

Information Extraction from CV Documents Using a Hybrid Natural Language Processing and Rule-Based Approach

[Ekstraksi Informasi dari Dokumen CV Menggunakan Pendekatan *Hybrid Natural Language Processing* dan *Rule-Based*]

Syahfrizka Dyah Nazwa Umbara ¹⁾, Ade Eviyanti ²⁾, Hindarto ³⁾, Sumarno ⁴⁾

¹⁾Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

²⁾Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

³⁾Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

⁴⁾Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

adeeviyanti@umsida.ac.id

Abstract. Digital transformation in recruitment necessitates the adoption of Applicant Tracking Systems (ATS) to ensure efficient applicant management. However, a primary challenge in ATS development lies in the high variability of unstructured Curriculum Vitae (CV) formats. These formats are difficult to process using solely rule-based methods due to their inherent rigidity, while Deep Learning approaches often impose significant computational burdens. This study aims to develop a CV information extraction system that strikes a balance between high accuracy and computational efficiency. Employing a hybrid approach, this research integrates Rule-Based algorithms (Regular Expressions) for extracting factual entities with Natural Language Processing (NLP)—utilizing the spaCy library and PhraseMatcher—for the contextual analysis of competencies and work experience. Empirical testing results demonstrate superior system performance, achieving a Precision of 91.3%, a Recall of 87.5%, and an F1-Score of 89.4%. Overall, the system attained an accuracy of 80.8% with an average processing time of under 2 seconds per document. These findings prove that the integration of hybrid methods effectively addresses the complexity of CV formats while maintaining computational efficiency.

Keywords - Natural Language Processing, Applicant Tracking System, Information Extraction, Resume Parsing, Hybrid Approach, Rule-Based System

Abstrak. Transformasi digital dalam rekrutmen menuntut adopsi Applicant Tracking System (ATS) untuk efisiensi pengelolaan pelamar. Namun, tantangan utama pengembangan ATS terletak pada tingginya variabilitas format Curriculum Vitae (CV) tidak terstruktur, yang sulit diproses oleh metode berbasis aturan karena sifatnya yang kaku, maupun Deep Learning yang membebani sumber daya komputasi. Penelitian ini bertujuan mengembangkan sistem ekstraksi informasi CV yang menyeimbangkan akurasi tinggi dan efisiensi komputasi. Melalui pendekatan hibrida (Hybrid Approach), penelitian ini mengintegrasikan algoritma Rule-Based (Regular Expressions) untuk ekstraksi entitas faktual dan Natural Language Processing (NLP) menggunakan pustaka spaCy serta PhraseMatcher untuk analisis kontekstual pada kompetensi dan pengalaman kerja. Hasil pengujian empiris menunjukkan kinerja sistem yang unggul dengan nilai Precision 91.3%, Recall 87.5%, dan F1-Score 89.4%. Secara keseluruhan, sistem mencapai akurasi 80.8% dengan waktu pemrosesan rata-rata di bawah 2 detik per dokumen. Temuan ini membuktikan bahwa integrasi metode hibrida efektif menangani kompleksitas format CV dengan kebutuhan komputasi yang efisien.

Kata Kunci - Natural Language Processing, Applicant Tracking System, Information Extraction, Resume Parsing, Hybrid Approach, Rule-Based System

I. PENDAHULUAN

1.1 Latar Belakang

Dalam era transformasi digital yang dinamis, efisiensi proses rekrutmen telah berevolusi menjadi prioritas strategis bagi keberlangsungan perusahaan. Volume pelamar yang masif menuntut adopsi teknologi *Applicant Tracking System* (ATS) sebagai standar industri dalam manajemen talenta [1]. Komponen inti yang menentukan kecerdasan sebuah ATS adalah teknologi *Resume Parsing*, yang berfungsi mengonversi dokumen *Curriculum Vitae* (CV) tidak terstruktur (seperti format PDF atau Word) menjadi data terstruktur yang siap diolah untuk proses seleksi otomatis [2]. Keberhasilan teknologi ini sangat krusial karena data yang akurat menjadi fondasi bagi pengambilan keputusan rekrutmen yang tepat sasaran.

