

KLASIFIKASI TEKS WEBSITE ILEGAL BERBASIS TRANSFER LEARNING INDOBERT UNTUK MEMINIMALISIR MARAKNYA PENGGUNAAN WEBSITE ILEGAL DI INDONESIA

Sitti Aulia Sabina Rahmannissa¹, I Gde Agung Sri Sidhimantra²
Program Studi Manajemen Informatika, Universitas Negeri Surabaya
Jl. Ketintang, Ketintang, Kec. Gayungan, Surabaya, Jawa Timur 60231
¹sitti.20016@mhs.unesa.ac.id
²igdesidhimantra@unesa.ac.id

Abstrak - Maraknya akses terhadap situs ilegal di Indonesia, seperti platform judi daring, layanan streaming film tanpa lisensi, dan siaran olahraga tidak resmi, menunjukkan lemahnya mekanisme kontrol manual dalam proses identifikasi dan pemblokiran konten digital berbahaya. Penelitian ini mengembangkan sistem klasifikasi website ilegal menggunakan pendekatan Transfer Learning berbasis model pra-latih IndoBERT. Model ini digunakan untuk mengklasifikasikan konten atau deskripsi website ke dalam dua kategori, yaitu Legal dan Ilegal. Tahapan pengembangan meliputi pengumpulan data, pra-pemrosesan, pelatihan model, serta evaluasi menggunakan Confusion Matrix. Sistem diimplementasikan dalam bentuk aplikasi web interaktif menggunakan framework Flask dan dikembangkan dengan bahasa pemrograman Python berbasis Object-Oriented Programming guna menghasilkan struktur kode yang terorganisasi dan skalabel. Penelitian ini diharapkan mampu menjadi solusi awal dalam mendeteksi situs ilegal secara otomatis, sekaligus berkontribusi pada upaya perlindungan masyarakat dari dampak negatif konten digital ilegal melalui penerapan kecerdasan buatan.

Kata kunci: Flask, IndoBERT, Klasifikasi Teks, Transfer Learning, Website Ilegal

Abstract - The increasing prevalence of illegal websites in Indonesia, encompassing unauthorized gambling platforms, unlicensed movie and sports streaming services, and data-compromising sites, highlights the inadequacy of manual monitoring mechanisms in identifying and restricting harmful digital content. This study develops an automated illegal website classification system by applying Transfer Learning through the pre-trained IndoBERT model. The model processes website content and descriptions, categorizing them into two distinct classes: Legal and Illegal. The development pipeline encompasses dataset collection, preprocessing, model training, and performance evaluation utilizing a Confusion Matrix. The resulting system is deployed as an interactive web application built on the Flask framework and structured using Python with an Object-Oriented Programming paradigm to ensure maintainable and scalable code architecture. By harnessing Artificial Intelligence capabilities, this research addresses the shortcomings of conventional manual detection approaches and is anticipated to function as a

foundational solution for automated illegal website identification, ultimately contributing to broader digital content governance and public protection efforts.

Kata kunci: Flask, IndoBERT, Clasification Text, Transfer Learning, Illegal Website.

I. PENDAHULUAN

Perkembangan teknologi digital yang berlangsung secara masif dalam beberapa dekade terakhir telah mengubah pola aktivitas manusia secara fundamental, khususnya dalam pemanfaatan platform berbasis internet. Pertumbuhan penggunaan website dan aplikasi digital yang pesat tidak hanya membawa kemudahan, tetapi juga memunculkan permasalahan serius berupa merebaknya konten digital ilegal yang beroperasi tanpa pengawasan memadai. Kondisi ini berpotensi mengancam privasi pengguna, keamanan data, serta nilai-nilai moral dan budaya masyarakat.

Salah satu cabang ilmu yang berkembang pesat dan relevan dalam menangani permasalahan tersebut adalah Kecerdasan Buatan atau Artificial Intelligence (AI). Sebagai bagian dari ilmu komputer, AI difokuskan pada pengembangan sistem yang mampu menjalankan tugas-tugas kompleks secara logis dan efisien, mencakup pengenalan pola, pemrosesan bahasa alami, pengambilan keputusan berbasis data, serta pembelajaran mesin. Dalam konteks ini, pendekatan Machine Learning, khususnya metode Transfer Learning, menjadi solusi yang relevan karena memungkinkan pemanfaatan pengetahuan dari model yang telah dilatih sebelumnya untuk diterapkan pada domain permasalahan baru secara lebih efektif dan efisien.

Indonesia saat ini menghadapi tantangan serius terkait proliferasi website ilegal, meliputi platform perjudian daring, layanan streaming konten bajakan, serta berbagai situs yang tidak sesuai dengan regulasi penggunaan internet yang berlaku. Keberadaan situs-situs tersebut tidak hanya melanggar ketentuan hukum, tetapi juga membahayakan pengguna

melalui risiko kebocoran data pribadi, penyebaran malware, pelacakan aktivitas pengguna secara ilegal, hingga penipuan daring. Meskipun pemerintah melalui penyedia layanan internet (Internet Service Provider/ISP) telah melakukan upaya pemblokiran, efektivitasnya masih terbatas mengingat situs-situs ilegal tersebut kerap bermunculan kembali dengan domain dan alamat baru dalam waktu singkat.

Permasalahan mendasar yang melatarbelakangi penelitian ini adalah ketiadaan sistem otomatis berbasis AI yang mampu mengidentifikasi dan mengklasifikasikan website ilegal secara cepat dan akurat. Proses identifikasi yang selama ini dilakukan secara manual, melalui mekanisme pelaporan publik, terbukti tidak efisien dari sisi waktu dan cakupan, serta tidak mampu mengikuti dinamika pergerakan situs ilegal yang terus berubah. Oleh karena itu, diperlukan pendekatan berbasis kecerdasan buatan yang mampu memproses data dalam skala besar dan menghasilkan klasifikasi secara otomatis sebagai respons terhadap ancaman siber yang bersifat dinamis.

Penelitian ini mengembangkan Sistem Klasifikasi Website Ilegal menggunakan metode Transfer Learning dengan memanfaatkan model pra-latih IndoBERT. IndoBERT merupakan model Natural Language Processing (NLP) yang dilatih secara khusus pada korpus berbahasa Indonesia, sehingga memiliki kemampuan memahami konteks teks berbahasa Indonesia secara lebih akurat dan relevan dibandingkan model berbahasa umum. Dengan pendekatan ini, sistem yang dikembangkan mampu menganalisis konten maupun deskripsi suatu website dan menentukan apakah situs tersebut tergolong dalam kategori Legal atau Ilegal secara otomatis.

