkatan ICP dan sindrom herniasi yang berpotensi fatal.

Salah satu cara diagnosis pendarahan otak (ICH) adalah mengambil gambar otak pasien atau yang biasa disebut CT-Scan. CT-Scan dapat menunjukkan kelainan pada otak seperti pembengkakan atau pembekuan darah. Diagnosa tersebut lalu dianalisis oleh dokter ahli agar diketahui apakah terdapat pendarahan otak (ICH) atau tidak. Sayangnya analisis CT-Scan saat ini masih dilakukan secara manual dan harus dilakukan oleh dokter atau ahli yang memahami. Tenaga Kesehatan yang tidak memiliki kemampuan dalam menganalisis hasil CT-Scan secara langsung karena tidak memiliki standar pengetahuan yang cukup menjadi penghambat dalam proses analisa CT-Scan karena tidak selamanya tenaga ahli dan dokter tersedia setiap saat.

Dalam Proyek Akhir ini akan dibangun sebuah aplikasi deteksi pendarahan otak (ICH) dengan metode Vision Transformer (ViT). Vision Transformer adalah sebuah arsitektur jaringan saraf yang dikembangkan untuk memproses data gambar atau visual menggunakan metode transformasi. Vision Transformer dapat mendeteksi dan menganalisa citra CT-Scan pendarahan otak. Metode Vision Transformer diketahui memiliki tingkat keakuratan yang mirip dengan metode Convolutional Neural Network

(CNN) namun memiliki tingkat keefisienan lebih tinggi (Cuenat et al. 2021). Proyek Akhir ini diharapkan dapat membantu proses Analisa pendarahan otak dengan CT-Scan secara otomatis dan tidak harus menggunakan tenaga ahli atau dokter.

1.2. PERUMUSAN MASALAH

Berdasarkan dari uraian latar belakang diatas, maka rumusan masalah dari proyek akhir ini adalah diagnosa pendarahan otak (ICH) dan penentuan jenisnya masih dilakukan secara manual dengan cara mengambil gambar otak atau sering disebut CT-Scan kemudian baru hasil foto tersebut dianalisis oleh dokter spesialis radiologi yang berpengalaman. Ketika tenaga ahli dan spesialis tidak tersedia maka petugas kesehatan yang ada kesulitan dalam menganalisa pendarahan otak sehingga dapat menghambat proses perawatan pasien.

1.3. TUJUAN

Pada proyek akhir ini dilakukan pembangunan aplikasi berbasis web dengan pemodelan Vision Transformer (ViT) sebagai alat bantu dokter untuk mendeteksi pendarahan otak (ICH) berdasarkan gambar CT-Scan dari pasien. Pembangunan sistem proyek akhir ini dilakukan dengan menggunakan bahasa pemrograman Python dan *web framework* Django dengan tampilan antarmuka yang *user friendly* agar memudahkan pengguna dalam memakai sistem deteksi pendarahan otak (ICH) ini.

1.4. MANFAAT

Manfaat yang akan diperoleh dari Proyek Akhir ini adalah berikut:

1. Membantu proses klasifikasi jenis pendarahan otak (ICH) dengan CT-Scan otak yang dibagi menjadi lima kelas yaitu *Epidural, Intracerebral, Intraventricular, Subarachnoid, Subdural*.
2. Membantu ahli untuk menganalisa ICH secara otomatis.
3. Membantu ahli mengetahui tingkat dan probabilitas dari ICH yang terdeteksi.
4. Membantu ahli dan pihak yang membutuhkan dalam menyimpan hasil Analisa gambar CT-Scan dan dilacak riwayatnya.

1.5. SISTEMATIKA PENULISAN

Sistematika pembahasan pada proposal proyek akhir ini adalah sebagai berikut:

Bab 1 **Pendahuluan**

Bab ini berisi tentang latar belakang, perumusan masalah, tujuan, manfaat, dan sistematika pada penulisan penelitian ini.

Bab 2

Kajian Pustaka

Bab ini membahas mengenai deskripsi permasalahan, hasil studi literatur yang dilakukan, dan penelitian terkait yang berkaitan dengan penyelesaian penelitian ini.

Bab 3

Desain Sistem

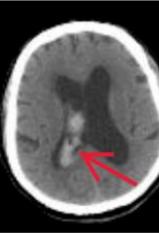
Bab ini membahas mengenai deskripsi solusi serta desain sistem rancangan dan alur proses yang dilakukan dalam penelitian ini.

BAB 2

TEORI PENUNJANG

2.1. PENDARAHAN OTAK

Pendarahan otak atau *intracranial hemorrhage* (ICH) terjadi ketika terjadi pecahnya pembuluh darah di otak yang menyebabkan perdarahan di dalam atau sekitar jaringan otak [2]. Hal ini dapat menyebabkan kerusakan jaringan otak dan dapat mengancam jiwa.

| | Intraparenchymal | Intraventricular | Subarachnoid | Subdural | Epidural |
|--------------|---|---|---|---|---|
| Location | Inside of the brain | Inside of the ventricle | Between the arachnoid and the pia mater | Between the Dura and the arachnoid | Between the dura and the skull |
| Imaging |  |  |  |  |  |
| Mechanism | High blood pressure, trauma, arteriovenous malformation, tumor, etc | Can be associated with both intraparenchymal and subarachnoid hemorrhages | Rupture of aneurysms or arteriovenous malformations or trauma | Trauma | Trauma or after surgery |
| Source | Arterial or venous | Arterial or venous | Predominantly arterial | Venous (bridging veins) | Arterial |
| Shape | Typically rounded | Conforms to ventricular shape | Tracks along the sulci and fissures | Crescent | Lentiform |
| Presentation | Acute (sudden onset of headache, nausea, vomiting) | Acute (sudden onset of headache, nausea, vomiting) | Acute (worst headache of life) | May be insidious (worsening headache) | Acute (skull fracture and altered mental status) |

Gambar 2.1 Ilustrasi Klasifikasi Intracranial Hemorrhage

Berikut lima jenis ICH yang dikembangkan pada Proyek Akhir ini beserta penyebab dan gejala pendarahan:

1. **Pendarahan Otak Epidural** adalah jenis pendarahan otak yang terjadi ketika pembuluh darah di ruang epidural pecah menyebabkan darah menumpuk. Penyebab umumnya adalah trauma kepala yang parah, seperti kecelakaan mengakibatkan benturan keras pada kepala. Gejalanya antara lain sakit kepala yang parah, mual dan muntah, kelemahan atau kelumpuhan pada satu sisi tubuh, kejang, kebingungan atau kehilangan kesadaran.
2. **Pendarahan Otak Intraparenkimal (Intracerebral)** adalah jenis pendarahan otak yang terjadi ketika pembuluh darah di dalam otak pecah, menyebabkan darah merembes ke dalam jaringan otak dan membentuk bekuan darah atau hematoma. Penyebabnya dapat bervariasi, tetapi tekanan darah tinggi

(hipertensi) adalah penyebab utama. Beberapa gejala yang umum terjadi meliputi sakit kepala yang parah, kelemahan atau kelumpuhan pada satu sisi tubuh, kesulitan berbicara atau memahami kata-kata, kejang, mual atau muntah, dan kehilangan kesadaran.

3. **Pendarahan Otak Intraventrikular** adalah jenis pendarahan otak yang terjadi ketika pembuluh darah di dalam sistem ventrikel otak pecah, sehingga darah merembes ke dalam cairan serebrospinal. Penyebab umumnya berkaitan dengan cedera kepala atau trauma yang parah, perdarahan intraparenkimal, kelainan pembuluh darah, atau stroke. Beberapa gejala yang mungkin terjadi termasuk sakit kepala yang parah, mual dan muntah, kelemahan atau kelumpuhan pada satu sisi tubuh, kejang, kebingungan, dan kesulitan dalam berbicara atau memahami bahasa.
4. **Pendarahan Otak Subarachnoid** adalah jenis pendarahan otak yang terjadi di ruang subarachnoid atau ruang yang terdapat di antara otak dan membran yang melapisi otak, yang disebut arakhnoid. Penyebabnya bervariasi, tetapi yang paling umum adalah pecahnya aneurisma otak. Gejalanya biasanya dimulai dengan sakit kepala hebat yang tiba-tiba.
5. **Pendarahan Otak Subdural** adalah pendarahan otak yang terjadi ketika pembuluh darah di antara permukaan otak dan lapisan terluar yang menutupi otak pecah dan menyebabkan darah merembes ke dalam ruang subdural. Penyebabnya yang paling umum adalah cedera kepala yang parah, terutama pada orang yang berusia lebih tua, anak-anak kecil, atau pada orang dengan riwayat alkoholisme atau penggunaan obat-obatan terlarang. Beberapa gejala yang mungkin terjadi termasuk sakit kepala yang bertambah parah dari waktu ke waktu, mual dan muntah, kelemahan atau kelumpuhan pada satu sisi tubuh, kejang, kebingungan, dan kesulitan dalam berbicara atau memahami bahasa.