1.2 Rumusan Masalah

Meskipun urgensinya tinggi, pengembangan *parser* CV menghadapi tantangan fundamental berupa variabilitas format dokumen yang sangat ekstrem [3]. Literatur terkini mengidentifikasi dikotomi kelemahan pada dua pendekatan dominan yang ada. Pertama, pendekatan *Rule-Based* menawarkan presisi tinggi untuk entitas dengan pola tetap

(seperti email atau nomor telepon) [4][5], namun sangat kaku dan rentan gagal ketika menghadapi variasi gaya bahasa atau tata letak CV yang kreatif. Kedua, pendekatan *Machine Learning* (seperti model BERT atau LSTM) memang unggul dalam pemahaman kontekstual [6][7], namun pendekatan ini menuntut ketersediaan dataset latih (*training dataset*) yang besar serta sumber daya komputasi tinggi (GPU). Kebutuhan sumber daya yang intensif ini seringkali menjadi hambatan implementasi, khususnya bagi infrastruktur skala kecil hingga menengah yang membutuhkan efisiensi biaya dan kecepatan.

1.3 Tujuan Penelitian

Penelitian ini bertujuan untuk menjembatani kesenjangan (*gap*) antara akurasi ekstraksi informasi dan efisiensi komputasi. Fokus utama penelitian adalah mengembangkan sistem ekstraksi informasi CV yang tidak hanya akurat dalam menangkap data pelamar, tetapi juga ringan secara komputasi sehingga layak diimplementasikan pada berbagai skala infrastruktur tanpa ketergantungan pada perangkat keras kelas atas (*high-end hardware*).

1.4 Rencana Penyelesaian Masalah


Untuk mencapai tujuan tersebut, penelitian ini mengusulkan solusi jalan tengah melalui pendekatan Hibrida (*Hybrid Approach*) berbasis Python. Kebaruan (*Novelty*) dari penelitian ini terletak pada arsitektur integrasi sistem yang menggabungkan kekuatan dua metode:

1. Optimasi *Rule-Based*: Penggunaan *Regular Expressions* yang dipertajam khusus untuk ekstraksi entitas faktual (identitas kontak).
2. Penerapan NLP Kontekstual: Pemanfaatan pustaka spaCy dengan metode *PhraseMatcher* untuk menangani entitas yang membutuhkan pemahaman konteks, seperti kompetensi (*Skills*) dan riwayat pengalaman kerja.

Sistem ini kemudian akan divalidasi menggunakan mekanisme evaluasi otomatis berbasis *Ground Truth* untuk mengukur performa sistem (Presisi, *Recall*, dan *F1-Score*) secara kuantitatif dan objektif.

II. METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan metode hibrida dengan tahapan pengembangan perangkat lunak yang meliputi pengumpulan data, perancangan algoritma ekstraksi, implementasi sistem, dan evaluasi kinerja.



Gambar 1. Diagram alur penelitian

2.1 Pengumpulan Data

Pengumpulan data difokuskan untuk menyusun data uji (*test set*) guna memvalidasi kinerja sistem, tanpa memerlukan dataset pelatihan karena penggunaan model NLP *pre-trained*. Data diperoleh dari dua sumber:

1. Data Primer: Dokumen CV nyata (PDF/DOCX) yang dikumpulkan dari mahasiswa dan *fresh graduate* untuk merepresentasikan format industri.
2. Data Sintetis: Dokumen CV buatan yang dirancang dengan variasi format khusus untuk menguji ketahanan sistem.

Seluruh data yang terkumpul kemudian dipetakan secara manual menjadi format JSON (*Ground Truth*) yang berfungsi sebagai kunci jawaban dalam proses evaluasi otomatis.

