

Implementasi Chatbot Berbasis Transformer Dan Pemindaian QR Code Pada Website Inventaris

1st Hendrik Hermawan

Teknologi Informasi

Telkom University Surabaya

Surabaya, Indonesia

hendrikhermawan@student.telkomuniversity.ac.id

2nd Yohanes Setiawan

Teknologi Informasi

Telkom University Surabaya

Surabaya, Indonesia

yohannessetiawan@telkomuniversity.ac.id

3rd Mustafa Kamal

Teknologi Informasi

Telkom University Surabaya

Surabaya, Indonesia

mustafakamal@telkomuniversity.ac.id

Abstrak — Belum adanya transformasi digital pengolahan data inventaris pada PT Berlian Jasa Terminal Indonesia menyebabkan rawan kesalahan seperti data yang tidak akurat, akses informasi yang lambat, dan pelacakan aset yang tidak efisien akibat proses manual. Metode konvensional berbasis spreadsheet yang lambat dan rawan kesalahan mendorong perlunya solusi teknologi modern untuk meningkatkan efisiensi dan kemudahan akses informasi. Penelitian ini berhasil mengembangkan dan mengimplementasikan sistem inventaris berbasis website yang mengintegrasikan pemindaian QR Code untuk pelacakan aset fisik dan chatbot berbasis model Transformer (IndoBERT) untuk akses informasi melalui Natural Language Processing (NLP). Proses pengembangan mencakup perancangan arsitektur, pelatihan model, dan pengujian sistem secara menyeluruh. Hasil pelatihan model menunjukkan bahwa konfigurasi hyperparameter optimal (Skenario 3) mampu mencapai akurasi 91% untuk klasifikasi intent dan performa nyaris sempurna untuk *Named Entity Recognition* (NER) pada data uji awal. Namun, pengujian lanjutan menggunakan 100 sampel data uji yang menantang mengungkap bahwa model memiliki keterbatasan dalam menangani permintaan di luar cakupan (intent unknown), di mana banyak di antaranya keliru diklasifikasikan sebagai cari_perangkat. Sistem ini terbukti fungsional dan mampu meningkatkan efisiensi dibandingkan metode manual, dengan chatbot yang berhasil merespons permintaan pengguna secara akurat untuk fungsionalitas inti.

Kata kunci— Manajemen Inventaris IT, Pemindaian QR Code, Chatbot dengan Model Transformer, Pemrosesan Bahasa Alami (NLP)

I. PENDAHULUAN

Inventaris merupakan proses mencatat dan mengelola aset atau barang yang dimiliki oleh suatu organisasi secara terstruktur dan profesional untuk mendukung kelancaran operasionalnya [1]. Dalam dunia industri modern, pengelolaan inventaris perangkat Teknologi Informasi (TI) menjadi komponen penting karena berkaitan langsung dengan efektivitas kerja, stabilitas sistem, dan efisiensi operasional, khususnya pada perusahaan sektor logistik.

Namun, banyak organisasi atau perusahaan masih kurang memberikan perhatian yang memadai terhadap sistem

inventarisasi, sehingga menghadapi tantangan dalam melacak aset secara real-time, memastikan akurasi data, dan memprediksi kebutuhan pemeliharaan perangkat. Sebagian besar perusahaan masih mengandalkan metode manual atau semi-digital, seperti pencatatan menggunakan spreadsheet atau Excel, yang memiliki berbagai keterbatasan [2].

PT Berlian Jasa Terminal Indonesia (BJTI) merupakan perusahaan penyedia jasa terminal pelabuhan yang memiliki peran strategis dalam mendukung kelancaran logistik dan transportasi di Indonesia. Dalam operasionalnya, perangkat teknologi informasi (IT) memegang peranan penting untuk mendukung pengelolaan data, komunikasi, dan pengendalian aktivitas pelabuhan secara efisien. Namun, berdasarkan hasil survei dan wawancara, pengelolaan dan pemeliharaan perangkat IT di PT BJTI saat ini masih dilakukan secara manual, yaitu dengan mencatat data perangkat melalui aplikasi seperti Microsoft Excel dan Google Spreadsheet. Proses ini tidak hanya memakan waktu, tetapi juga rawan terhadap kesalahan manusia serta sering mengakibatkan keterlambatan dalam pembaruan data, sehingga menghambat pemantauan kondisi perangkat secara real-time.