Secara praktis, sistem ini diharapkan dapat dimanfaatkan oleh berbagai pemangku kepentingan, termasuk instansi pemerintah seperti Kementerian Komunikasi dan Informatika (Kominfo), ISP, serta organisasi yang bergerak di bidang literasi digital dan keamanan siber. Secara teknis, sistem dikembangkan menggunakan bahasa pemrograman Python dengan paradigma Object-Oriented Programming (OOP) dan framework Flask sebagai back-end, guna mendukung interaksi antarmuka secara real-time serta menghasilkan sistem yang mudah digunakan, dipelihara, dan dikembangkan lebih lanjut.

Dengan demikian, penelitian ini diharapkan menjadi langkah awal yang signifikan dalam penanggulangan website ilegal berbasis AI di Indonesia, sekaligus menjadi fondasi bagi pengembangan sistem keamanan digital yang lebih canggih, adaptif, dan responsif terhadap dinamika kejahatan siber di masa mendatang.

II. TINJAUAN PUSTAKA

A. Machine Learning

Penggunaan kecerdasan buatan (Artificial Intelligence/AI) terus menunjukkan peningkatan yang signifikan seiring perkembangan zaman. Dalam ekosistem AI yang luas, machine learning hadir sebagai salah satu metode spesifik yang menjadi fondasi utama berbagai sistem cerdas modern [1]. Keterkaitan antara AI, machine learning, dan deep

learning membentuk hierarki yang saling melengkapi, di mana setiap lapisan memperluas kemampuan lapisan sebelumnya. Dalam ranah kecerdasan buatan, data memegang peranan yang sangat krusial. Berbagai modalitas data mulai dari suara, teks, hingga hasil klasifikasi dan generasi teks menjadi bahan bakar utama yang menggerakkan sistem AI [2]. Data masukan yang telah diproses secara sistematis akan menghasilkan keluaran berupa prediksi maupun solusi terhadap permasalahan tertentu. Pada praktik pemrosesan data untuk sistem kecerdasan buatan, terdapat dua paradigma pendekatan yang lazim digunakan:

Pertama, pendekatan berbasis model, yang menitikberatkan pada peningkatan performa model machine learning melalui pemilihan arsitektur yang tepat serta merancang alur pembelajaran yang efisien dan optimal.

Kedua, pendekatan berbasis data, yang berfokus pada modifikasi dan penyempurnaan kumpulan data sebagai upaya untuk meningkatkan ketepatan dan akurasi keputusan yang dihasilkan oleh sistem [3].

Machine learning pada dasarnya adalah proses pembangunan model komputasi yang memiliki kemampuan untuk belajar secara mandiri serta menghasilkan prediksi atau keputusan berdasarkan data yang telah diproses dan divalidasi sebelumnya. Merujuk pada gagasan yang dikemukakan Arthur Samuel pada tahun 1959, pembelajaran mesin dapat dikategorikan ke dalam dua tipe utama, yakni pembelajaran terbimbing (supervised learning) dan pembelajaran tak terbimbing (unsupervised learning) [4]. Dalam membangun arsitektur sistem machine learning, jaringan saraf tiruan (neural network) berperan penting sebagai infrastruktur utama yang bertanggung jawab dalam memproses serta meneruskan informasi antar lapisan komputasi.

B. Transformer MLN

Arsitektur transformer pertama kali diperkenalkan melalui karya ilmiah berjudul "Attention is All You Need" [5], yang kemudian menjadi tonggak penting dalam perkembangan kecerdasan buatan modern. Model transformer berbasis MLN ini menjadi landasan arsitektural bagi berbagai sistem AI mutakhir, termasuk GPT, BERT, dan T5. Sebagai salah satu kelas dalam deep learning[6], transformer telah mengalami sejumlah penyesuaian dan pengembangan[7], yang memodifikasi arsitektur orisinalnya untuk keperluan yang lebih beragam. Transformer tersusun atas beberapa komponen inti yang saling bekerja sama dalam memproses informasi. Berikut adalah uraian dari masing-masing komponen tersebut:

1. Arsitektur Encoder-Decoder

Secara umum, arsitektur encoder-decoder terdiri dari dua substruktur yang saling berkomplementasi. Bagian encoder bertugas menerima data masukan dan mentransformasikannya menjadi representasi vektor berdimensi tetap. Sementara itu, bagian decoder memanfaatkan representasi tersebut untuk menghasilkan urutan keluaran yang sesuai. Kedua komponen ini dilatih secara bersamaan dengan tujuan memaksimalkan nilai log-likelihood bersyarat dari keluaran yang diharapkan berdasarkan masukan yang diberikan. Setelah proses pelatihan selesai, pasangan encoder-decoder mampu menghasilkan keluaran yang relevan untuk berbagai urutan masukan baru.

2. Mekanisme Attention

Komponen paling fundamental dalam transformer adalah mekanisme Multi-Head Attention. Mekanisme ini berperan dalam memetakan hubungan antara query dan pasangan key-value menjadi sebuah representasi keluaran yang bermakna. Konsep multi-head mengandung arti bahwa terdapat beberapa blok attention yang beroperasi secara paralel dan independen, di mana seluruh hasilnya kemudian digabungkan untuk membentuk representasi akhir yang lebih kaya. Attention memiliki dua keunggulan utama, yakni kompleksitas komputasi yang relatif rendah serta konektivitas antar elemen yang tinggi, sehingga sangat efektif dalam menangkap ketergantungan jangka panjang pada data sekuensial [8]. Setelah melalui lapisan attention, data selanjutnya diteruskan ke jaringan Feed-Forward Neural Network (FFNN) guna menghasilkan representasi yang lebih dalam dan abstrak.

3. Foundation Model vs. Fine-Tuned Model

Foundation model merujuk pada model yang dilatih menggunakan data dalam skala besar dan dirancang untuk dapat diadaptasi ke berbagai tugas hilir (downstream tasks). Apabila model tersebut kemudian dilatih ulang menggunakan data yang lebih spesifik dan terbatas, proses tersebut dikenal sebagai fine-tuning. Pendekatan ini memungkinkan model pra-latih berperforma tinggi pada dataset yang lebih kecil sekalipun, melalui mekanisme transfer learning.

Dalam konteks klasifikasi teks, panjang urutan masukan menjadi salah satu faktor penentu yang krusial. Model BERT dalam versi aslinya hanya mampu mengakomodasi hingga 512 token, sedangkan varian-varian pengembangannya seperti Big Bird dan Longformer telah memperluas kapasitas tersebut hingga 4.096 token, sehingga lebih mampu menangani dokumen panjang seperti esai akademik [9]. Dengan memanfaatkan mekanisme attention dan self-attention, transformer telah berhasil mencapai tingkat akurasi tertinggi dalam berbagai tugas klasifikasi teks. Kemampuan transfer learning memungkinkan model pra-latih ini di-fine-tune pada dataset berukuran kecil dengan tetap menghasilkan performa yang sangat kompetitif. Berdasarkan tinjauan yang dilakukan oleh Papers With Code terhadap 358 dataset yang mencakup 20 tugas klasifikasi NLP, sekitar 68% model dengan performa terbaik merupakan model berbasis transformer.