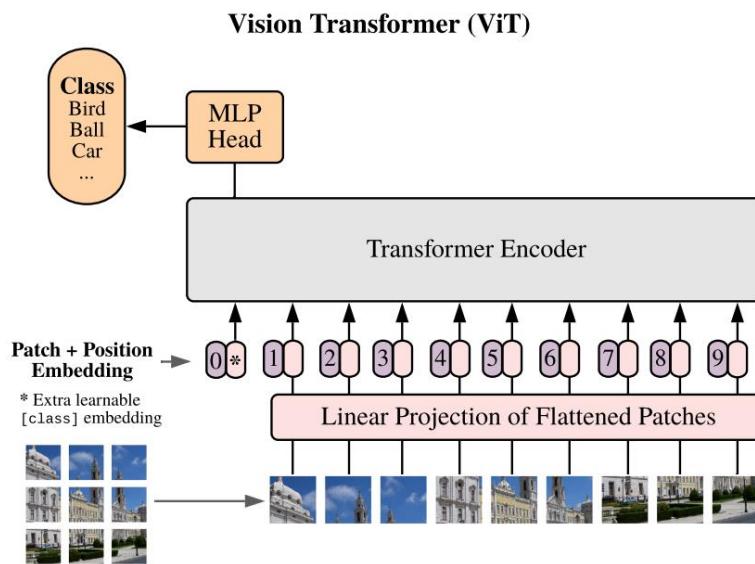
Untuk menentukan perawatan terbaik berdasarkan lokasi, ukuran, dan penyebab ICH terdapat berbagai macam cara dokter atau ahli dalam mendiagnosis yaitu dengan pemeriksaan fisik, metode citra Magnetic Resonance Imaging (MRI), Angiografi atau prosedur di mana agen kontras disuntikkan ke dalam arteri di dekat otak. Pungsi Lumbal atau pengambilan sampel cairan serebrospinal, Elektroensefalogram (EEG)

atau tes yang dapat membantu mengukur aktivitas listrik di otak, dan yang dikembangkan dalam proyek akhir ini yaitu dengan citra CT-Scan.

Computed Tomography Scan atau CT Scan adalah prosedur pemeriksaan yang memanfaatkan teknologi komputer khusus dan sinar-X untuk melihat jaringan dan struktur di dalam tubuh melalui berbagai sudut [1]. CT scan dapat membantu dokter mengidentifikasi tanda-tanda pendarahan otak serta memperkirakan ukuran dan lokasi pendarahan [7].

2.2. VISION TRANSFORMER (ViT)

Metode yang digunakan dalam proyek akhir ini adalah *Vision Transformer* (ViT). Vision Transformer (ViT) adalah sebuah model jaringan saraf tiruan yang diusulkan oleh Alexey Dosovitskiy et al. pada tahun 2020 [3]. Model ini menggunakan transformasi dasar sebagai pengganti konvolusi spasial tradisional pada jaringan saraf konvolusional (CNN) untuk memproses gambar. Vision Transformer menggunakan dasar dari arsitektur Transformer yang sebelumnya merupakan *state-of-the-art* dalam bidang pemrosesan bahasa alami sedangkan sebelum arsitektur ini ada *state-of-the-art* dari vision computer menggunakan Convolutional Neural Network (CNN). Dalam model *training* ViT, gambar masukan dibagi menjadi sejumlah "blok gambar" (misalnya 16 blok gambar), yang masing-masing diubah menjadi vektor fitur. Vektor fitur ini kemudian diproses oleh beberapa lapisan Transformers untuk menghasilkan representasi akhir dari gambar.



Gambar 2.2 Ilustrasi arsitektur vision Transformer

Proses dari ViT berdasarkan ilustrasi di atas diawali dengan sebuah gambar yang ingin di training dibagi menjadi beberapa *patch*. Tiap *patch* kemudian disematkan posisinya secara linear menghasilkan *vector-vector* yang berurutan dan kemudian mengirim tiap *patch* ke pada sebuah transformer standard. Pada ViT tiap *patch* merupakan sesuatu yang dapat dipelajari namun terdiri dari beberapa hal yang ambigu yaitu *vector*. Satu *patch* terdiri dari beberapa *vector* yang nantinya bisa dipelajari oleh komputer untuk proses klasifikasi. Supaya dapat menjalankan proses klasifikasi, maka digunakan pendekatan standard dengan menambah sebuah token ke urutan posisi embedding atau pada ilustrasi di atas yaitu *patch* nomor 0.

1. Patch Embeddings

Syarat data masukan untuk arsitektur Vision Transformer adalah citra tersebut dapat dibagi menjadi *patch* berukuran $n \times n$. *Patch embeddings* adalah proses dimana citra akan dibagi menjadi beberapa *patch* yang kemudian akan dijadikan *vector* satu dimensi berisi nilai piksel citra tersebut. Berikut persamaan rumus perubahan *vector* dua dimensi menjadi satu dimensi pada proses *patch embeddings* [3].

$$X \in \mathbb{R}^{H \times W \times C} \rightarrow X_p \in \mathbb{R}^{N \times W(P^2 \cdot C)} \quad (1)$$

Keterangan:

- | | |
|-------|--------------------------------------|
| X | = Citra masukan |
| X_p | = Citra masukan setelah transformasi |
| H | = Tinggi citra masukan |
| C | = Jumlah channel citra masukan |
| N | = $\frac{HW}{P^2}$ |

2. Layer Normalization

Proses pelatihan arsitektur deep learning pada umumnya meghabisikan sumber daya komputasi yang sangat banyak, sehingga dibutuhkan suatu cara yang dapat mengurangi penggunaan daya dan waktu yang dibutuhkan untuk menyelesaikan proses pelatihan tersebut [10]. Salah satu langkah yang dapat ditempuh adalah *Layer Normalization*. *Layer Normalization* mengurangi penggunaan sumber daya dan waktu pelatihan dengan mengurangi nilai inputan menggunakan rata-rata dan

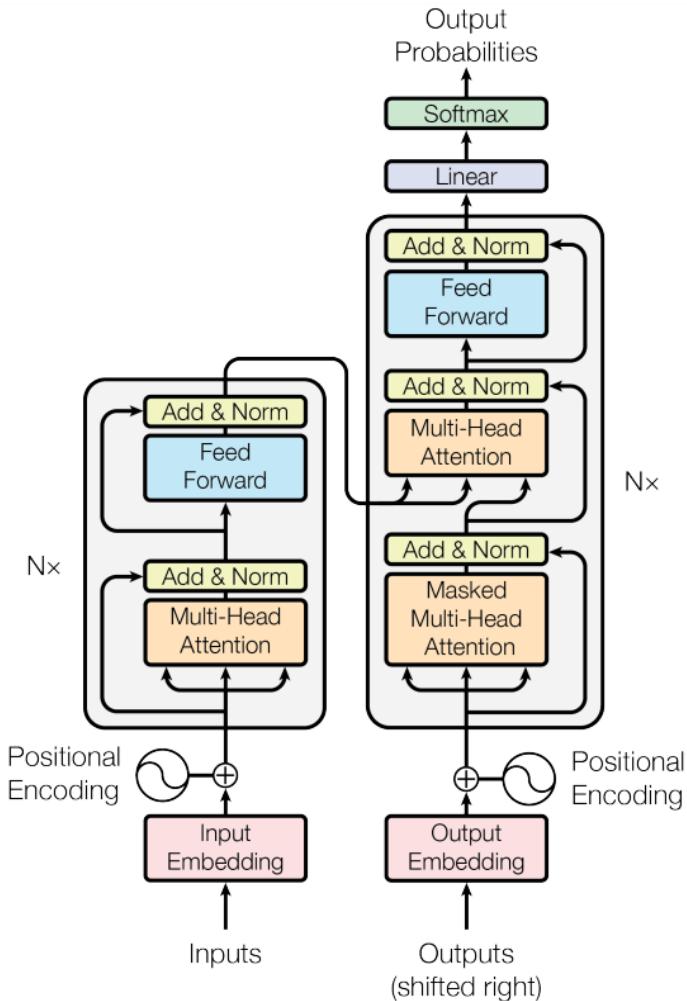
standar deviasi. Semakin nilai inputan mendekati rata-rata dan standar deviasi, maka nilai inputan tersebut akan mendekati 0. Perhitungan *Layer Normalization* ditunjukkan pada persamaan:

$$X'_{i,k} = \frac{X_{i,k} - \mu^i}{\sqrt{\sigma_i^2 + \epsilon}} \quad (2)$$

Keterangan:

- $X_{i,k}$ = Nilai inputan/Vektor
- μ^i = Rata-rata nilai inputan/Vektor
- σ_i^2 = Standar deviasi nilai inputan/Vektor
- ϵ = Denominator

3. Transformer Encoder



Gambar 2.3 *Transformer Encoder-Decoder Model*

Transformer encoder terdiri dari tumpukan dengan $N = 6$ lapisan identik. Ada dua lapisan di tiap sub-lapisan. Yang pertama adalah mekanisme *self-attention multi-head-attention* dan yang kedua adalah jaringan *feedForward* yang sederhana dan terhubung secara posisional. Digunakan ikatan sisa di sekitar tiap dua sub-lapisan diikuti dengan *layer normalization*. Dengan kata lain, hasil dari setiap sub-lapisan adalah :

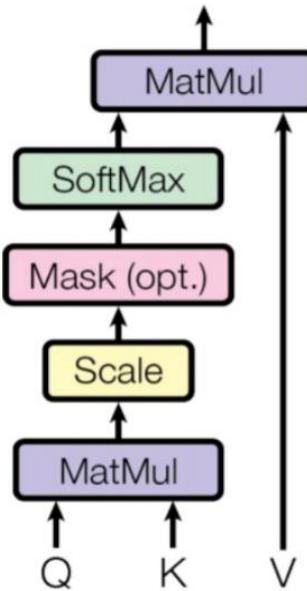
$$\text{LayerNorm}(x \text{ Sublayer}(x)) \quad (3)$$

Keterangan:

Sublayer(x) = Fungsi yang diimplementasikan oleh *sublayer*

Untuk memfasilitasi sambungan yang tersisa ini, semua lapisan bawah model dan juga fiksasi lapisan, memberikan keluaran dengan dimensi $d_{\text{model}} = 512$ [8].