Tim IT support yang bekerja dalam sistem shift juga menghadapi kesulitan dalam melakukan koordinasi dan pelacakan perangkat secara menyeluruh. Masalah perangkat sering kali baru terdeteksi setelah terjadi kerusakan, sehingga proses pemeliharaan bersifat reaktif dan tidak terjadwal dengan baik. Selain itu, proses pencatatan inventaris dilakukan secara konvensional dengan menggunakan stiker kode inventaris yang ditulis tangan menggunakan spidol. Stiker tersebut mudah rusak, terkelupas, atau hilang, sehingga menyulitkan proses identifikasi perangkat. Tidak adanya sistem pemindaian otomatis seperti QR Code menyebabkan pendataan perangkat bergantung sepenuhnya pada ketelitian manusia, yang pada akhirnya meningkatkan risiko kesalahan pencatatan serta menurunkan akurasi data inventaris.

Untuk mengatasi masalah tersebut, penelitian ini mengusulkan pengembangan sistem inventaris cerdas yang mengintegrasikan teknologi Quick Response (QR) Code dan chatbot. QR Code memungkinkan identifikasi aset yang cepat dan otomatis [3] sementara chatbot menawarkan antarmuka percakapan yang efisien untuk mengakses dan mengelola data inventaris. Penelitian sebelumnya telah menunjukkan keberhasilan chatbot di berbagai bidang seperti pariwisata [4].

dan keunggulan model Transformer dalam tugas pemrosesan bahasa alami, yang terbukti efektif memahami dan menghasilkan respons akurat [5]

Kebaruhan penelitian ini terletak pada penerapan chatbot berbasis Transformer yang dioptimalkan untuk tugas inventarisasi perangkat TI dengan pemahaman bahasa alami (NLU) dalam Bahasa Indonesia. Dengan mengintegrasikan klasifikasi niat, ekstraksi entitas, dan pemindaian QR Code, sistem ini dirancang untuk merespons perintah kompleks secara kontekstual—seperti pencarian aset berdasarkan nama, lokasi, atau kondisi—secara real-time. Solusi ini diharapkan dapat secara signifikan mengurangi kesalahan pencatatan manual, meningkatkan akurasi data, dan mendukung pengambilan keputusan proaktif dalam manajemen aset TI di lingkungan industri.

II. KAJIAN TEORI

A. QR Code

QR Code adalah pengembangan dari barcode, yang hanya dapat menyimpan informasi secara horizontal. Berbeda dengan barcode, QR Code mampu menyimpan lebih banyak data secara horizontal dan vertikal. Kapasitas penyimpanannya cukup besar, mencakup berbagai jenis data seperti numerik, alfabet, simbol, kode biner, hingga karakter kanji. Secara rinci, QR Code dapat menyimpan hingga 7.089 karakter numerik, 4.296 karakter alfanumerik, 2.844 byte kode biner, dan 1.817 karakter kanji [6]

B. Chatbot

Chatbot atau percakapan dengan robot adalah aplikasi kecerdasan buatan yang dirancang untuk mensimulasikan percakapan cerdas antara manusia berdasarkan pengetahuan yang dimilikinya. Chatbot berfungsi sebagai agen cerdas yang dapat meniru kemampuan manusia dalam berkomunikasi melalui pesan teks. Teknologi ini telah banyak digunakan di berbagai sektor, termasuk di perusahaan perbankan, untuk menjawab pertanyaan terkait layanan perbankan dan menangani keluhan pelanggan [7]

C. Natural Language Processing (NLP)

Natural Language Processing (NLP) atau pengolahan bahasa alami adalah cabang dari kecerdasan buatan yang memungkinkan komputer untuk berkomunikasi dengan manusia menggunakan bahasa sehari-hari, termasuk Bahasa Indonesia [8].