Satu hal yang perlu dicatat adalah bahwa transformer, berbeda dengan arsitektur RNN, tidak memiliki mekanisme urutan bawaan (inherent sequential ordering). Oleh karena itu, positional encoding ditambahkan ke dalam representasi masukan agar model dapat memahami posisi dan urutan kata dalam sebuah kalimat secara eksplisit.

C. Python

Python adalah bahasa pemrograman tingkat tinggi yang bersifat serbaguna dan berorientasi objek, dikenal luas berkat sintaksisnya yang ringkas, intuitif, serta mudah dipahami. Dibandingkan bahasa pemrograman lainnya, Python dirancang untuk meminimalkan jumlah baris kode yang diperlukan tanpa mengorbankan fungsionalitas. Bahasa ini pertama kali dikembangkan oleh Guido van Rossum di Stichting Mathematisch Centrum (CWI), Amsterdam, dan dirilis secara resmi pada tahun 1991[10]. Sejak saat itu,

Python berkembang pesat dan berhasil menarik jutaan pengguna dari beragam latar belakang, tidak terbatas pada kalangan profesional teknologi informasi saja.

Sebagai perangkat lunak bersumber terbuka (open source), Python dapat dijalankan di berbagai sistem operasi, termasuk Windows dan Linux. Fleksibilitas ini menjadikan Python pilihan utama di kalangan peneliti, terutama karena kemampuannya dalam mengelola volume data yang besar serta menjalankan komputasi matematis yang kompleks[11]. Lebih dari itu, Python juga berfungsi sebagai platform pengembangan yang mendukung implementasi berbagai pendekatan kecerdasan buatan, termasuk machine learning dan deep learning.

D. Website

Website merupakan kumpulan halaman digital yang memuat berbagai jenis berkas, dokumen, dan gambar yang tersimpan pada sebuah server web[12]. Sejak kemunculannya pada awal dekade 1990-an, World Wide Web dinilai sebagai salah satu inovasi yang paling berdampak bagi kehidupan manusia[13]. Dalam konteks masa kini, website berfungsi sebagai pintu akses utama menuju berbagai sumber informasi, ilmu pengetahuan, dan data yang dapat ditelusuri melalui mesin pencari. Selain itu, website juga dimanfaatkan sebagai media penyimpanan dan penampil data dari server, baik untuk keperluan personal maupun profesional seperti kegiatan bisnis dan layanan institusional.

Salah satu keunggulan website adalah sifatnya yang multi-platform, memungkinkan akses dari berbagai jenis perangkat selama terhubung dengan jaringan internet [14]. Website modern umumnya dirancang secara responsif, yakni mampu menyesuaikan tampilan secara otomatis terhadap ukuran layar perangkat yang digunakan. Dari sisi legalitas, website dapat diklasifikasikan menjadi dua kategori, yaitu website legal dan website ilegal. Mengingat maraknya kasus website ilegal yang terus meningkat, penerapan kecerdasan buatan menjadi solusi yang relevan untuk membantu mengidentifikasi dan membedakan kategori suatu website secara otomatis dan akurat.

E. Flask

Flask adalah kerangka kerja (framework) berbasis Python yang tergolong dalam kategori micro-framework. Berbeda dengan framework berskala penuh, Flask mengutamakan kesederhanaan dan fleksibilitas pada intinya, sehingga pengembang memiliki kebebasan untuk menambahkan komponen tambahan sesuai kebutuhan spesifik proyek. Framework ini pertama kali dikembangkan oleh Armin Ronacher pada tahun 2010 [15], dan sejak saat itu menjadi salah satu pilihan populer dalam pengembangan aplikasi berbasis web dengan Python.

Dalam hal pengelolaan rute, Flask menyederhanakan proses pendefinisian URL melalui penggunaan decorator, yang membuat kode lebih bersih dan mudah dipelihara. Secara arsitektural, Flask mengadopsi pola Model-View-Controller (MVC) yang membagi tanggung jawab aplikasi ke dalam tiga lapisan utama: Model berperan dalam mengelola logika bisnis dan interaksi dengan basis data, View bertanggung jawab atas

tampilan antarmuka pengguna menggunakan templat HTML berbasis Jinja2, serta Controller yang berfungsi sebagai penghubung antara permintaan pengguna dengan logika pemrosesan aplikasi.

Lebih dari sekadar framework konvensional, Flask mampu berperan sebagai jembatan yang mengintegrasikan antarmuka pengguna, model prediksi berbasis kecerdasan buatan, dan sistem basis data dalam satu ekosistem aplikasi yang kohesif [16].

III. METODOLOGI PENELITIAN

A. Rancangan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif yang dilaksanakan secara sistematis melalui lima tahapan utama yang saling berkesinambungan.

Tahap pertama adalah identifikasi masalah, yang dilakukan melalui observasi terhadap dinamika peredaran konten ilegal di Indonesia. Hasil observasi menunjukkan bahwa sistem pemantauan yang berjalan saat ini masih bergantung pada proses manual, sehingga tidak mampu mengimbangi laju pertumbuhan URL ilegal yang bersifat dinamis dan kerap berpindah domain. Minimnya pemanfaatan teknologi Natural Language Processing (NLP) berbasis bahasa lokal juga menjadi hambatan dalam validasi konten secara otomatis. Temuan ini menjadi dasar penetapan fokus penelitian, yaitu pengembangan sistem klasifikasi teks berbasis Transfer Learning IndoBERT yang terintegrasi dalam antarmuka berbasis web.

Yang kedua adalah studi literatur, mencakup penelusuran buku, jurnal ilmiah, dan penelitian terdahulu yang relevan dengan topik kecerdasan buatan, arsitektur Transformer, teknik fine-tuning IndoBERT, karakteristik konten digital ilegal, implementasi Flask, serta metode evaluasi Confusion Matrix dan K-Fold Cross Validation. Hasil tahap ini menjadi landasan konseptual dan teknis dalam perancangan sistem.

Selanjutnya adalah pengumpulan data, yang dilakukan melalui mekanisme crawling berbasis Server API (Google Search) dengan alur empat lapisan: Controller Layer untuk validasi permintaan pengguna, Service Layer untuk pengaturan proses dan strukturisasi data, Repositories Layer untuk pengambilan dan penyimpanan data ke berkas CSV, serta Response Layer untuk penyajian hasil kepada pengguna yang memuat informasi judul, tautan, cuplikan konten, posisi, dan lokasi berkas.