4. Multi-head Attention



Gambar 2.4 Ilustrasi proses *scaled-dot product*

Setelah *Layer Normalization*, *Layer* selanjutnya adalah *Multi Head Attention*.

Di Lapisan ini terjadi proses *attention* yang berfungsi untuk mencari informasi jangka Panjang yang berguna dari vektor masukan. *Multi Head Attention* bekerja dengan cara menduplikasi vector masukan menjadi *query*, *key*, dan *value*. Kemudian *query*, *key*, dan *value* tersebut akan diproses menggunakan *scaled-dot product*. Proses tersebut akan dilakukan sesuai jumlah *head* dan kemudian hasilnya

akan di-*concat* lalu dikompres menjadi ukuran vector yang telah ditentukan. Berikut ilustrasi proses *scaled-dot* product [8].

5. Multi Layer Perceptron

Multi Layer Perceptron (MLP) adalah model jaringan syaraf tiruan yang terinspirasi dari sistem syaraf pada manusia. MLP terbagi menjadi tiga bagian yaitu lapisan masukan, tersembunyi, dan keluaran. MLP memiliki neuron yang memiliki bobot. Di setiap neuron tersebut ada fungsi aktivasi non-linear kecuali pada lapisan masukan [3].

6. Gaussian Error Linear Units

Gaussian Error Linear Units (GELU) merupakan fungsi aktivasi non-linear. GELU Ketika dibandingkan dengan fungsi aktivasi yang lain seperti ReLU dan ELU memiliki peningkatan performa di bidang visi computer, pemrosesan Bahasa alami dan suara (Hendrycks and Gimpel, 2020) GELU banyak digunakan pada arsitektur Transformer. Berikut rumus fungsi aktivasi GELU.

$$0.5x(1 + \tanh[\sqrt{\frac{2}{\pi}}(x + 0.044715x^3)]) \quad (4)$$

7. GradCam

Ketika sebuah arsitektur melakukan propagasi balik, gradien akan menjadi salah satu parameter bagaimana bagaimana penambahan atau pengurangan bobot berdasarkan kontribusi bobot tersebut penting atau tidak. Hal ini membuktikan bahwasanya gradien menyimpan informasi mengenai kondisi dari suatu layer mengenai dimana neuron yang kurang bekerja (Selvaraju et al., 2017) Hal ini dimanfaatkan oleh gradCAM untuk melakukan visualisasi terhadap gradien tersebut.

2.3. PENELITIAN TERKAIT

2.3.1. Penelitian Klasifikasi Intracranial Hemorrhage

Pada penelitian ini menggunakan metode Scopeformer n-CNN-ViT secara *hybrid* untuk mengklasifikasikan Intracranial Hemorrhage (ICH) (Barhoumi and Rasool. 2021). Penelitian ini menggunakan metode Convolutional Neural Networks (CNN) untuk meningkatkan kemampuan dari model Vision Transformer (ViT). Penelitian ini menangani masalah klasifikasi RSNA ICH, yaitu identifikasi tipe-tipe ICH dari potongan-potongan *Computed Tomography* (CT). Penelitian ini

menunjukkan secara bertahap hasil pemetaan fitur yang diekstrasi menggunakan CNN Xception yang kemudian dikembangkan dengan model ViT. Model ViT memperhatikan fitur yang relevan di berbagai tingkatan. Karena pra-training n-CNN menghasilkan fitur yang beragam, maka dari itu untuk meningkatkan kinerja digunakanlah metode *hybrid* n-CNN-ViT. Tingkat akurasi yang dihasilkan mencapai 98.04% dengan *loss value* 0.0708.

Pada penelitian yang lain menjelaskan metode Scopeformer yang efisien terhadap ekstraksi deteksi Intracranial Hemorrhage yang kaya fitur dan berskala (Barhoumi, et al. 2023). Penelitian ini menyajikan model multi-CNN-ViT klasifikasi ICH dalam citra *Computed Tomography* (CT). Arsitektur Scopeformer berskala dan modular dengan fitur output yang beragam dan bermacam strategi *pratrain*. Penelitian ini bertujuan mengurangi redundansi dari fitur yang dihasilkan CNN dan mengontrol input ViT. Penelitian ini mengusulkan versi Scopeformer yang lebih kecil dengan komputasi efisien dengan konfigurasi I/O ViT berbeda. Scopeformer yang efisien menggunakan empat arsitektur *tested* CNN yang berbeda. Model scoperformer efisien ini mencapai akurasi sebesar 96.94% dengan *loss value* 0.083 dengan delapan kali pengurangan jumlah parameter *training* dibandingkan scopeformer dasar.

Pada penelitian yang lain menjelaskan deteksi ICH dengan metode *deep learning* (Majumdar et al. 2018). Penelitian ini menggunakan *Deep Convolutional Neural Network* secara simultan mempelajari berbagai fitur dan klasifikasi, serta mengeliminasi penggunaan beberapa langkah *head-tuned*. Performa yang dihasilkan mengalami peningkatan dengan proses komputasi dari rata-rata *output* dari tiap input gambar. Hasil proses digunakan untuk *output* CNN agar meningkatkan spesifitas. Performa yang dihasilkan adalah 81% sensitivitas per lesi dan 98% per kasus.

| No Ref. | Penelitian | Hasil | Persamaan | Perbedaan |
|---------|---------------------|--|---|--|
| [5] | Barhoumi and Rasool | Penelitian tentang penggunaan metode Scopeformer | Menggunakan metode Vision Tranformer (ViT) dengan | Menggunakan metode ViT dan CNN secara hybrid |

| | | | | |
|------|---|--|--|---|
| | Scopeformer: n-CNN-ViT Hybrid Model for Intracranial Hemorrhage Classification | hybrid n-CNN-ViT untuk mengklasifikasikan penyakit ICH. Metode yang digunakan dalam penelitian ini telah mencapai tingkat akurasi 98,04% dengan nilai loss 0,0708. | dataset gambar CT-Scan Intracranial Hemorrhage (ICH) | dengan teknik Scopformer |
| [6] | Barhoumi, et al. Efficient Scopeformer: Towards Scalable and Rich Feature Extraction for Intracranial Hemorrhage Detection | Studi lain menjelaskan n-CNN-ViT hybrid Scopeformer lebih efisien untuk ekstraksi deteksi ICH yang kaya fitur dan berskala. Penelitian ini telah mencapai tingkat akurasi 96,94% dengan nilai kerugian 0,083 tetapi efisien dengan penggunaan parameter pelatihan 8 kali lebih sedikit dibandingkan dengan metode dasar Scopformer | Menggunakan metode Vision Transformer (ViT) dengan dataset gambar CT-Scan ICH | Menggunakan metode ViT dan CNN secara hybrid dengan teknik Scopformer dengan pengurangan parameter train data |
| [12] | Majumdar, Arjun. et al. Detecting Intracranial Hemorrhage with Deep Learning | Studi lain menggunakan metode Deep Learning untuk deteksi ICH dengan CNN. Proses hasil dari penelitian ini menggunakan output CNN untuk meningkatkan spesivitas dan menghasilkan | Menggunakan dataset gambar CT-Scan ICH. Menggunakan metode deep learning untuk mendeteksi jenis ICH | Menggunakan metode Convolutional Network (CNN) |

| | | | | |
|--|--|---|--|--|
| | | tingkat sensitivitas 81% per lesi dan tingkat sensitivitas 98% per kasus. | | |
|--|--|---|--|--|