2.2 Arsitektur Sistem

Sistem dibangun berbasis web menggunakan kerangka kerja Flask (app.py). Alur pemrosesan data terdiri dari tiga modul utama:

1. Modul Input: Menerima file CV (PDF/DOCX) dan melakukan validasi format.
2. Modul Ekstraktor (extractor.py): Inti pemrosesan yang menggunakan pustaka pdfplumber untuk konversi teks dan spaCy (en_core_web_md) untuk pemrosesan linguistik.
3. Modul Evaluator (evaluator.py): Mengukur akurasi hasil ekstraksi dibandingkan dengan data validasi manual.
- 4.

2.3 Algoritma Ekstraksi (Hybrid Method)

Metode ekstraksi dibagi berdasarkan jenis entitas:

1. Informasi Kontak (Rule-Based): Menggunakan Regular Expressions (*Regex*) ketat untuk mengidentifikasi pola email, nomor telepon (+62/08), dan URL LinkedIn. Pendekatan ini dipilih karena pola entitas ini bersifat universal dan baku [13].
2. Ekstraksi Keahlian (NLP - Phrase Matching): Menggunakan fitur PhraseMatcher dari spaCy. Kamus keahlian (skills_safe) didefinisikan mencakup teknologi populer (Python, SQL, AWS, dll). Metode ini lebih unggul daripada pencarian kata kunci biasa karena memperhatikan tokenisasi kata majemuk (misal: "Machine Learning" dihitung satu entitas).
3. Pengalaman & Pendidikan (Contextual Parsing): Menggunakan logika keyword-driven (seperti "Bachelor", "University", "Experience") dikombinasikan dengan deteksi pola tanggal untuk memisahkan blok pengalaman kerja. Algoritma menyaring baris yang mengandung kata kerja aksi (action verbs) untuk menghindari False Positive pada deskripsi tugas.

2.4 Metode Evaluasi

Evaluasi dilakukan dengan membandingkan hasil output sistem (JSON) [13] dengan file Ground Truth (ground_truth.json). Metrik yang digunakan dihitung secara otomatis oleh evaluator.py meliputi:

1. Precision: Tingkat ketepatan entitas yang diekstraksi.
2. Recall: Tingkat keberhasilan sistem menemukan seluruh entitas yang ada.
3. F1-Score: Rata-rata harmonis antara Precision dan Recall.
4. Accuracy (Jaccard Index): Mengukur irisan antara himpunan hasil ekstraksi dan himpunan data sebenarnya.

Precision (P):

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

Recall (R):

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

F1-Score:

$$\frac{1}{F1} = \frac{1}{2} \left(\frac{1}{precision} + \frac{1}{recall} \right) \quad (3)$$

Accuracy:

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

Dimana:

TP (True Positive): Informasi yang benar diekstraksi


TN (True Negative): Informasi yang benar tidak diekstraksi

FP (False Positive): Informasi yang salah diekstraksi

FN (False Negative): Informasi yang seharusnya diekstraksi tapi tidak

III. HASIL DAN PEMBAHASAN

Pengujian dilakukan menggunakan sampel CV (seperti "CV - Eng ver (8-10-2025).pdf") yang telah dipetakan data sebenarnya dalam *Ground Truth*.



Gambar 2. Alur proses batch extraction dan evaluasi

3.1 Kinerja Ekstraksi Entitas

Berdasarkan hasil eksekusi algoritma, diperoleh temuan sebagai berikut:

1. Identifikasi Personal: Algoritma Regex pada extractor.py berhasil mencapai akurasi 100% untuk mendeteksi Email dan Nomor Telepon. Hal ini sejalan dengan penelitian Sari et al. [13] yang menyatakan bahwa metode berbasis aturan sangat efektif untuk pola string yang terstandarisasi.
2. Ekstraksi Skill (Keahlian): Penggunaan PhraseMatcher spaCy terbukti efektif. Sistem mampu membedakan Hard Skill (seperti "Python", "Tableau") yang terdaftar dalam kamus skills_safe. Namun, tantangan muncul pada penulisan skill yang tidak baku atau typo pada dokumen asli.
3. Segmentasi Pengalaman Kerja: Logika pemisahan blok berdasarkan pola tanggal (`re.match(r'^d{4}'...)`) berhasil memisahkan riwayat pekerjaan secara kronologis.