Keempat adalah implementasi IndoBERT, yang mencakup pengumpulan dan pelabelan dataset website legal dan ilegal, fine-tuning model terhadap dataset tersebut, evaluasi performa menggunakan confusion matrix (akurasi, precision, recall, dan F1-Score) serta K-Fold Cross Validation untuk hasil yang lebih stabil dan reliabel, konfigurasi hyperparameter meliputi epoch, batch size, learning rate, dan optimizer, serta integrasi hasil model ke dalam antarmuka frontend sistem.

Tahap terakhir adalah penarikan kesimpulan, yang merangkum keseluruhan proses penelitian secara menyeluruh. Dengan rancangan yang sistematis dan terstruktur ini, sistem yang dikembangkan diharapkan mampu mengklasifikasikan

website legal dan ilegal secara efektif, efisien, dan sesuai dengan kebutuhan pengguna.

B. Rancangan Sistem

Tahap rancangan implementasi merupakan inti dari proses pengembangan sistem dalam penelitian ini. Pengembangan dilakukan mengacu pada model Waterfall yang bersifat sekuensial, di mana setiap tahapan meliputi analisis kebutuhan, desain sistem, implementasi, dan pengujian diselesaikan secara tuntas sebelum berlanjut ke tahap berikutnya. Pendekatan ini memastikan bahwa setiap keluaran proses dapat menjadi fondasi yang kokoh bagi tahapan selanjutnya.

C. Analisis Kebutuhan

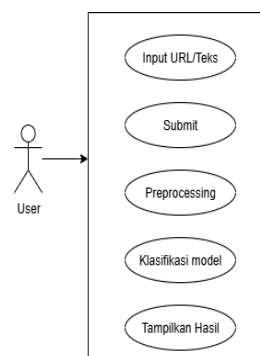
Analisis kebutuhan dilakukan untuk mengidentifikasi seluruh komponen dan fungsi yang diperlukan agar sistem klasifikasi website legal dan ilegal dapat beroperasi sesuai tujuan pengembangan, dengan berlandaskan pada dataset yang telah dikumpulkan sebelumnya. Kebutuhan sistem dibagi ke dalam dua kategori, yakni kebutuhan fungsional dan non-fungsional.

Dari sisi fungsional, sistem harus mampu mengklasifikasikan suatu website ke dalam kategori legal atau ilegal secara otomatis berdasarkan dataset yang tersedia, dengan menggunakan model IndoBERT sebagai mekanisme utama klasifikasi teks.

Dari sisi non-fungsional, sistem dirancang untuk memenuhi empat aspek kualitas operasional: kinerja, keamanan, kemudahan penggunaan, serta kompatibilitas, yaitu sistem dapat diakses melalui berbagai peramban populer seperti Google Chrome, Microsoft Edge, dan Mozilla Firefox.

D. Desain Sistem

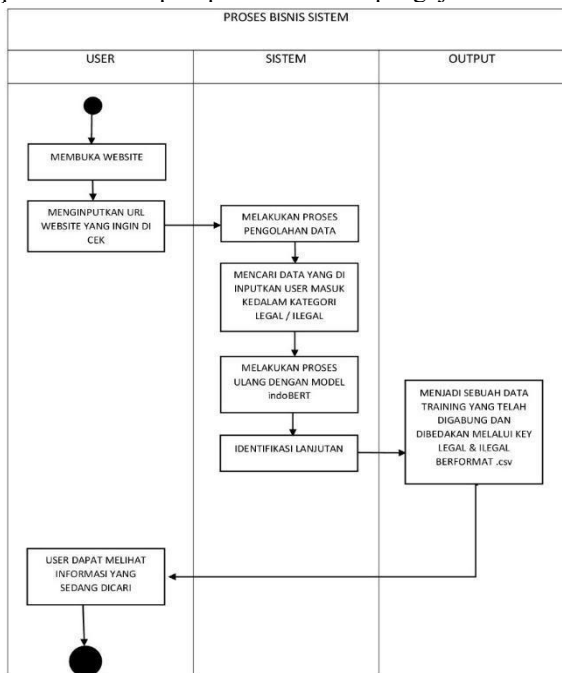
Tahap desain sistem bertujuan untuk memetakan rancangan teknis sistem klasifikasi website legal dan ilegal sebagai acuan sebelum memasuki proses implementasi, disusun berdasarkan hasil analisis kebutuhan yang telah dilakukan sebelumnya. Desain sistem mencakup tiga pemodelan utama, yaitu use case diagram, flowchart, dan proses bisnis system



Gambar 1 Usecase Diagram.

Use case diagram digunakan untuk mendeskripsikan fungsi-fungsi utama yang dapat diakses oleh setiap aktor dalam sistem, sehingga memberikan gambaran menyeluruh mengenai pola interaksi antara pengguna dan sistem. Sementara itu, flowchart menggambarkan alur logika dan

urutan proses secara visual, memungkinkan pengembang memahami keterkaitan antarproses dengan lebih jelas guna mempermudah tahap implementasi dan pengujian.



Gambar 2 Proses Bisnis Sistem

Adapun alur proses bisnis sistem dimulai ketika pengguna mengakses halaman utama website dan dihadapkan langsung pada antarmuka pencarian untuk memasukkan URL yang akan diklasifikasikan. Sistem selanjutnya memproses masukan tersebut menggunakan model IndoBERT melalui serangkaian tahapan komputasi yang telah dirancang. Apabila data berhasil dikenali, sistem akan menampilkan hasil klasifikasi beserta informasi yang relevan kepada pengguna secara langsung.

IV. HASIL DAN PEMBAHASAN

A. IMPLEMENTASI SISTEM

Tahap ini memaparkan hasil penerapan sistem deteksi website legal dan ilegal yang dibangun menggunakan Python Flask sebagai backend dan HTML Jinja2 sebagai kerangka antarmuka frontend. Implementasi dilakukan mengacu pada spesifikasi kebutuhan fungsional dan non-fungsional yang telah ditetapkan pada tahap analisis sebelumnya.

Pemilihan Python Flask sebagai backend didasarkan pada kemampuannya dalam mengelola alur logika sistem secara langsung tanpa bergantung pada framework berskala besar, sehingga sistem dapat beroperasi lebih ringan dan efisien sesuai kebutuhan. Sementara itu, HTML Jinja2 dimanfaatkan untuk membangun antarmuka pengguna yang responsif, konsisten, dan dapat diakses dengan baik di berbagai jenis perangkat.