Tabel 2.1 Perbandingan Penelitian Terkait Klasifikasi ICH

2.3.2. Perbandingan Penelitian Metode Vision Transformer dengan Metode Deep Learning Lain

| No Ref. | Penelitian | Objek Penelitian | Metode | Hasil |
|---------|--|--|--|--|
| [13] | Xiaohong Gao et al. COVID-VIT: Classification of COVID-19 from CT chest images based on vision transformer models | Klasifikasi COVID-19 dengan Gambar CT dada | Vision Tranformer (ViT) | Membuat hasil prediksi dari deteksi COVID-19 gambar CT dada menggunakan metode Vision Transformer mampu menghasilkan score F1 0.76 pada hasil inisialisasi |
| [14] | Hayden Gunraj et al. (2020) COVIDNet-CT: A Tailored Deep Convolutional Neural Network Design for Detection of COVID-19 Cases From Chest CT Images | Klasifikasi COVID-19 dengan Gambar CT dada | Tailored Deep Convolutional Neural Network (CNN) | Prediksi deteksi COVID-19 gambar CT dada menggunakan metode Deep CNN Mampu menghasilkan tingkat akurasi 99.1% dalam tingkat kompleksitas yang rendah |
| [15] | Ahmet Gokberk Gul et al. Histopathological Image Classification based on Self- | Klasifikasi Gambar Histopathological | Self-Supervised Vision Transformer (ViT) | Penelitian ini menggunakan Self-ViT-MIL untuk klasifikasi Gambar Histopathological. Multiple instance learning (MIL) mengurangi |

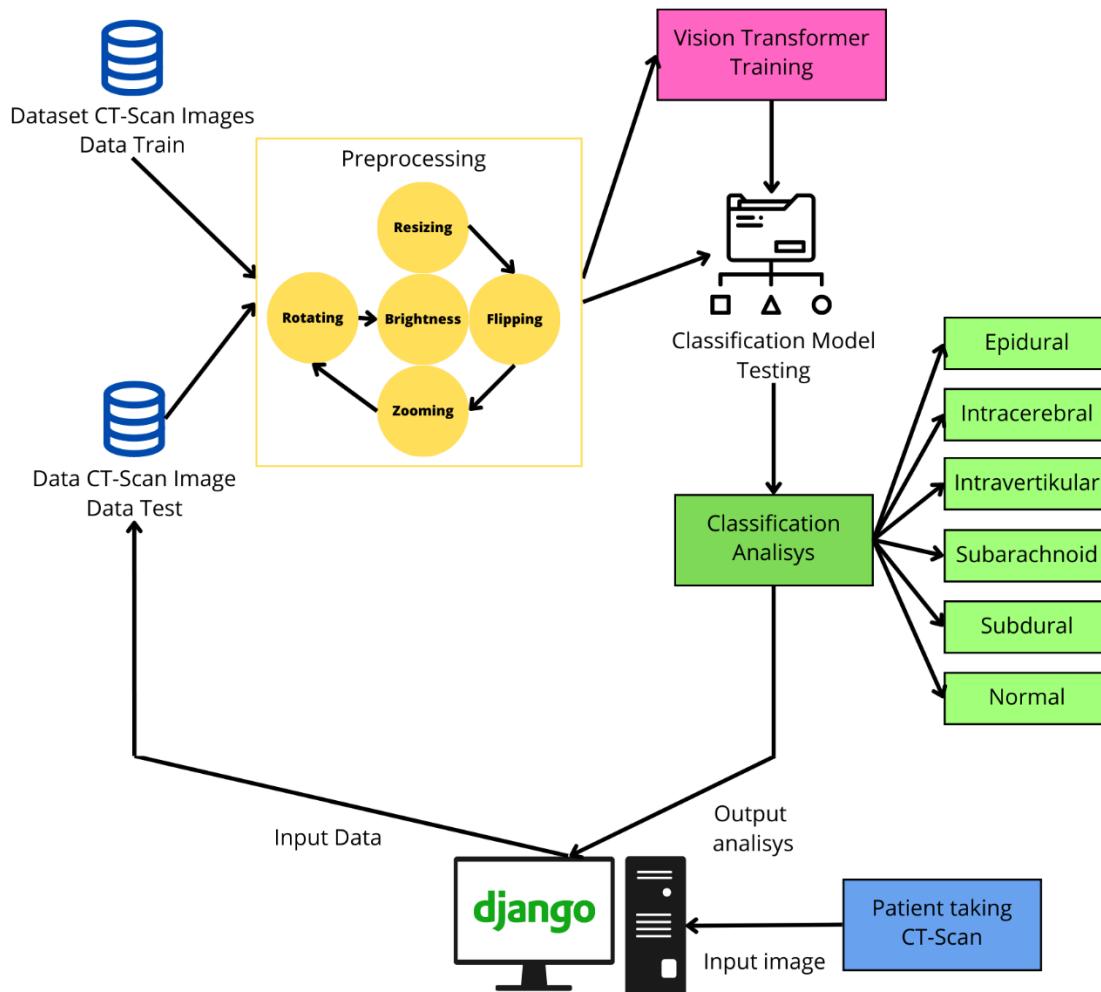
| | | | | |
|------|---|--------------------------------------|--|---|
| | Supervised Vision Transformer and Weak Labels | | | kebutuhan akan anotasi tingkat piksel yang baik. Hasil dari penelitian ini menghasilkan nilai tingkat akurasi sebesar 91,7% |
| [16] | Tiep Vu et al. Histopathological Image Classification using Discriminative Feature-oriented Dictionary Learning | Klasifikasi Gambar Histopathological | Discriminative Feature-oriented Dictionary Learning (DFDL) | Penelitian ini menggunakan DFDL untuk Klasifikasi Gambar Histopathological. DFDL merupakan gabungan Dictionary Learning dan Feature Learning bertujuan untuk menghasilkan kamus fitur yang optimal untuk merepresentasikan data citra. Penelitian ini menghasilkan tingkat akurasi sebesar hampir 90% |
| [17] | Leonardo Tanzi et al. Vision Transformer For Femur Fracture Classification | Klasifikasi Femur Fracture | Vision Transformer (ViT) | Dalam penelitian ini digunakan metode ViT untuk deteksi Femur Fracture. Hasil menunjukkan bahwa penelitian ini menghasilkan score F1 sebesar 0.77. |
| [18] | Amelia Jiménez-Sánchez et al. Curriculum Learning For Improved Femur Fracture Classification: Scheduling Data With Prior Knowledge | Klasifikasi Femur Fracture | Curriculum Learning (CL) | Dalam penelitian ini digunakan metode CL untuk Klasifikasi Femur Fracture. CL bertujuan untuk membantu model mesin mengatasi pembelajaran yang sulit atau kompleks dengan memperkenalkan data secara bertahap. Penelitian ini dibagi |

| | | | | |
|--|--------------------|--|--|---|
| | And Uncertainty | | | menjadi dua output yaitu Prior Knowledge dengan F1 Score tertinggi pada strategi Reorder sebesar 68.93% dan output Uncertainly dengan F1 Score tertinggi pada strategi subsets sebesar 65.51% |
|--|--------------------|--|--|---|

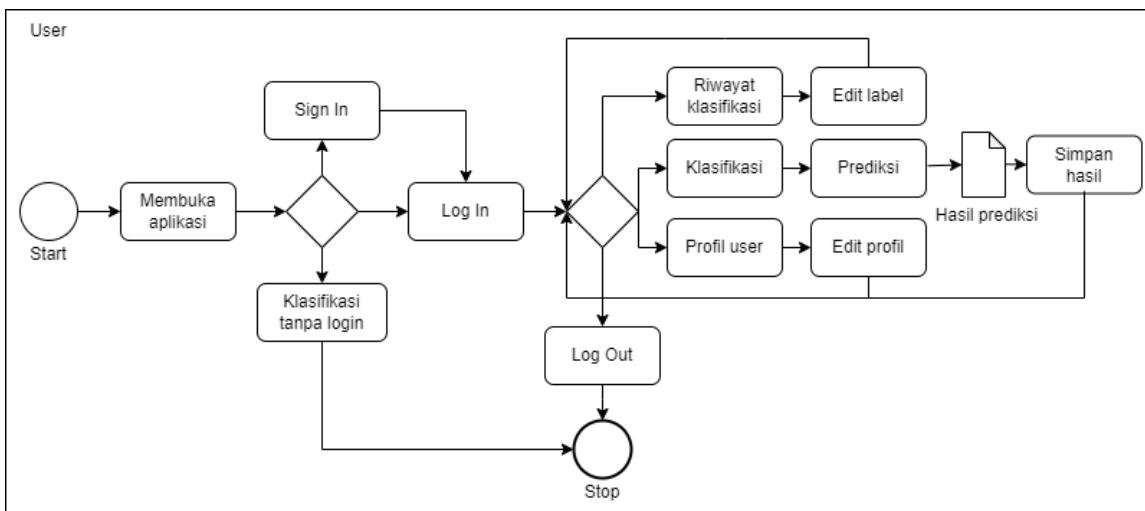
Tabel 2.2 Perbandingan Penelitian ViT dengan Deep Learning Lain

BAB 3

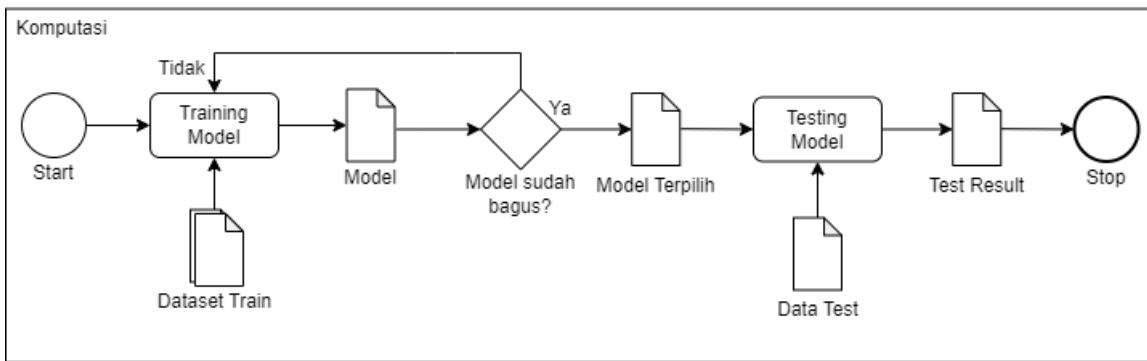
DESAIN SISTEM



Gambar 3.1 Desain Sistem



Gambar 3.2 Diagram Aktivitas User



Gambar 3.3 Diagram Aktivitas Komputasi

3.1. PENJELASAN DESAIN SISTEM

3.1.1. Desain Sistem

Pertama-tama terdapat sebuah dataset CT-Scan *images* sebagai data train. Dilakukan data *preprocessing* yaitu proses dimana sebuah gambar dioptimalkan dari segi ukuran, posisi, kecerahan, pembesaran, dan arah gambar sesuai standard agar proses *learning* lebih optimal. Kemudian hasil *preprocessing* data dilakukan *training* menggunakan metode Vision Transformer yang kemudian menghasilkan model yang akan digunakan untuk proses testing.