D. Arsitektur Transformer

Transformer adalah arsitektur deep learning yang merevolusi NLP dengan menggunakan mekanisme self-attention [9]. Mekanisme ini memungkinkan model untuk menimbang pentingnya setiap kata dalam sebuah kalimat, sehingga mampu menangkap konteks secara lebih mendalam. Arsitektur ini terdiri dari komponen *Encoder* dan *Decoder* [10]. Encoder bertugas memproses seluruh urutan data masukan (seperti kalimat) dan mengubahnya menjadi representasi numerik yang kaya akan informasi kontekstual. Kemudian, Decoder menggunakan representasi tersebut untuk menghasilkan urutan keluaran (misalnya, kalimat terjemahan atau jawaban) kata demi kata. [11]

E. Bidirectional Encoder Representations from Transformers (BERT)

BERT (*Bidirectional Encoder Representations from Transformers*) adalah model bahasa pra-latih yang dikembangkan oleh Google yang mampu memahami konteks kata secara mendalam dalam sebuah kalimat [12]. Model ini menggunakan arsitektur transformer yang memanfaatkan perhatian diri (*self-attention*) secara bidirectional, artinya model memproses konteks dari kedua arah kiri dan kanan secara bersamaan. [13]

F. Named Entity Recognition (NER)

Named Entity Recognition (NER) adalah salah satu teknik penting dalam bidang *Natural Language Processing* (NLP) yang bertujuan untuk mengidentifikasi dan mengelompokkan entitas bernama dalam sebuah teks menjadi kategori-kategori yang telah ditentukan, seperti nama orang, organisasi, lokasi, waktu, dan sebagainya [14]. Dalam konteks sistem chatbot inventaris perangkat IT ini, NER digunakan untuk mengenali entitas-entitas spesifik yang terkandung dalam pertanyaan pengguna [15]. Entitas-entitas tersebut meliputi, antara lain .

- Nama perangkat (contoh: computer, printer, monitor)
- Merk perangkat (contoh: HP, Lenovo, BenQ)
- Tipe atau model perangkat (contoh: Pavilion, RL2460S)
- User pengguna perangkat (contoh: Lucia, Teguht, Vera)
- Divisi atau lokasi perangkat (contoh: PCO-C, PCO-M)
- Status kondisi perangkat (contoh: Normal Aktif, Baik, Rusak)

G. Pengujian Model

Menggunakan confusion matrix evaluasi NLP

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (1)$$

$$precision = \frac{TP}{TP + FP} \quad (2)$$

$$recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1 - Score = 2 \times \frac{precision \times recall}{precision + recall} \quad (4)$$

$$mAP = \frac{1}{Q} \sum_{q=1}^Q AP_q \quad (5)$$

Keterangan :

TP (*True Positives*) : Prediksi positif yang benar

TN (*True Negatives*) : Prediksi negatif yang benar

FP (*False Positives*) : Prediksi salah tetapi dianggap positif

FN (*False Negatives*) : Prediksi salah tetapi dianggap negatif

mAP (*Mean Average Precision*): Ini adalah metrik yang mengukur performa rata-rata

Rumus (1) mengukur tingkat ketepatan model secara keseluruhan. Akurasi menghitung persentase prediksi yang benar (baik True Positive maupun True Negative) dari total semua prediksi yang dibuat. Sederhananya, ini menjawab pertanyaan: "Seberapa sering model membuat prediksi yang benar?"

Rumus (2) mengukur tingkat kepercayaan dari prediksi positif. Presisi menghitung proporsi prediksi positif yang benar dari semua yang diprediksi sebagai positif.

Rumus (3) mengukur kemampuan model untuk menemukan semua kasus positif yang ada. Recall menghitung proporsi kasus positif aktual yang berhasil diidentifikasi dengan benar oleh model.

Rumus (4) menjelaskan rata-rata harmonik dari Presisi dan Recall.

Rumus (5) mengukur performa rata-rata model di berbagai query atau kategori. Metrik ini menghitung rata-rata dari semua nilai.