3.2 Hasil Evaluasi Kinerja Sistem

Kategori Entitas	Precision	Recall	F1-Score
Informasi Kontak	1.00	1.00	1.00
Pendidikan	0.80	0.67	0.73
Keahlian (Skills)	1.00	0.94	0.97
Pengalaman Kerja	0.94	0.94	0.94
Akademi	1.00	1.00	1.00

Berdasarkan Tabel 1, terlihat bahwa kinerja sistem bervariasi bergantung pada jenis entitas yang diekstraksi. Kategori Informasi Kontak dan Akademi mencatatkan performa sempurna dengan nilai *Precision* dan *Recall* mencapai 1.00. Hasil ini memvalidasi efektivitas penggunaan metode *Rule-Based* (Regex) untuk menangani pola data yang bersifat baku dan terstandarisasi. Pada kategori Keahlian (Skills), sistem mencapai *Precision* sempurna (1.00) dengan *Recall* yang sangat tinggi (0.94). Hal ini menunjukkan bahwa metode *phrase matching* sangat akurat dalam memvalidasi *skill*, meskipun masih terdapat sebagian kecil *skill* unik yang tidak tertangkap kamus data. Sementara itu, kategori Pendidikan menunjukkan performa terendah dibandingkan kategori lainnya, dengan *Recall* sebesar 0.67. Penurunan ini mengindikasikan adanya tantangan signifikan dalam menangani variabilitas format penulisan institusi pendidikan dan gelar yang sangat beragam pada dokumen CV yang tidak terstruktur.


3.3 Analisis Komparatif

Dibandingkan dengan metode Deep Learning murni yang dibahas oleh Bhaliya et al. [13], sistem yang diusulkan memiliki keunggulan dalam hal kecepatan (*inference time*). Sistem ini tidak memerlukan proses training yang memakan waktu berjam-jam. *evaluator.py* menunjukkan bahwa waktu rata-rata pemrosesan per dokumen adalah di bawah 2 detik, yang sangat efisien untuk penggunaan real-time. Selain itu, fleksibilitas kode memungkinkan penambahan skill baru hanya dengan memperbarui daftar *skills_safe* di *extractor.py* tanpa perlu melatih ulang model, sebuah keuntungan signifikan dibanding model "Black-box" AI [14].

3.4 Implementasi Antarmuka Sistem (*User Interface*)

Sistem ekstraksi informasi CV ini diimplementasikan sebagai aplikasi berbasis web untuk memudahkan interaksi pengguna. Antarmuka pengguna (*User Interface*) dirancang dengan pendekatan minimalis namun fungsional [15], yang terbagi menjadi tiga modul utama: modul *input* (pengunggahan), modul visualisasi hasil, dan modul evaluasi kinerja. Berikut adalah pembahasan rinci mengenai implementasi antarmuka sistem:

Halaman utama sistem berfungsi sebagai gerbang masuk data. Seperti yang ditunjukkan pada Gambar 1, antarmuka ini menyediakan fasilitas *Batch Extraction* yang memungkinkan pengguna untuk mengunggah lebih dari satu dokumen CV sekaligus (format .pdf atau .docx).