Di sisi user, data hasil CT-Scan pasien dimasukkan ke dalam aplikasi web berbasis framework Django sebagai data test dan dilakukan pula *preprocessing* data. Kemudian hasilnya dilakukan proses *testing* yaitu proses klasifikasi antara model data *train* dengan data *test*. Hasil proses klasifikasi menghasilkan analisa klasifikasi yang dapat digunakan untuk menganalisa deteksi ICH. Hasil klasifikasi sendiri terbagi menjadi enam macam yaitu: *Epidural*, *Intracerebral*, *Intravertikular*, *Subarachnoid*, *Subdural*, dan normal. Hasil analisis dikembalikan ke user berupa output sekumpulan data seperti jenis klasifikasi, persentase keakuratan data, dan data-data lain yang sekiranya diperlukan. Semua proses komputasi dijalankan di belakang layar dengan bantuan framework Django yang berbasis python.

3.1.2. Activity Diagram

Pada alur diagram aktivitas proyek ini terbagi menjadi dua sisi yaitu disisi pengguna meliputi dokter, ahli, dan orang-orang yang terkait untuk melakukan proses klasifikasi CT-Scan ICH dan satu sisinya lagi adalah sisi proses komputasi yang terjadi di belakang layar dimana proses klasifikasi berjalan.

Pada sisi pengguna, pertama pengguna membuka aplikasi. Karena aplikasi yang digunakan berbasis web maka dibutuhkan browser untuk membukanya. Kemudian user memasuki halaman landing page dimana user dapat memilih tiga Tindakan yaitu langsung mencoba melakukan proses klasifikasi dan selesai, melakukan *log in* jika memiliki akun, atau melakukan *sign in* jika belum memiliki akun. Setelah melakukan *sign in* akan otomatis dianggap telah melakukan *log in*. Setelah *log in*, pengguna akan masuk ke halaman dashboard Riwayat atau dapat memilih halaman-halaman lain seperti halaman untuk klasifikasi atau halaman profil pengguna serta pengguna juga dapat langsung melakukan *log out*. Pada halaman dashboard riwayat, pengguna dapat melakukan edit data sekaligus melihat detail data. Pada halaman klasifikasi, pengguna dapat melakukan proses prediksi yang kemudian menghasilkan analisa klasifikasi kemudian menyimpannya di dalam *database*. Pada halaman profil pengguna, pengguna dapat melihat sekaligus mengedit data profil pengguna. Setelah *log in* pengguna juga dapat langsung *log out*. Setelah *log out* maka aktivitas pengguna dalam menggunakan aplikasi akan berhenti.

Pada sisi komputasi, pertama dataset ICH akan dijadikan sebagai data train. Kemudian dilakukan proses training data train yang kemudian menghasilkan model. Model kemudian diperiksa apakah sudah dianggap layak atau tidak dengan membandingkan tingkat keakuratan model baru dengan model yang sudah ada sebelumnya sehingga proses ini minimal terjadi dua kali. Jika dianggap sudah layak maka model tersebut dipilih yang selanjutnya digunakan untuk proses testing dengan data test yang sudah disiapkan. Proses testing menghasilkan data yang nantinya dipakai oleh pengguna untuk mendapatkan hasil analisa. Setelah data hasil analisa dikembalikan ke pengguna maka proses aktivitas komputasi sudah selesai.

3.1.3. Sumber Data

| PatientNumber | SliceNumber | Intraparenchymal | Subarachnoid | Epidural | Subdural | No_Hemo_Fracture_Yes_No |
|---------------|-------------|------------------|--------------|----------|----------|-------------------------|
| 2 | 49 | 1 | 0 | 0 | 0 | 1 |
| 3 | 49 | 2 | 0 | 0 | 0 | 1 |
| 4 | 49 | 3 | 0 | 0 | 0 | 1 |
| 5 | 49 | 4 | 0 | 0 | 0 | 1 |
| 6 | 49 | 5 | 0 | 0 | 0 | 1 |
| 7 | 49 | 6 | 0 | 0 | 0 | 1 |
| 8 | 49 | 7 | 0 | 0 | 0 | 1 |
| 9 | 49 | 8 | 0 | 0 | 0 | 1 |
| 10 | 49 | 9 | 0 | 0 | 0 | 1 |
| 11 | 49 | 10 | 0 | 0 | 0 | 1 |
| 12 | 49 | 11 | 0 | 0 | 0 | 1 |
| 13 | 49 | 12 | 0 | 0 | 0 | 1 |
| 14 | 49 | 13 | 0 | 0 | 0 | 1 |
| 15 | 49 | 14 | 0 | 0 | 0 | 1 |
| 16 | 49 | 15 | 0 | 0 | 0 | 1 |
| 17 | 49 | 16 | 0 | 0 | 0 | 1 |
| 18 | 49 | 17 | 0 | 0 | 0 | 1 |
| 19 | 49 | 18 | 0 | 0 | 0 | 1 |
| 20 | 49 | 19 | 0 | 0 | 0 | 1 |
| 21 | 49 | 20 | 0 | 0 | 0 | 1 |
| 22 | 49 | 21 | 0 | 1 | 0 | 0 |
| 23 | 49 | 22 | 0 | 0 | 0 | 1 |
| 24 | 49 | 23 | 0 | 0 | 0 | 1 |
| 25 | 49 | 24 | 0 | 0 | 0 | 1 |
| 26 | 49 | 25 | 0 | 0 | 0 | 1 |

Gambar 3.4 Label dataset .csv

Pada Proyek Akhir ini digunakan dataset gambar CT-Scan ICH *open source* yang diambil dari pengguna di situs kaggle.com dengan nama pengguna vbookshelf dengan judul dataset *Brain CT Images with Intracranial Hemorrhage Masks* yang bisa diakses pada <https://www.kaggle.com/datasets/vbookshelf/computed-tomography-ct-images>. Pada dataset ini mengandung gambar CT-Scan otak dan tempurung tulang kepala. Terdapat kurang lebih 2500 gambar CT-Scan otak dan kurang lebih 2500 gambar CT-Scan tempurung tulang kepala dari 82 pasien yang berbeda dengan tiap pasiennya memiliki kurang lebih 30 potongan gambar CT-Scan otak maupun tempurung tulang kepala. Pada dataset ini juga sudah termasuk file .csv berisi label klasifikasi ICH tiap gambar. Namun dataset yang digunakan pada Proyek Akhir ini hanya gambar CT-Scan otak saja.

3.2. UJI COBA PRODUK

3.2.1. Desain Uji Coba

Uji coba produk aplikasi deteksi Intracranial Hemorrhage (ICH) dengan Vision Transformer (ViT) dilakukan untuk mengukur kualitas dari produk yang dihasilkan dari proyek akhir ini. Uji coba yang dilakukan mencakup tingkat keakuratan efisiensi metode yang digunakan dalam produk ini. Subjek yang dituju adalah ahli atau dokter dan tenaga Kesehatan umum.

3.2.2. Subjek Uji Coba

3.2.2.1. Subjek Ahli atau Dokter

Dalam proyek akhir ini subyek ahli dan dokter adalah kalangan pengguna produk yang memiliki pengetahuan dalam analisa gambar CT-Scan ICH secara manual tanpa menggunakan alat bantu. Subyek ini dapat memberi label sendiri kepada gambar CT-Scan ICH yang diuji.

3.2.2.2. Subyek Tenaga Kesehatan Umum

Subyek tenaga Kesehatan umum merupakan kalangan pengguna produk yang tidak memiliki pengetahuan dalam analisa gambar CT-Scan ICH namun masih berkontribusi dalam proses penyembuhan pasien. Subyek ini tidak memberi label sendiri kepada gambar CT-Scan yang diuji.