III. METODE


A. Alur Sistematika Penelitian



GAMBAR 1
(SISTEMATIKA PENYELESAIAN MASALAH)

Proses penelitian pada Gambar 1 ini mencakup identifikasi masalah di PT Berlian Jasa Terminal Indonesia, studi literatur, dan analisis kebutuhan yang menjadi dasar perancangan sistem. Sistem kemudian dikembangkan menggunakan Codeigniter dengan fitur QR Code dan chatbot Transformer, lalu dievaluasi melalui pengujian fungsional dan *User Acceptance Testing* (UAT), sebelum akhirnya disempurnakan untuk implementasi akhir.


B. Alur Pengembangan QR Code



GAMBAR 2
(PENGEMBANGAN QR CODE)

Gambar 2 menjelaskan Proses pembuatan dan penggunaan QR Code dalam sistem inventarisasi ini diawali dengan pengumpulan data detail perangkat seperti nama, nomor seri, dan status. Data tersebut kemudian dikonversi menjadi QR Code yang dicetak dan ditempelkan pada setiap perangkat IT. Ketika pengguna memindai kode ini menggunakan smartphone, data di dalamnya akan dikirim ke sistem untuk menampilkan informasi lengkap mengenai perangkat, termasuk statusnya serta saran perawatan yang diperlukan, sehingga secara keseluruhan mempermudah manajemen dan pemeliharaan aset.


C. Alur Pengembangan Chatbot



GAMBAR 3
(ALUR ALUR PRA-PEMROSESAN DATA TEKS)

Pra-pemrosesan data teks pada Gambar 3 adalah proses untuk membersihkan teks mentah melalui serangkaian langkah berurutan: mengubah semua huruf menjadi kecil (case folding), memecah teks menjadi token (tokenisasi), menghapus kata-kata umum yang tidak relevan (stopword removal), dan mengubah kata ke bentuk dasarnya (stemming atau lemmatization). Setelah tanda baca dihilangkan, data teks menjadi bersih dan terstruktur, sehingga siap digunakan untuk melatih model.

Alur Model Intent + NER berbasis Transformer



GAMBAR 4
(PERANCANGAN CHATBOT INTENT & NER)

Pada Gambar 4 pengguna memberikan perintah, teks tersebut dipecah menjadi token dan dimasukkan ke dalam Model Transformer. Model ini secara bersamaan memprediksi tujuan pengguna (*intent*) dan mengekstrak informasi kunci (*entities*) dari kalimat. Hasilnya berupa data terstruktur (tujuan dan detail) yang langsung digunakan oleh logika bot untuk menyusun dan mengirimkan respons yang akurat.

IV. HASIL DAN PEMBAHASAN

Sumber data ini berasal dari PT Berlian Jasa Terminal Indonesia (BJTI), yang saat ini masih mengelola data secara manual menggunakan Excel dan Spreadsheet. meliputi

informasi detail tentang perangkat IT seperti 'id', 'divisi', 'sub_divisi', 'nomor_inventaris', 'kategori', 'nama_barang', 'merk', 'tipe', 'serial_number', 'lokasi', 'waktu_perolehan', 'kondisi_existing', 'status_aset', 'usia_perangkat', 'username_pc', 'user_pengguna', 'computer_name', 'cpu', 'ram', 'hdd', 'os', 'antivirus', 'office', 'rekendasi', dan 'ip_address'.

TABEL 1
(DATA INVENTARIS)

ID	Divisi	Kategori	Nama Barang	Merk	...	...	Lokasi	Kondisi
01	Pco - c	Perangkat komputer	computer	HP	...	...	HGA	Normal aktif
02	Pco - c	Perangkat komputer	computer	HP	...	...	HGA	Normal aktif
...	...	...	...	...	...	...	...	...
99	Pco- m	Perangkat Komputer	Monitor	HP	...	...	FIN	RUSAK

Data pada Tabel 1 ini diambil dari 99 data inventaris (24 kolom), namun disederhanakan untuk penulisan tugas akhir. Metode pengumpulan dilakukan melalui wawancara dengan pemangku kepentingan untuk memahami kebutuhan data dan ketersediaan data historis. Data ini krusial untuk melacak aset secara real-time dan memprediksi kebutuhan pemeliharaan.

A. Pelatihan dan Evaluasi Kinerja Model

Pelatihan model dilakukan untuk dua tugas utama: Klasifikasi Intent dan *Named Entity Recognition* (NER).