Gambar 3. Halaman input batch extraction

Pada halaman ini, pengguna dapat memilih *file* melalui tombol "Pilih File". Sistem memberikan umpan balik visual berupa jumlah *file* yang terpilih (contoh: "*2 files selected*") sebelum diproses. Tombol "Analyze Batch" akan memicu proses *backend* yang menjalankan fungsi *parsing* dokumen, *preprocessing*, dan ekstraksi entitas menggunakan kombinasi Regex dan NLP spaCy sebagaimana dijelaskan pada Bab 3.

3.4.1 Visualisasi Hasil Ekstraksi (*Extraction Results*)

Setelah proses analisis selesai, sistem menampilkan hasil ekstraksi dalam format terstruktur yang mudah dibaca (*human-readable*). Implementasi antarmuka hasil dapat dilihat pada Gambar 4.

BATCH EXTRACTION

EVALUATION METRICS

Upload Multiple CVs

Pilih File

2 file

Analyze Batch

Select up to 10 PDF/DOCX files at once.

2 files selected

CV - Eng ver (7-10-2025).pdf

SYAHFRIZKA DYAH NAZWA UMBARA

nazwaumbara@gmail.com

+62 895 8085 48030

www.linkedin.com/in/nazwaumbara

Professional Summary

Final-semester Informatics student at the University of Muhammadiyah Sidoarjo with proven leadership as Head of Pojok Statistik Agent at Umsida. A Bangkit Academy 2024 and Coding Camp 2025 graduate specializing in Machine Learning Engineering. Skilled in data analysis, Python programming, and Machine Learning model development with a focus on practical business solutions.

Work Experience

Unknown Role

Badan Pusat Statistik Sidoarjo Regency

Aug 2025 – Oct 2025

Unknown Role

Dinas Koperasi UKM Sidoarjo Regency

May 2025 – Aug 2025

Intern – Sekretariat & Cooperative Division

LAZISMU East Java Province

Sept 2024 – Jul 2025

Freelance Web Developer (ZISKA project)

CV Wahana Karya Jaya

Aug 2024 – Sept 2024

Freelance Graphic Designer

CV Wahana Karya Jaya

Feb 2024 – Aug 2025

Education

University of Muhammadiyah Sidoarjo Sept 2022 – Present

Bachelor's Degree in Informatics | GPA: 3.94

| GPA: 3.94

SMA Muhammadiyah 2 Jombang 2019 – 2022

Science Major

Technical Skills

Adobe Illustrator

Canva

Dart

Data Analytics

Deep Learning

Figma

Flutter

Google Workspace

Java

Machine Learning

Microsoft Office

MongoDB

MySQL

Python

QGIS

Statistical Analysis

Academy & Certifications

IDCamp 2025 Scholarship Powered by Indosat Ooredoo Hutchison

Participant

Coding Camp Powered by DBS Foundation Feb 2025 – Jul 2025

Participant

Bangkit Academy by Google, GoTo, Tokopedia, Traveloka

Sept 2024 – Feb 2025

Participant

CV 1 of 2

Gambar 4. Visualisasi hasil ekstraksi cv


Halaman ini mentransformasi teks mentah dari CV menjadi kartu informasi digital yang terorganisir. Fitur utama pada halaman ini meliputi:

1. Header Informasi Personal: Menampilkan Nama Lengkap, Email, Nomor Telepon, dan tautan LinkedIn yang diekstraksi menggunakan pola *Regex*.
2. Segmentasi Data: Informasi dibagi ke dalam blok-blok logis seperti *Professional Summary*, *Work Experience*, *Education*, dan *Academy & Certifications*.

3. Visualisasi Skill: Bagian *Technical Skills* ditampilkan menggunakan gaya *chips* atau *tags* (seperti "Python", "Data Analytics", "Deep Learning"), yang memudahkan perekrut untuk memindai kompetensi kandidat dengan cepat.
4. Navigasi Multi-CV: Terdapat fitur navigasi (panah kiri/kanan dan indikator "CV 1 of 2") di bagian bawah layar, memungkinkan pengguna untuk berpindah antar profil kandidat tanpa perlu memuat ulang halaman.