3.2.3. Jenis Data Uji Coba

Pada proyek akhir ini jenis data uji coba dibagi menjadi dua yaitu jenis data kuantitatif dan kualitatif. Jeni data kuantitatif bertuju pada seberapa banyak pengguna subyek ahli atau dokter dan tenaga kesehatan umum yang menggunakan produk beserta tingkat urgensinya. Jenis data kuantitatif mengacu pada tingkat akurasi dan efisiensi dari hasil deteksi gambar CT-Scan ICH dari produk proyek akhir ini dan perbandingan antara hasil deteksi dari produk dengan hasil pemberian label secara mandiri oleh ahli atau dokter.

3.3. EVALUATION METRICS

3.3.1. Intracranial Hemorrhage

Salah satu evaluation metrics yang dapat digunakan dalam Klasifikasi Intracranial Hemorrhage adalah Weighted Multi-Label Logarithmic Loss [19]. Teknik ini adalah evaluation metrics yang digunakan dalam tugas klasifikasi multi-label. Evaluation metrics ini mengukur perbedaan antara probabilitas prediksi model dengan label yang sebenarnya.

$$L = -1/N * \sum[\sum[w_i * (y_{ij} * \log(p_{ij}) + (1 - y_{ij}) * \log(1 - p_{ij}))]] \quad (5)$$

Keterangan:

L = Weighted Multi-Label Logarithmic Loss

N = Total sampel data dalam dataset

w_i = Bobot label ke-i.

y_{ij} = Label biner label ke-i ada atau tidak dalam sampel data ke-j

p_{ij} = Probabilitas label ke-i dalam sampel data ke-j

3.3.2. Vision Transformer

Terdapat dua evaluation metrics yang paling umum digunakan dalam penelitian-penelitian Vision Transformer (ViT) yaitu F1-Score dan Accuracy Score.

- F1-Skor

F1-Skor adalah salah satu evaluation metrics yang menggabungkan presisi (precision) dan recall. F1-Skor memberikan nilai yang mencerminkan keseimbangan antara presisi dan recall dalam sebuah model klasifikasi. Berikut formula perhitungan F1-Skor:

$$\text{Presisi} = TP / (TP + FP) \quad (5)$$

$$\text{Recall} = TP / (TP + FN) \quad (6)$$

$$F1\text{-Skor} = 2 * (\text{Presisi} * \text{Recall}) / (\text{Presisi} + \text{Recall}) \quad (7)$$

Keterangan:

TP = jumlah prediksi benar positif.

FP = jumlah prediksi salah positif.

FN = jumlah kasus positif yang tidak terdeteksi oleh model.

- Accuracy

Accuracy adalah evaluation metrics yang digunakan untuk mengukur sejauh mana model klasifikasi dapat memprediksi dengan benar. Accuracy memberikan gambaran umum tentang seberapa baik model dapat melakukan prediksi yang benar secara keseluruhan. Berikut formula perhitungan Accuracy:

$$\text{Accuracy} = (TP + TN) / (TP + TN + FP + FN) \quad (8)$$

Keterangan:

TP = jumlah prediksi benar positif.

TN = jumlah prediksi benar negatif.

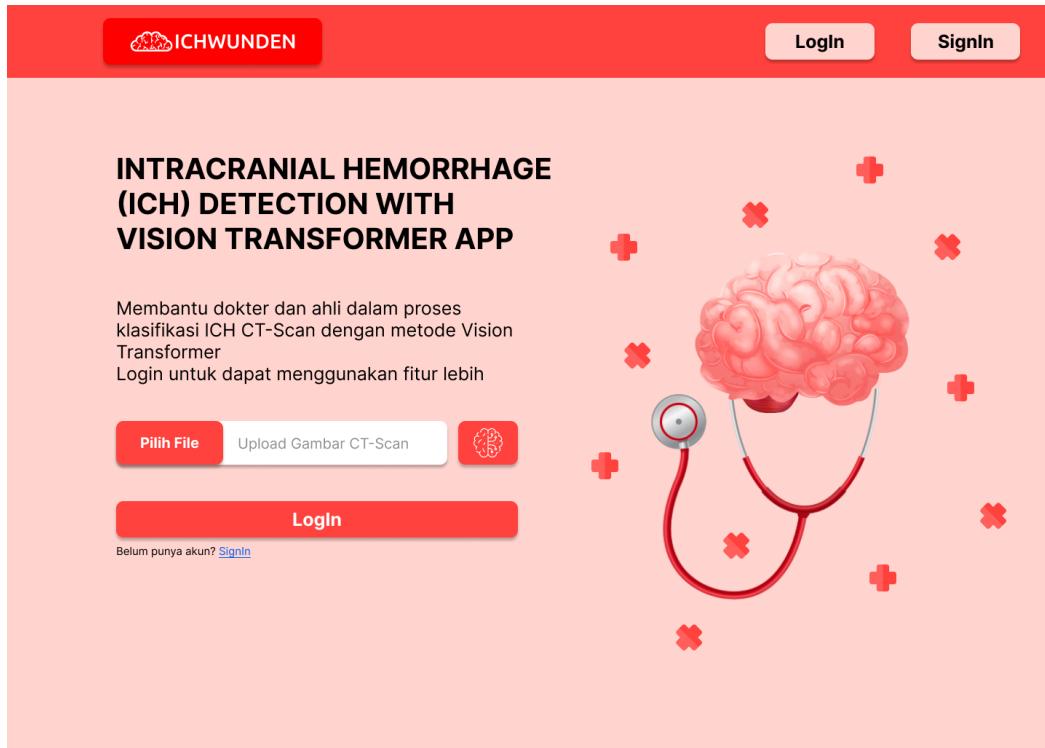
FP = jumlah prediksi salah positif.

FN = jumlah kasus positif yang tidak terdeteksi oleh model.

Dari kedua Evaluation Metrics di atas, akan diuji mana Evaluation Metrics yang lebih baik dengan membandingkannya dengan penelitian-penelitian terkait tentang penggunaan metode ViT.

3.4. TAMPILAN ANTAR MUKA

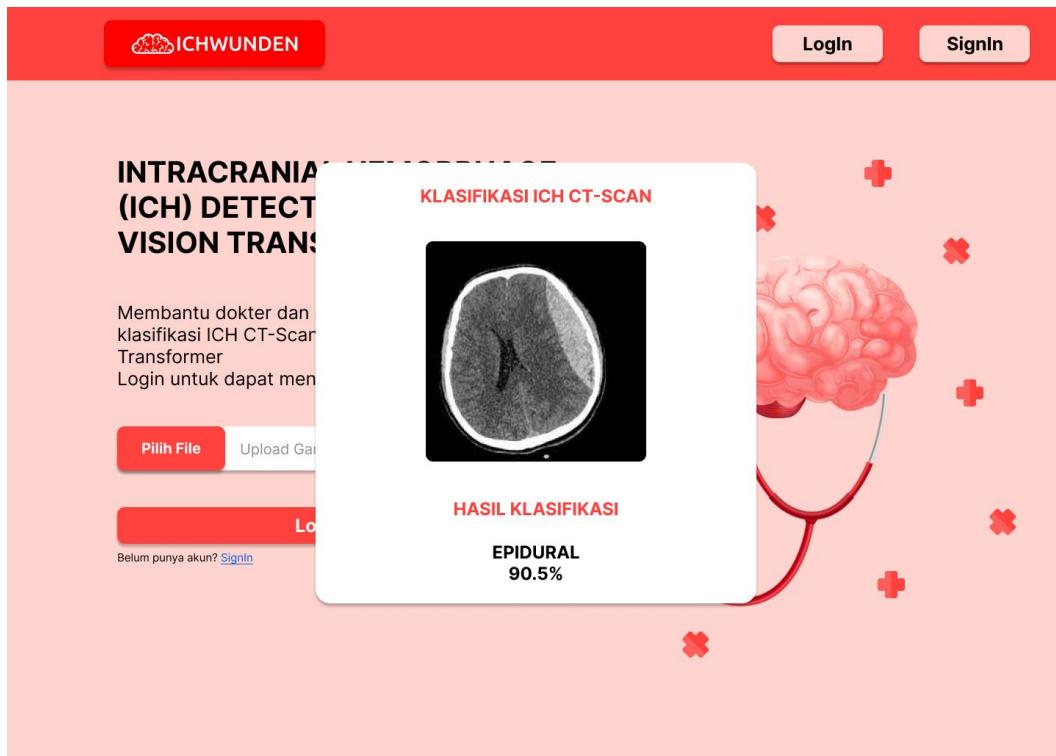
3.4.1. Landing Page



Gambar 3.2.1 UI Landing Page

Berikut halaman yang pertama kali muncul Ketika pengguna membuka aplikasi. Halaman ini berisi judul aplikasi, tombol *log in* dan *sign in*, deskripsi singkat aplikasi, dan terdapat satu form input untuk gambar CT-Scan ICH yang dapat digunakan langsung oleh pengguna untuk deteksi klasifikasi ICH dengan CT-Scan tanpa melalui *log in* kedalam aplikasi.