1. Untuk Klasifikasi Intent

TABEL 2
(HYPERPARAMETER INTENT TRAIN)


Skenario	Learning Rate	Batch Size	Scheduler
1	2e-5	16	Linear
2	4.5e-5	16	Linear
3	1.5e-5	8	Linear

TABEL 3
(HASIL SEMUA SKENARIO TUGAS KLASIFIKASI)

no	Accuracy	Precision	Recall	F1 Score	Eval Loss	Runtime (s)
1	0.9655	0.9685	0.965	0.965	0.1268	0.74
2	0.9224	0.9312	0.922	0.922	0.2227	0.75
3	1.0000	1.0000	1.000	1.000	0.0577	0.74

Tabel 3 menjelaskan Tiga skenario eksperimen dilakukan dengan *hyperparameter* yang berbeda pada tabel 2. Hasilnya menunjukkan bahwa Skenario 3 (*Learning Rate* 1.5e-5, *Batch Size* 8) memberikan performa paling unggul, berhasil

mencapai akurasi, presisi, recall, dan *F1-Score* sempurna (1.0) pada data validasi.



GAMBAR 5
(CONFUSION MATRIX SKENARIO 3)

Gambar 5 mencapai kinerja yang sempurna dengan akurasi 100%. Meskipun menggunakan konfigurasi yang berbeda, yaitu *learning rate* yang lebih rendah (1.5e-5) dan *batch size* yang lebih kecil (8), hasilnya identik dengan Skenario 2. *Confusion matrix* untuk skenario ini juga menunjukkan bahwa semua prediksi jatuh tepat di diagonal, mengonfirmasi tidak adanya kesalahan klasifikasi. Hasil ini menunjukkan bahwa model tidak hanya dapat mencapai performa puncak, tetapi juga robust atau tetap stabil pada konfigurasi pelatihan yang berbeda.

2. Untuk Pelatihan NER

TABEL 4
(HYPERPARAMETER NER TRAIN)

Skenario	Learning Rate	Batch Size	Scheduler
1	5e-5	16	Linear
2	3e-5	16	Linear
3	2e-5	8	Linear

TABEL 5
(HASIL SEMUA SKENARIO TUGAS NER)

no	Accuracy	Precision	Recall	F1 Score	Eval Loss	Runtime (s)
1	9.992	9.991	9.992	9.992	85	227.5
2	9.992	9.991	9.992	9.992	83	181.2
3	9.992	9.991	9.992	9.992	81	135.9

Tabel 5 menjelaskan Tiga skenario diuji untuk tugas NER pada tabel 4. Semua skenario berhasil mencapai *F1-Score* nyaris sempurna (~0.999). Namun, Skenario 3 menjadi pilihan paling optimal karena mencapai performa maksimal dengan waktu pelatihan tercepat, yaitu hanya dalam 3 epoch.




GAMBAR 6
(CONFUSION MATRIX SKENARIO 3)

Pada Gambar 6 Confusion matrix lagi-lagi menegaskan keandalan model dengan hasil yang identik dengan dua skenario sebelumnya. Hal ini mengindikasikan bahwa pelatihan selama 3 epoch sudah cukup bagi model untuk mencapai konvergensi dan performa maksimal pada set data yang digunakan.

B. Pengujian Sistem pada Data Uji

Untuk mengukur kinerja model dalam kondisi yang lebih realistis, dilakukan pengujian akhir menggunakan 100 sampel data uji.



GAMBAR 7
(CONFUSION MATRIX DATA UJI)

Analisis confusion matrix pada Gambar 7 mengungkap kekuatan dan kelemahan model. Model sangat andal dalam mengenali intent yang terdefinisi dengan jelas seperti *cari_perangkat* dan *salam*. Namun, tantangan terbesar terletak pada penanganan intent unknown (permintaan di luar cakupan), di mana 11 dari 25 kasus (48%) keliru diklasifikasikan sebagai *cari_perangkat*. Hal ini menunjukkan model memiliki kecenderungan untuk mengasosiasikan kata kunci terkait inventaris dengan niat mencari, meskipun konteks perintahnya berbeda.