3.4.2 Halaman Evaluasi Kinerja (*Evaluation Metrics*)

Untuk memvalidasi keandalan sistem secara transparan, disediakan halaman khusus *Evaluation Metrics*. Halaman ini membandingkan hasil ekstraksi sistem secara otomatis dengan data kebenaran dasar (*Ground Truth JSON*).



Gambar 5. Dasbor evaluasi kinerja sistem

Sebagaimana terlihat pada Gambar 3, dasbor ini menyajikan empat metrik evaluasi utama secara *real-time*:

1. Precision (91.3%): Mengindikasikan tingkat ketepatan informasi yang diekstraksi.
2. Recall (87.5%): Mengukur seberapa lengkap informasi yang berhasil ditemukan oleh sistem.
3. F1-Score (89.4%): Nilai rata-rata harmonis yang menunjukkan keseimbangan antara presisi dan kelengkapan.
4. Accuracy (80.8%): Tingkat kesesuaian keseluruhan data.

Di bagian bawah dasbor, terdapat tabel rincian yang memecah skor evaluasi per dokumen (misalnya: "CV - Eng ver (8-10-2025).pdf"), sehingga pengguna dapat mengidentifikasi dokumen mana yang berhasil diekstraksi dengan sempurna dan mana yang memiliki anomali format.

IV. SIMPULAN

Penelitian ini menyimpulkan bahwa implementasi pendekatan hibrida yang menggabungkan Natural Language Processing (NLP) dan Rule-Based System terbukti efektif dalam mengatasi variabilitas format dokumen CV yang tidak terstruktur pada sistem *Applicant Tracking System* (ATS). Berdasarkan hasil evaluasi, sistem mampu mengekstraksi informasi kunci dengan nilai *Precision* mencapai 91,3%, *Recall* 87,5%, dan *F1-Score* 89,4%. Secara spesifik, metode Regex memberikan akurasi sempurna pada data faktual kontak, sedangkan NLP berbasis *PhraseMatcher* unggul dalam mengidentifikasi kompetensi teknis dengan presisi tinggi. Meskipun sistem memiliki performa tinggi dengan waktu pemrosesan rata-rata di bawah 2 detik per dokumen, tantangan parsial masih ditemukan pada segmentasi riwayat pendidikan yang memiliki variasi format penulisan yang ekstrem.

Menindaklanjuti temuan tersebut, penelitian selanjutnya disarankan untuk tidak hanya berfokus pada tahap ekstraksi, melainkan memperluas fungsionalitas menuju tahap pemeringkatan kandidat (*applicant ranking*). Pengembangan algoritma pencocokan semantik (*semantic matching*) antara hasil ekstraksi (JSON) dengan deskripsi pekerjaan (*Job Description*) sangat direkomendasikan agar sistem dapat memberikan rekomendasi urutan kandidat terbaik secara otomatis kepada perekrut. Selain itu, eksplorasi metode yang lebih adaptif diperlukan untuk menangani kompleksitas variasi format pada bagian riwayat pendidikan guna meningkatkan akurasi sistem secara menyeluruh.

UCAPAN TERIMA KASIH

Terimakasih kepada Allah SWT, Tri Mulyani, Khusni Jamaludin Malik dan dosen pembimbing. Ucapan terima kasih juga disampaikan kepada seluruh pihak yang telah berkontribusi, baik secara langsung maupun tidak langsung, dalam penyelesaian penelitian ini