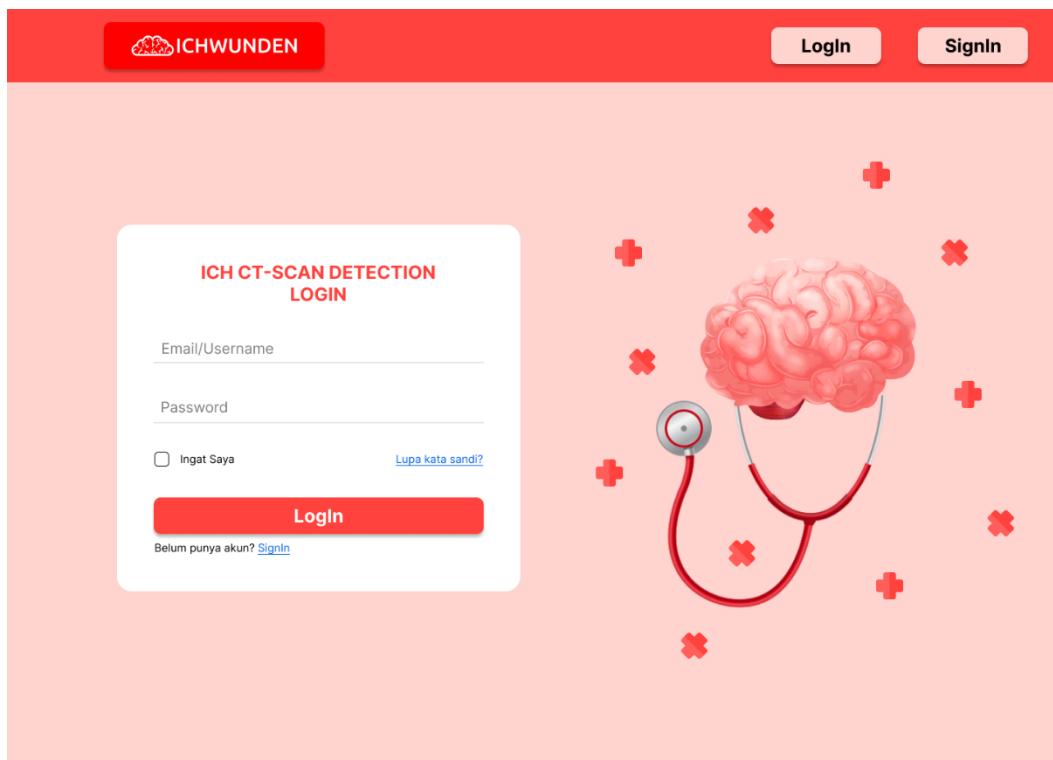
3.4.2. Landing Page Klasifikasi



Gambar 3.2.2 UI Landing Page dengan Klasifikasi

Setelah pengguna memasukkan file gambar CT-Scan ICH kemudian menekan tombol proses dengan logo otak maka aplikasi akan memproses di latar belakang dan kemudian mengembalikan data-data informasi analisa hasil deteksi yang ditampilkan seperti di gambar.

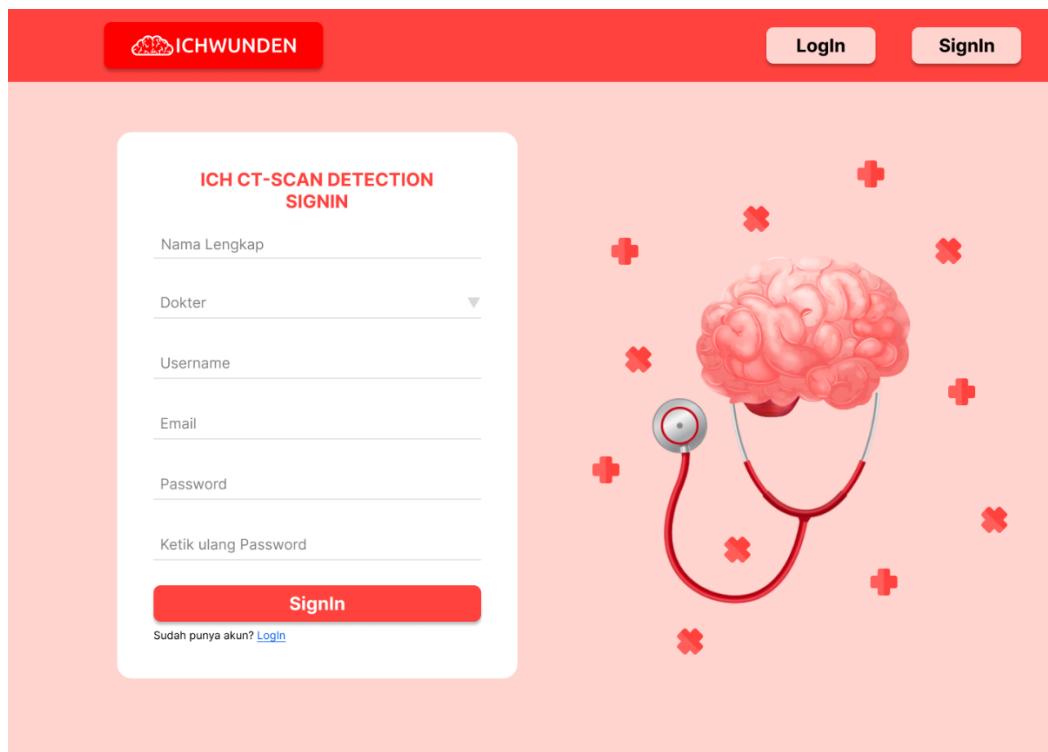
3.4.3. Login Page



Gambar 3.2.3 UI Log In Page

Pada halaman ini pengguna memasukkan data kriteria untuk melakukan proses *log in* ke dalam aplikasi. Setalah berhasil *log in* pengguna akan diarahkan langsung ke halaman dashboard riwayat.

3.4.4. Signin Page



Gambar 3.2.4 UI Sign In Page

Pada halaman ini pengguna memasukkan data-data yang dibutuhkan untuk digunakan pada proses *sign in*. Setelah itu pengguna meng-*submit* data form dan otomatis *log in* kemudian diarahkan ke halaman dashboard riwayat.

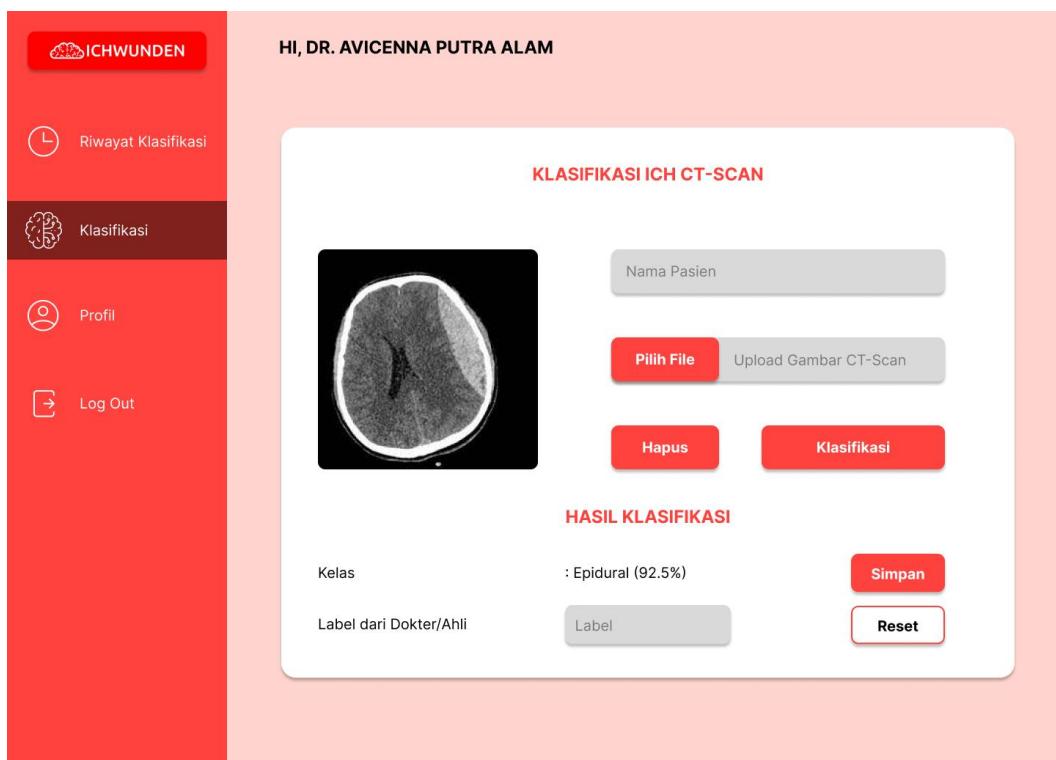
3.4.5. Dashboard Riwayat

| No | Tanggal | Nama Pasien | Gambar CT-Scan | Klasifikasi | Label | Nama Dokter/Ahli | Aksi |
|----|------------|-------------------|----------------|-------------|----------|-------------------------|-----------------------------------|
| 1 | 14/05/2023 | Joko Prasetyo | | Epidural | Subdural | Dr. Avicenna Putra Alam | |
| 2 | 11/05/2023 | Sri Wahyu Yuliani | | Subdural | Epidural | Dr. Ahmad Ilham Yanuar | |
| 3 | 10/05/2023 | Putra Pamungkas | | Normal | Normal | Dr. Anisa Putri Cantika | |

Gambar 3.2.5 UI Dashboard Riwayat

Pada halaman ini terdapat navbar untuk navigasi halaman, pengguna dapat melihat daftar riwayat semua pasien yang pernah dianalisa dengan aplikasi ini. Pengguna dapat melihat detail tiap data pasien dan mengeditnya dengan menekan tombol pensil (edit). Fitur hapus data hanya dapat diakses oleh pengguna admin. Pengguna juga dapat mencari data pasien dengan mengetik nama pasien yang dicari.