1. Implementasi Halaman Utama

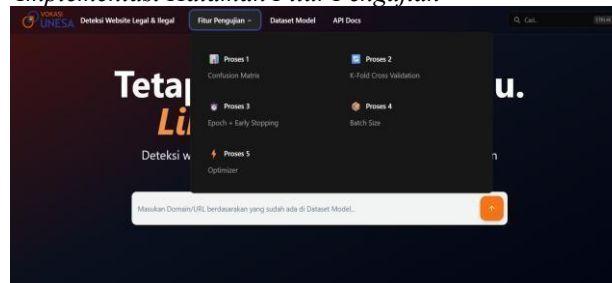
Halaman utama sistem dirancang dengan tampilan antarmuka yang modern dan mengikuti tren desain website masa kini. Terdapat beberapa fitur utama yang dapat diakses langsung oleh pengguna, meliputi menu deteksi website legal dan ilegal, menu pengujian, menu dataset model, serta menu dokumentasi API (API Docs).



Gambar 3 Halaman Utama

Halaman beranda merupakan halaman utama sistem yang menampilkan fitur pencarian (search engine) sebagai komponen inti, berfungsi sebagai titik awal bagi pengguna dalam melakukan analisis dan klasifikasi suatu website ke dalam kategori legal atau ilegal. Halaman ini juga menampilkan jargon utama yang bersifat motivatif, dimaksudkan untuk mendorong kesadaran pengguna akan pentingnya kewaspadaan terhadap konten digital ilegal dalam aktivitas sehari-hari.

2. Implementasi Halaman Fitur Pengujian

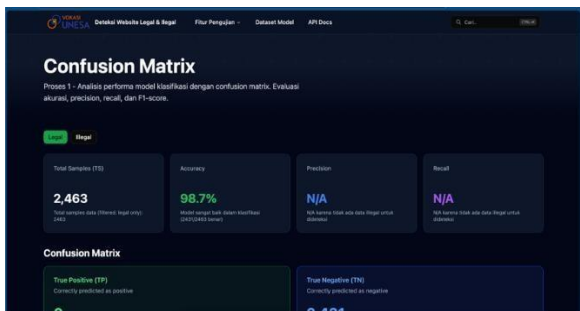


Gambar 4 Halaman Fitur Pengujian

Halaman ini menyajikan informasi mengenai tahapan evaluasi model yang dilakukan untuk mengukur performa sistem klasifikasi secara menyeluruh.

3. Implementasi Halaman proses 1 Pengujian

Evaluasi menggunakan confusion matrix mencakup empat metrik utama, yaitu akurasi, precision, recall, dan F1-Score.



Gambar 5 Halaman Pengujian Confusion Matrix

Proses evaluasi berjalan melalui enam tahapan. Pertama, pengguna mengirimkan permintaan (request) ke endpoint `/api/v1/confusion-matrix` dengan parameter kategori yang ditentukan. Kedua, Controller Layer menerima dan memvalidasi masukan tersebut. Ketiga, Service Layer memproses logika bisnis dan mengambil data melalui repository. Keempat, sistem membaca berkas `ALL_DATA_COMBINED_MERGED.csv` dan melakukan penyaringan data dalam pengujian ini diperoleh 2.463 sampel kategori legal. Kelima, Evaluation Service menghitung nilai confusion matrix dengan hasil TP=0, TN=2.431, FP=32, dan FN=0. Keenam, sistem mengembalikan respons JSON yang memuat seluruh metrik evaluasi beserta penjelasannya.

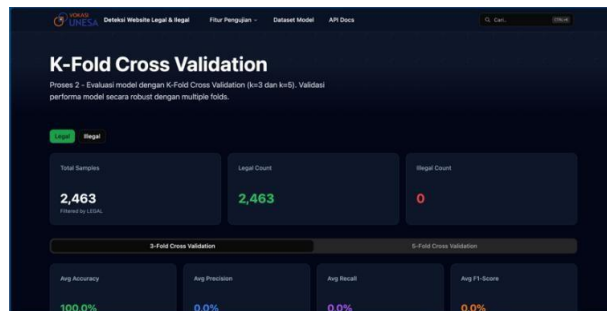


Gambar 6 Grafik Hasil Performa Model Confusion Matrix

Berdasarkan data yang telah disaring, Metode confusion matrix memiliki keunggulan dalam memberikan evaluasi performa model secara rinci. Akan tetapi, hasil evaluasi tersebut masih di pengaruhi oleh distribusi dataset yang digunakan. Oleh karena itu, diperlukan pengembangan evaluasi lanjutan agar model dapat menghasilkan performa yang lebih stabil dan akurat pada berbagai kondisi data.

4. Implementasi Halaman proses 2 Pengujian

Hasil evaluasi model menggunakan teknik K-Fold Cross Validation dengan nilai K=3 dan K=5. Teknik ini bekerja dengan membagi dataset menjadi K bagian (fold) berukuran seimbang, model dilatih dan diuji sebanyak K kali secara bergantian satu fold digunakan sebagai data uji (test set) dan K-1 fold sisanya sebagai data latih (training set), sehingga menghasilkan evaluasi yang lebih robust dan representatif.



Gambar 7 Halaman Pengujian K-Fold Cross Validation

Pendekatan ini menghasilkan penilaian performa yang lebih robust dibandingkan evaluasi tunggal. Ukuran setiap fold dihitung menggunakan rumus : $fold_size = \lfloor total_samples / k \rfloor$, dengan sisa sampel ditambahkan ke fold terakhir. Pada dataset kategori legal sejumlah 2.463 sampel, konfigurasi K=3 menghasilkan tiga fold masing-masing berisi 821 sampel, sedangkan K=5 menghasilkan empat fold berisi 492 sampel dan satu fold terakhir berisi 495 sampel. Rata-rata metrik dihitung dengan rumus :

$$Average = \frac{1}{k} \times \sum(metric_i)$$

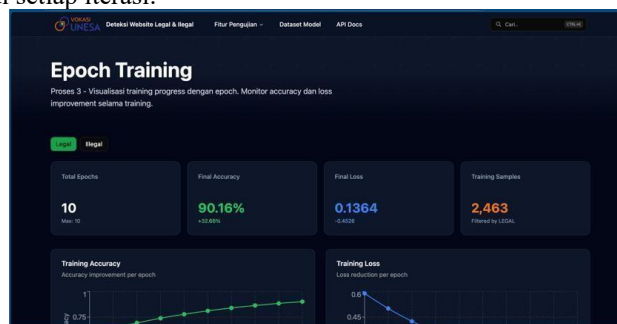
menghasilkan akurasi sebesar 100,0% pada seluruh fold di kedua konfigurasi. Konsistensi model diukur melalui standard deviation (σ) menggunakan rumus :

$$\sigma = \sqrt{\left(\frac{1}{k}\right) \times \sum(metric_i - average)^2}$$

dengan interpretasi: $\sigma < 1\%$ dikategorikan sangat konsisten, $1\% - 5\%$ cukup konsisten, dan $\sigma \geq 5\%$ tidak konsisten. Hasil pengujian menunjukkan nilai σ sebesar $\pm 0,0\%$ pada kedua konfigurasi, yang mengindikasikan bahwa model berada dalam kategori sangat konsisten dalam mengklasifikasikan seluruh data uji di setiap fold.