REFERENSI

- [1] M. Saatci, R. Kaya, and R. Ünlü, "Resume Screening With Natural Language Processing (NLP)," *Alphanumeric J.*, vol. 12, no. 2, pp. 121–140, 2024, doi: 10.17093/alphanumeric.1536577.
- [2] K. Chhabra and D. Vashistha, "Applicant Tracking System (ATS) Department of Computer Science & Engineering and Information Technology Jaypee University of Information Technology ," vol. 173234, no. 201293, 2024.
- [3] Harshitha R and M. Veena, "A SURVEY ON RESUME ANALYSIS USING NLP," *www.irjmets.com @International Res. J. Mod. Eng.*, 1030, [Online]. Available: www.irjmets.com
- [4] N. Nair, S. Pavithra, and V. Vismaya, "Resume parser using NLP," *Int. J. Adv. Res. Comput. Commun. Eng.*, vol. 13, no. 9, pp. 39–42, 2024, doi: 10.17148/IJARCCCE.2024.13905.
- [5] Y. Sari, M. F. Hassan, and N. Zamin, "Rule-based pattern extractor and Named Entity Recognition: A hybrid approach," *Proc. 2010 Int. Symp. Inf. Technol. - Eng. Technol. ITSIM'10*, vol. 2, pp. 563–568, 2010, doi: 10.1109/ITSIM.2010.5561392.
- [6] B. Nirali*, J. Gandhi, and D. K. Singh, "NLP based Extraction of Relevant Resume using Machine Learning," *Int. J. Innov. Technol. Explor. Eng.*, vol. 9, no. 7, pp. 13–17, 2020, doi: 10.35940/ijitee.f4078.059720.
- [7] M. B. Gunjal, T. P. Thorat, K. S. Muttha, V. C. Shete, and P. D. Sagar, "A Review Paper on Resume Parser Using AI," 2025.
- [8] "Analysis & Shortcomings of E-Recruitment Systems: Towards a Semantics-based Approach Addressing Knowledge Incompleteness and Limited Domain Coverage 1."
- [9] S. Pudasaini, S. Shakya, S. Lamichhane, S. Adhikari, A. Tamang, and S. Adhikari, "Application of NLP for Information Extraction from Unstructured Documents," *Lect. Notes Networks Syst.*, vol. 209, pp. 695–704, 2022, doi: 10.1007/978-981-16-2126-0_54.
- [10] D. T. Tolciu, C. Săcărea, and C. Matei, "Analysis of patterns and similarities in service tickets using natural language processing," *J. Commun. Softw. Syst.*, vol. 17, no. 1, pp. 29–35, Feb. 2021, doi: 10.24138/JCOMSS.V17I1.1024.
- [11] R. Panwar, "AI-ENABLED INTERVIEW ANALYSIS: UNVEILING INSIGHTS AND ENHANCING DECISION-MAKING IN HUMAN RESOURCE MANAGEMENT," *INTERANTIONAL J. Sci. Res. Eng. Manag.*, vol. 07, no. 05, Jun. 2023, doi: 10.55041/IJSREM24357.
- [12] A. D. Wibawa, A. M. Amri, A. Mas, and S. Iman, "Text Mining for Employee Candidates Automatic Profiling Based on Application Documents," *Emit. Int. J. Eng. Technol.*, pp. 47–62, Apr. 2022, doi: 10.24003/emitter.v10i1.679.
- [13] R. Sonbol, G. Rebdawi, and N. Ghneim, "Date of publication xxxx 00, 0000, date of current version xxxx 00, 0000. The Use of NLP-Based Text Representation Techniques to Support Requirement Engineering Tasks: A Systematic Mapping Review", doi: 10.1109/ACCESS.2017.DOI.
- [14] E. Omodei et al., "OPEN ACCESS EDITED BY REVIEWED BY Natural language processing for humanitarian action: Opportunities, challenges, and the path toward humanitarian NLP." [Online]. Available: <https://thedeep.io>
- [15] M. F. Ghazali and A. Eviyanti, "Sistem Pakar Diagnosa Dini Penyakit Leukimia Dengan Metode 'Certainty Factor,'" *Kinetik*, vol. 1, no. 3, p. 135, 2016, doi: 10.22219/kinetik.v1i3.122.

Conflict of Interest Statement:

The author declares that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.