C. Implementasi Antarmuka dan Fungsionalitas

Sistem berhasil diimplementasikan dalam dua platform utama:

Website Inventaris:



GAMBAR 8
(LOGIN)

Gambar 8 ini menampilkan Halaman Login sistem. Halaman ini berfungsi sebagai gerbang keamanan untuk memastikan hanya pengguna yang berwenang (admin) yang dapat mengakses data inventaris. Pengguna harus memasukkan *username* dan *password* yang valid untuk masuk ke dalam sistem.



GAMBAR 9
(DASHBOARD)

Gambar 9 merupakan Halaman Dashboard, yang merupakan tampilan utama setelah login berhasil. Halaman ini menyajikan ringkasan visual dari seluruh data inventaris melalui kartu statistik (seperti total perangkat, perangkat aktif, dan lokasi gudang) serta grafik statistik pemakaian dan pemeliharaan. Tujuannya adalah untuk memberikan gambaran umum kondisi inventaris secara cepat dan efisien.



GAMBAR 10
(HALAMAN UTAMA INVENTARIS)

Gambar 10 menampilkan seluruh daftar aset dalam format tabel yang terstruktur dan mudah dibaca. Halaman ini dilengkapi dengan fitur pencarian untuk memfilter data, tombol untuk menambah data baru, serta tombol aksi untuk melihat detail atau menghapus setiap aset.



GAMBAR 11
(HALAMAN DETAIL ASET INVENTARIS)


Gambar 11 adalah Halaman Detail Aset, yang menampilkan informasi lengkap untuk satu perangkat spesifik. Halaman ini menyajikan foto perangkat, spesifikasi teknis, lokasi, pengguna, hingga QR Code unik untuk aset tersebut. Dari sini, admin dapat mengedit data atau mencetak informasi perangkat.



GAMBAR 12
(QR CODE)

Gambar 12 merupakan QR Code yang dihasilkan oleh sistem untuk setiap aset. Setiap kode bersifat unik dan berisi tautan langsung ke halaman detail perangkat yang bersangkutan di dalam website. Kode ini dicetak dan ditempelkan pada aset fisik, berfungsi sebagai jembatan antara barang fisik dan data digitalnya, yang dapat dipindai dengan mudah menggunakan *smartphone*.

Chatbot Telegram:




GAMBAR 13
(LAPORAN PERANGKAT)

Gambar 13 ini menunjukkan kemampuan chatbot untuk merespons perintah laporan ringkas. Ketika pengguna meminta laporan perangkat milik pengguna tertentu ("yera"), bot memberikan ringkasan data yang terstruktur, meliputi total perangkat, kondisi, lokasi, dan contoh detail perangkat yang relevan.



GAMBAR 14
(PENCARIAN PERANGKAT)

Gambar 14 mendemonstrasikan fungsionalitas pencarian spesifik. Pengguna menanyakan lokasi "laptop merk lenovo", dan chatbot berhasil mengidentifikasi kriteria tersebut, lalu memberikan jawaban detail mengenai satu perangkat yang cocok, lengkap dengan ID, tipe, lokasi, dan penggunanya.



GAMBAR 15
(QUERY_TOTAL_PERANGKAT)

Gambar 15 menampilkan kemampuan bot untuk melakukan agregasi atau penghitungan data. Pengguna bertanya "berapa total perangkat komputer", dan bot merespons dengan jawaban kuantitatif yang akurat, yaitu jumlah total perangkat yang masuk dalam kategori tersebut sesuai data di database.

V. KESIMPULAN

Sistem inventaris berbasis website dengan integrasi QR Code dan chatbot Transformer telah berhasil dikembangkan dan diuji secara fungsional. Proses pelatihan model menunjukkan bahwa konfigurasi *hyperparameter* yang optimal (Skenario 3) mampu menghasilkan model NLU dengan performa sangat tinggi pada data validasi. Meskipun demikian, Pengujian lebih lanjut menggunakan 100 data uji yang menantang menunjukkan performa model secara realistik, dengan akurasi dan *Mean Average Precision* (mAP) sebesar 91%. sekaligus mengidentifikasi kelemahan utama dalam menangani permintaan di luar cakupan (unknown intent). Seluruh fungsionalitas utama, mulai dari antarmuka website hingga interaksi chatbot dan pemindaian QR Code, telah divalidasi dan berjalan sesuai harapan.