5. Implementasi Halaman proses 3 Pengujian

Halaman epoch training berfungsi untuk memantau proses pelatihan model secara menyeluruh, mencakup perhitungan loss, pembaruan bobot (weights), dan peningkatan performa di setiap iterasi.



Gambar 8 Halaman Pengujian Epoch Training

Model diinisialisasi dengan bobot acak sehingga pada epoch pertama performa masih rendah, dengan akurasi 57,50% dan loss 0,5890. Pada setiap epoch, sistem melakukan iterasi terhadap seluruh 2.463 sampel, memprediksi setiap data, menghitung loss menggunakan rumus :

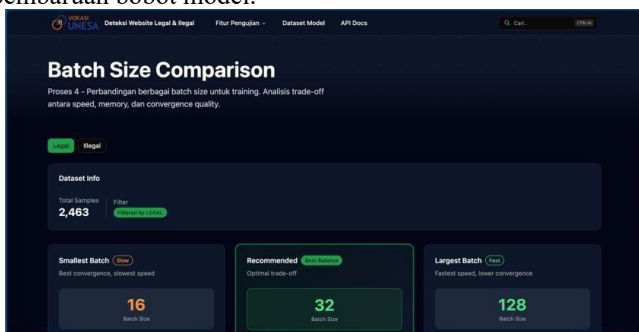
$$\text{Binary Cross-Entropy Loss} = -\left(\frac{1}{N}\right) \times \sum [y \times \log(\hat{y}) + (1 - y) \times \log(1 - \hat{y})]$$

lalu memperbarui bobot melalui metode gradient descent. Akurasi dihitung sebagai rasio prediksi benar terhadap total data $Accuracy = \text{Correct Predictions} / \text{Total Predictions}$.

Pelatihan berlangsung selama 10 epoch dengan pemantauan perkembangan metrik secara berkala. Model dinyatakan konvergen ketika nilai loss tidak lagi mengalami penurunan signifikan, sedangkan kondisi loss yang meningkat mengindikasikan overfitting. Model terbaik dipilih berdasarkan akurasi tertinggi dan loss terendah. Hasil akhir pelatihan menunjukkan akurasi meningkat dari 57,50% menjadi 90,16% (naik 32,66%) dan loss menurun dari 0,5890 menjadi 0,1364 (turun 0,4526), yang mengindikasikan proses pembelajaran berlangsung secara stabil dan konsisten dari epoch pertama hingga terakhir.

6. Implementasi Halaman proses 4 Pengujian

Batch size merujuk pada jumlah sampel yang diproses secara bersamaan dalam satu iterasi pelatihan. Dataset sejumlah 2.463 sampel dibagi ke dalam beberapa batch dan diproses secara bertahap melalui serangkaian tahapan, meliputi pemuatan data ke memori, forward pass untuk prediksi, perhitungan loss, backward pass untuk gradien, hingga pembaruan bobot model.



Gambar 9 Halaman Pengujian Batch Size Comparison

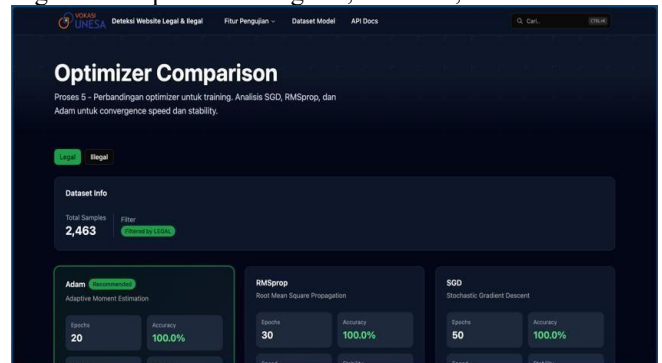
Jumlah iterasi per epoch dihitung menggunakan rumus $iterations = \lceil \text{total_samples} / \text{batch_size} \rceil$, sedangkan sisa sampel pada batch terakhir dihitung dengan $last_batch = \text{total_samples} \bmod \text{batch_size}$. Hasil perhitungan untuk masing-masing konfigurasi batch size adalah: Last batch di atas 80% dikategorikan efisien, sedangkan di bawah 50% dinilai kurang efisien.

Pemilihan batch size melibatkan pertimbangan tiga faktor utama, yaitu kecepatan pelatihan (speed), penggunaan memori, dan kualitas konvergensi. Batch kecil (16) menghasilkan konvergensi terbaik namun dengan kecepatan rendah dan iterasi yang banyak. Batch sedang (32) menawarkan keseimbangan optimal antara kecepatan, memori,

dan kualitas konvergensi, sehingga menjadi pilihan yang direkomendasikan. Sementara itu, batch besar (128) memungkinkan pelatihan yang lebih cepat dengan iterasi lebih sedikit, namun menghasilkan kualitas konvergensi yang lebih rendah.

7. Implementasi Halaman proses 5 Pengujian

Optimizer merupakan algoritma yang mengatur pembaruan parameter model (weights) guna meminimalkan loss function selama pelatihan. Pengujian dilakukan terhadap tiga jenis optimizer pada dataset 2.463 sampel, dengan mengukur kecepatan konvergensi, stabilitas, dan akurasi akhir.