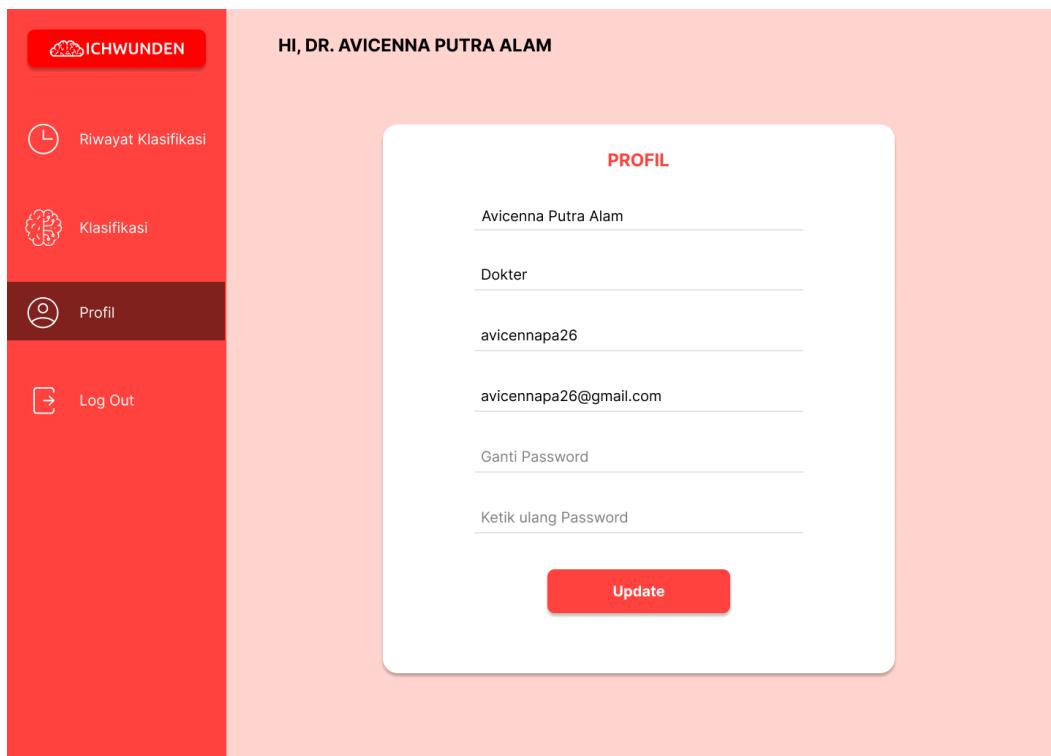
3.4.6. Dashboard Klasifikasi



Gambar 3.2.6 UI Dashboard Klasifikasi

Pada halaman ini, pengguna dapat melakukan analisa deteksi ICH dengan memasukkan nama pasien, kemudian memasukkan gambar CT-Scan ICH yang ingin di analisa kemudian submit untuk memunculkan hasil klasifikasi. Setelah submit akan muncul hasil klasifikasi beserta tingkat keakuratannya. Pengguna juga dapat memberi label klasifikasi sendiri. Setelah selesai menginput form, pengguna dapat menyimpan data.

3.4.7. Dashboard Profil



Gambar 3.2.7 UI Profile Page

Pada halaman ini, pengguna dapat melihat informasi profilnya. Pengguna juga dapat mengedit informasi profil.

3.5. JADWAL PENGERJAAN PA

| No | Nama kegiatan | Bulan | | | | | | | | | | | |
|----|---|-------|---|---|---|---|---|---|---|---|----|----|----|
| | | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 |
| 1 | Desain Sistem | X | X | X | X | | | | | | | | |
| 2 | Pengumpulan Data dan Preprocessing | | | X | X | X | | | | | | | |
| 3 | Penggunaan ViT dengan Optimasi pada Proses Pelatihan dan Evaluasi | | | | X | X | X | | | | | | |
| 4 | Pengembangan Perangkat Lunak | | | | X | X | X | X | X | X | X | | |
| 5 | Uji Coba dan Evaluasi Perangkat Lunak | | | | | | | | X | X | X | | |

| | | | | | | | | | | | | |
|---|--------------------------------|--|--|--|--|--|--|--|--|---|---|---|
| 6 | Penulisan Laporan Proyek Akhir | | | | | | | | | X | X | X |
|---|--------------------------------|--|--|--|--|--|--|--|--|---|---|---|

DAFTAR PUSTAKA

- [1]. <https://www.siloamhospitals.com/informasi-siloam/artikel/apa-itu-ct-scan>
- [2]. <https://my.clevelandclinic.org/health/diseases/14480-brain-bleed-hemorrhage-intracranial-hemorrhage>
- [3]. Alexey Dosovitskiy, Lucas Beyer, Alexander Kolesnikov, Dirk Weissenborn, Xiaohua Zhai, Thomas Unterthiner, Mostafa Dehghani, Matthias Minderer, Georg Heigold, Sylvain Gelly, Jakob Uszkoreit, Neil Houlsby *An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale*. 2021. arXiv:2010.11929.
- [4]. Ramprasaath R. Selvaraju, Michael Cogswell, Abhishek Das, Ramakrishna Vedantam, Devi Parikh, Dhruv Batra *Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization*. 2019. arXiv:1610.02391.
- [5]. Yassine Barhoumi, Ghulam Rasool *Scopeformer: n-CNN-ViT Hybrid Model for Intracranial Hemorrhage Classification*. 2021. arXiv:2107.04575.
- [6]. Yassine Barhoumi, Nidhal C. Bouaynaya, Ghulam Rasool *Efficient Scopeformer: Towards Scalable and Rich Feature Extraction for Intracranial Hemorrhage Detection*. 2023. arXiv:2302.00220.
- [7]. Chelsea S. Kidwell et al. *Comparison of MRI and CT for detection of acute intracerebral hemorrhage*. 2017. DOI:10.1001/jama.292.15.1823.
- [8]. Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Łukasz Kaiser, Illia Polosukhin. *Attention Is All You Need*. 2017. arXiv:1706.03762.
- [9]. Dan Hendrycks, Kevin Gimpel. *Gaussian Error Linear Units (GELUs)*. 2016. arXiv:1606.08415.
- [10]. Jimmy Lei Ba, Jamie Ryan Kiros, and Geoffrey E Hinton. Layer normalization. arXiv preprint. arXiv:1607.06450, 2016.
- [11]. Stéphane Cuenat et al. Convolutional Neural Network (CNN) vs Vision Transformer (ViT) for Digital Holography. 2021. arXiv:2108.09147.
- [12]. Majumdar, Arjun. et al. *Detecting Intracranial Hemorrhage with Deep Learning*. 2018. USA: MIT Lincoln Laboratory. DOI: 10.1109/EMBC.2018.8512336

- [13]. Xiaohong Gao, Yu Qian, Alice Gao. COVID-VIT: Classification of COVID-19 From CT Chest Images Based On Vision Transformer Models. 2021. arXiv:2107.01682
- [14]. Hayden Gunraj, Linda Wang, Alexander Wong. COVIDNet-CT: A Tailored Deep Convolutional Neural Network Design for Detection of COVID-19 Cases From Chest CT Images. 2020. doi: 10.3389/fmed.2020.608525
- [15]. Ahmet Gokberk Gul, Oezdemir Cetin, Christoph Reich, Tim Prangemeier, Nadine Flinner, Heinz Koeppl. Histopathological Image Classification based on Self-Supervised Vision Transformer and Weak Labels. 2022. arXiv:2210.09021
- [16]. Tiep Huu Vu, Hojjat Seyed Mousavi, Vishal Monga, Arvind UK Rao, Ganesh Rao. Histopathological Image Classification using Discriminative Feature-oriented Dictionary Learning. 2016. arXiv:1506.05032
- [17]. Leonardo Tanzi, Andrea Audisio, Giansalvo Cirrincione, Alessandro Aprato, Enrico Vezzetti. Vision Transformer For Femur Fracture Classification. 2021. arXiv:2108.03414
- [18]. Amelia Jiménez-Sánchez, Diana Mateus, Sonja Kirchhoff, Chlodwig Kirchhoff, Peter Biberthaler, Nassir Navab, Miguel A. González Ballester, Gemma Piella. Curriculum Learning For Improved Femur Fracture Classification: Scheduling Data With Prior Knowledge And Uncertainty. 2021. arXiv:2007.16102
- [19]. <https://www.kaggle.com/competitions/rsna-intracranial-hemorrhage-detection/overview/evaluation>