REFERENSI

- [1] R. Dwi Putri *et al.*, "RANCANG BANGUN SISTEM INFORMASI INVENTARIS BARANG PADA SMP NEGERI 01 RUNJUNG AGUNG BERBASIS WEBSITE."
- [2] Y. Sansena and S. Samsudin, "Aplikasi Perhitungan Penyusutan Inventaris Barang menggunakan Decreasing Charge Method Berbasis Website," *Edumatic: Jurnal Pendidikan Informatika*, vol. 7, no.

- 1, pp. 169–177, Jun. 2023, doi: 10.29408/edumatic.v7i1.17572.
- [3] Hery, J. Renaldo Laih, C. Alencia Haryani, and A. E. Widjaja, “Penerapan Teknologi Qr Code Berbasis Web pada Sistem Manajemen Inventaris di Gudang PT XYZ,” *Technomedia Journal*, vol. 7, no. 2, pp. 202–215, Aug. 2022, doi: 10.33050/tmj.v7i2.1903.
- [4] A. Chen, Z. Yu, X. Yang, Y. Guo, J. Bian, and Y. Wu, “Contextualized medication information extraction using Transformer-based deep learning architectures,” *J Biomed Inform*, vol. 142, Jun. 2023, doi: 10.1016/j.jbi.2023.104370.
- [5] W. T. Kim *et al.*, “Medication Extraction and Drug Interaction Chatbot: Generative Pretrained Transformer-Powered Chatbot for Drug-Drug Interaction,” *Mayo Clinic Proceedings: Digital Health*, vol. 2, no. 4, pp. 611–619, Dec. 2024, doi: 10.1016/j.mcpdig.2024.09.001.
- [6] I. Benito-Altamirano, D. Martínez-Carpena, H. Lizarzaburu-Aguilar, C. Fàbrega, and J. D. Prades, “Reading QR Codes on challenging surfaces using thin-plate splines,” *Pattern Recognit Lett*, vol. 184, pp. 37–43, Aug. 2024, doi: 10.1016/j.patrec.2024.06.004.
- [7] D. T. A. Victoire and M. Vasuki, “Smart Inventory Management System Using Chatbot,” 2024.
- [8] M. S. Azad, S. I. Leon, R. Khan, N. Mohammed, and S. Momen, “SAD: Self-assessment of depression for Bangladeshi university students using machine learning and NLP,” *Array*, vol. 25, Mar. 2025, doi: 10.1016/j.array.2024.100372.
- [9] T. T. Aurpa *et al.*, “Deep transformer-based architecture for the recognition of mathematical equations from real-world math problems,” *Heliyon*, vol. 10, no. 20, Oct. 2024, doi: 10.1016/j.heliyon.2024.e39089.
- [10] “Transformer Based Bengali Chatbot Using General Knowledge Dataset.”
- [11] S. Nerella *et al.*, “Transformers and large language models in healthcare: A review,” Aug. 01, 2024, *Elsevier B.V.* doi: 10.1016/j.artmed.2024.102900.
- [12] A. Babu and S. B. Boddu, “BERT-Based Medical Chatbot: Enhancing Healthcare Communication through Natural Language Understanding,” *Exploratory Research in Clinical and Social Pharmacy*, vol. 13, Mar. 2024, doi: 10.1016/j.rcsop.2024.100419.
- [13] “Transformer Based Bengali Chatbot Using General Knowledge Dataset.”
- [14] M. R. Azizi, W. Hayuhardhika, N. Putra, and I. Arwani, “Ekstraksi Informasi pada Data Logbook KKN Mahasiswa Fakultas Ilmu Komputer Universitas Brawijaya Malang menggunakan Metode NER (Named Entity Recognition),” 2023. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [15] J. Shin, E. Jo, Y. Yoon, and J. Jung, “A System for Interviewing and Collecting Statements Based on Intent Classification and Named Entity Recognition Using Augmentation,” *Applied Sciences (Switzerland)*, vol. 13, no. 20, Oct. 2023, doi: 10.3390/app132011545.

.