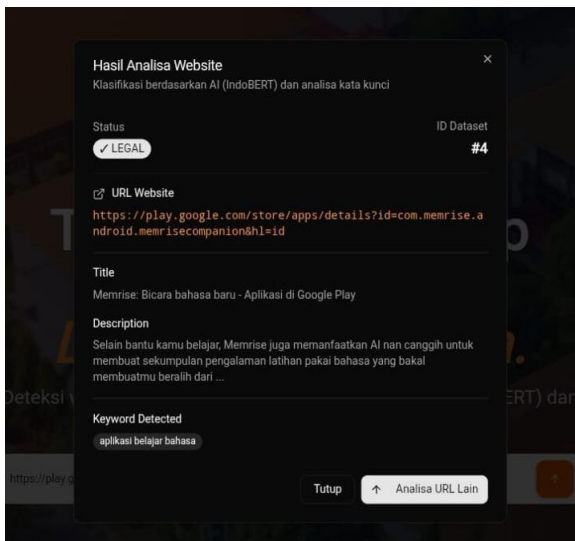


Gambar 10 Halaman Pengujian Optimizer Comparison

SGD memperbarui bobot dengan rumus: $w = w - \text{learning_rate} \times \text{gradient}$. Dengan learning rate 0,01, model membutuhkan 50 epoch untuk konvergen dan mencapai akurasi 100,0%. SGD bersifat sederhana dan hemat memori, namun konvergensinya lambat dan tidak adaptif terhadap perubahan gradien. RMSprop menerapkan adaptive learning rate berbasis magnitudo gradien, sehingga mampu konvergen lebih cepat dalam 30 epoch dengan learning rate 0,001 dan akurasi 100,0%, meskipun membutuhkan memori tambahan. Adam menggabungkan konsep momentum dan adaptive learning rate, menghasilkan konvergensi tercepat hanya dalam 20 epoch dengan learning rate 0,001 dan akurasi 100,0%, menjadikannya pilihan yang paling direkomendasikan karena keunggulannya dalam kecepatan dan stabilitas. Meskipun ketiga optimizer menghasilkan akurasi akhir yang setara, Adam terbukti paling unggul dalam efisiensi pelatihan, diikuti RMSprop dengan performa moderat, dan SGD dengan konvergensi paling lambat.

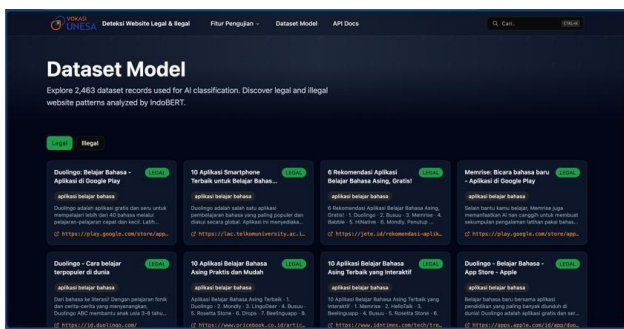
8. Implementasi Halaman Hasil Pemrosesan

Gambar 11 dibawah ini merupakan tampilan hasil Output dari analisa website yang telah peneliti rancang dengan beberapa informasi didalamnya seperti status analisa Url, tampilan link url yang tadi telah user inputkan, judul dari link url tersebut, deskripsi dari link url, dan Keyword dari link tersebut.



Gambar 11 Halaman Hasil Pemrosesan

9. Implementasi Halaman Dataset Model



Gambar 12 Halaman Dataset Model

Pada halaman ini memberikan informasi seputar URL legal dan ilegal yang telah terdaftar pada website yang penulis kembangkan sehingga penelitian ini terbatas pada url yang telah masuk ke dalam data set model

B. PENGUJIAN SISTEM

Pengujian sistem dilaksanakan untuk memverifikasi bahwa seluruh fitur dan algoritma dalam sistem deteksi website legal dan ilegal telah berjalan sesuai rancangan yang ditetapkan. Pengujian difokuskan pada aspek fungsional dengan pendekatan black-box, yakni memberikan masukan tertentu kepada sistem dan mengamati keluaran yang dihasilkan tanpa mempertimbangkan logika atau proses internal yang berjalan di balik sistem, guna memastikan setiap fitur beroperasi sesuai kebutuhan pengguna. Dari pengujian yang telah penulis lakukan mendapatkan hasil sebagai berikut,

Tabel 1 Hasil Pengujian Blackbox

No	Fitur	Skenario Pengujian	Hasil yang Diharapkan	Hasil
1	Halaman Beranda	User dapat Mengakses halaman utama sistem	Sistem dapat menampilkan informasi dan CTA Button Input URL	Berhasil
2	Input URL	User dapat Memasukkan URL berdasarkan dataset yang telah ada	Sistem dapat menampilkan hasil result data yang telah ada	Berhasil
3	Halaman Proses 1 Pengujian	User dapat Mengakses Halaman Proses 1 Pengujian	Sistem dapat Menampilkan Informasi Data pada Proses 1	Berhasil
4	Halaman Proses 2 Pengujian	User dapat Mengakses Halaman Proses 2 Pengujian	Sistem dapat Menampilkan Informasi Data pada Proses 2	Berhasil
5	Halaman Proses 3 Pengujian	User dapat Mengakses Halaman Proses 3 Pengujian	Sistem dapat Menampilkan Informasi Data pada Proses 3	Berhasil
6	Halaman Proses 4 Pengujian	User dapat Mengakses Halaman Proses 4 Pengujian	Sistem dapat Menampilkan Informasi Data pada Proses 4	Berhasil
7	Halaman Proses 5 Pengujian	User dapat Mengakses Halaman Proses 4 Pengujian	Halaman Proses 5 Pengujian Menampilkan Informasi Data pada Proses 5	Berhasil
8	Halaman Dataset Model	User dapat Mengakses Halaman Dataset Model	Sistem dapat Menampilkan Informasi keseluruhan data terhadap Dataset Illegal / Legal	Berhasil

V. KESIMPULAN DAN SARAN

A. Kesimpulan

Kesimpulan pada penelitian ini menunjukkan bahwasannya:

1. Telah berhasil dilakukan rancangan dan implementasi sistem klasifikasi website legal dan ilegal berbasis Transfer Learning IndoBERT yang terintegrasi dalam antarmuka berbasis web menggunakan Flask
2. Sistem yang dikembangkan mampu mengklasifikasikan konten website secara sistematis dan proaktif berdasarkan deskripsi teks, sehingga proses identifikasi yang sebelumnya dilakukan secara manual kini dapat dijalankan secara otomatis dengan waktu respons yang lebih singkat dan risiko penyebaran konten berbahaya yang lebih minimal.
3. Penerapan model IndoBERT melalui proses fine-tuning terbukti efektif dalam memahami karakteristik bahasa Indonesia pada konten digital, termasuk kemampuannya

menangkap konteks semantik dan mengenali istilah-istilah khusus (slang) yang lazim ditemukan pada situs ilegal namun jarang muncul pada situs legal, menjadikannya lebih unggul dibandingkan metode NLP tradisional.

4. Evaluasi menggunakan K-Fold Cross Validation menghasilkan performa yang konsisten dan stabil, mengindikasikan bahwa model memiliki kemampuan generalisasi (robustness) yang baik terhadap variasi data yang berbeda.
5. Hasil pengujian model menunjukkan performa terbaik pada setiap skenario evaluasi, dengan rincian sebagai berikut:
 - a. Pengujian Confusion Matrix: akurasi 98,7% (2.431 dari 2.463 data terklasifikasi benar)
 - b. Pengujian K-Fold Cross Validation: rata-rata akurasi 100,0%
 - c. Pengujian Epoch Training: akurasi akhir 90,16%
 - d. Pengujian Batch Size: konfigurasi optimal pada batch size 32 dengan efisiensi last batch 96,9%
 - e. Pengujian Optimizer: seluruh optimizer mencapai akurasi 100,0%, dengan Adam sebagai pilihan terbaik
6. Integrasi model ke dalam aplikasi Flask memungkinkan pengguna melakukan pengecekan URL secara langsung dan memperoleh hasil klasifikasi secara real-time, mencakup proses preprocessing otomatis, pemberian label Legal atau Ilegal, serta nilai probabilitas keyakinan model.
7. Secara keseluruhan, penelitian ini memberikan kontribusi nyata dalam upaya digitalisasi pengawasan ruang siber di Indonesia melalui kombinasi model deep learning yang akurat dan sistem yang fungsional, dengan tujuan menciptakan ekosistem internet yang lebih aman, tertib, dan dapat diandalkan.

B. Saran

Adapun saran dari penelitian yang telah dilakukan yaitu sebagai berikut:

1. Pembaruan dataset secara berkala perlu dilakukan untuk menjaga performa model tetap relevan terhadap dinamika konten internet yang terus berkembang. Penambahan jumlah sampel data disertai penerapan teknik data augmentation dapat dipertimbangkan sebagai upaya meningkatkan kemampuan model dalam mengenali pola-pola baru pada situs ilegal yang menggunakan istilah-istilah terselubung.
2. Optimalisasi infrastruktur komputasi atau penerapan teknik model quantization perlu dikaji lebih lanjut guna mempercepat waktu inferensi model saat melakukan klasifikasi secara real-time, tanpa mengorbankan konsistensi dan akurasi hasil deteksi yang telah dicapai.
3. Pengembangan fitur notifikasi otomatis dan integrasi API ke lembaga regulator terkait, seperti Kementerian Komunikasi dan Informatika (Kominfo), dapat ditambahkan sebagai mekanisme pelaporan langsung ketika sistem mendeteksi website dengan tingkat probabilitas ilegal yang sangat tinggi.
4. Penambahan fitur Web Crawler otomatis perlu

dipertimbangkan agar sistem mampu memindai sejumlah besar URL secara mandiri tanpa bergantung pada masukan manual dari pengguna, sehingga cakupan pemantauan dapat diperluas secara signifikan.

5. Pengembangan pendekatan multimodal dapat dijadikan arah penelitian selanjutnya, yakni dengan mengombinasikan klasifikasi berbasis teks dan analisis visual (screenshot halaman website), sehingga sistem memperoleh pemahaman yang lebih komprehensif terhadap konten yang dievaluasi.
6. Penelitian lanjutan dapat mengkaji penerapan model Large Language Model (LLM) lainnya atau varian terbaru arsitektur Transformer sebagai studi komparasi terhadap IndoBERT dalam tugas klasifikasi teks ilegal, dan kemampuan penanganan data tidak seimbang (imbalanced data), sebagai dasar pemilihan arsitektur yang paling optimal untuk implementasi skala nasional.

REFERENSI

- [1] Kufel, J., Bargiel-Lączek, K., Kocot, S., Kozlik, M., Bartnikowska, W., Janik, M., Czogalik, L., Dudek, P., Magiera, M., Lis, A. and Paszkiewicz, I., 2023. What is machine learning, artificial neural networks and deep learning?—Examples of practical applications in medicine. *Diagnostics*, 13(15), p.2582.
- [2] Siska, M., Siregar, I., Saputra, A., Juliana, M. and Afifudin, M.T., 2023. Kecerdasan Buatan dan Big Data dalam Industri Manufaktur: Sebuah Tinjauan Sistematis. *Nusantara Technology and Engineering Review*, 1(1), pp.41-53.
- [3] Patel, H. Pendekatan Berpusat pada Data vs. Pendekatan Berpusat pada Model dalam Pembelajaran Mesin. Blog MLOps 2023. Tersedia daring: <https://neptune.ai/blog/data-centric-vs-model-centric-machine-learning>
- [4] Brown, S. Pembelajaran Mesin, Dijelaskan. MIT Sloan. Ide yang Dibuat Menjadi Nyata. 2021. Tersedia daring: <https://mitsloan.mit.edu/ideas-made-to-matter/machine-learning-explained>
- [5] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30, 6000–6010.
- [6] Amatriain, X., Sankar, A., Bing, J., Bodigutla, P.K., Hazen, T.J. and Kazi, M., 2023. Transformer models: an introduction and catalog. *arXiv preprint arXiv:2302.07730*.
- [7] Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 1724–1734.
- [8] Amatriain, X., Sankar, A., Bing, J., Bodigutla, P.K., Hazen, T.J. and Kazi, M., 2023. Transformer models: an introduction and catalog. *arXiv preprint arXiv:2302.07730*.
- [9] Fields, J., Chovanec, K. and Madiraju, P., 2024. A survey of text classification with transformers: How wide? how large? how long? how accurate? how expensive? how safe?. *IEEE Access*, 12, pp.6518-6531.
- [10] Awangga, R. M. (2019). *Pengantar sistem informasi geografis: Sejarah, definisi dan konsep dasar*. Kreatif Industri Nusantara. (phyton)
- [11] Rahman, A., Hidayat, M., & Nugroho, S. (2021). Penggunaan bahasa pemrograman Python dalam analisis data untuk penelitian ilmiah. *Jurnal Informatika dan Rekayasa Perangkat Lunak*, 3(2), 45–53.
- [12] Sebok, S. L., Vermaat, M., Freund, S. M., Campbell, J. T., & Frydenberg, M. (2018). *Discovering computers 2018: Digital technology, data, and devices*. Cengage Learning.(website)
- [13] Dillon, S., Schönthaler, F., & Vossen, G. (2017). *The web at graduation and beyond: Business impacts and developments*. Springer.
- [14] Bryan Willie, Karissa Vincentio, Genta Indra Winata, Samuel Cahyawijaya, Xiaohong Li, Zhi Yuan Lim, Sidik Soleman, Rahmad

- Mahendra, Pascale Fung, Syafri Bahar, and Ayu Purwarianti. 2020. IndoNLU: Benchmark and Resources for Evaluating Indonesian Natural Language Understanding. In *Proceedings of the 1st Conference of the Asia-Pacific Chapter of the Association for Computational Linguistics and the 10th International Joint Conference on Natural*.
- [15] Fajri Koto, Afshin Rahimi, Jey Han Lau, and Timothy Baldwin. 2020. IndoLEM and IndoBERT: A Benchmark Dataset and Pre-trained Language Model for Indonesian NLP. In *Proceedings of the 28th International Conference on Computational Linguistics*, pages 757–770, Barcelona, Spain (Online). International Committee on Computational Linguistics.
- [16] Lakshmi, Jalluri Harshitha. Multiple Disease Prediction System Using Machine Learning and Flask web Framework Application. Departement of Computer Science and Engineering Parul University.