

Peningkatan Akurasi Temu Kembali Pengetahuan pada Kasus Sakit Kepala Menggunakan Integrasi Case-Based Reasoning dan Natural Language Processing

Agus Mulyanto

Departemen Informatika, UIN Sunan Kalijaga, Yogyakarta, Indonesia

e-mail : agus.mulyanto@uin-suka.ac.id.

Artikel ini diajukan 4 April 2026, direvisi 4 April 2026, diterima 4 April 2026, dan dipublikasikan 25 Mei 2026.

Abstract

Headache disorders represent a significant global neurological challenge, yet medical diagnosis is often hindered by subjective patient complaints and limited facilities. This study proposes an integrated model combining Natural Language Processing (NLP) and Case-Based Reasoning (CBR) to enhance the accuracy of medical decision-making for headache cases. The model utilizes the Random Forest algorithm for NLP classification and Cosine Similarity within the CBR framework to identify case relevance. The dataset consists of medical records for two types of headaches: Cluster headache (G44.0) and Tension-type headache (G44.2). Experimental results demonstrate that data augmentation significantly improves model performance, increasing accuracy from 62% to 69%. For the G44.0 label, the model achieved a precision of 0.84, while the G44.2 label reached a recall of 0.87. Furthermore, the CBR system strengthens the diagnosis with a similarity level of up to 0.82 and continuous learning capabilities through the Retain stage. This integration effectively provides faster, more targeted diagnostic recommendations for medical professionals.

Keywords: Headache, Natural Language Processing, Case-Based Reasoning, Random Forest, Data Augmentation

Abstrak

Penyakit sakit kepala merupakan masalah neurologis global yang signifikan, namun diagnosis medis sering terkendala oleh keluhan pasien yang subjektif dan keterbatasan fasilitas. Penelitian ini mengusulkan model integrasi antara *Natural Language Processing* (NLP) dan *Case-Based Reasoning* (CBR) untuk meningkatkan akurasi pengambilan keputusan medis pada kasus sakit kepala. Model ini menggunakan algoritma *Random Forest* untuk klasifikasi NLP dan teknik *Cosine Similarity* pada jalur CBR untuk mencari kemiripan kasus. Data yang digunakan berasal dari rekam medis dua jenis sakit kepala: *Cluster headache* (G44.0) dan *Tension-type headache* (G44.2). Hasil eksperimen menunjukkan bahwa proses augmentasi data secara signifikan meningkatkan kinerja model, dengan akurasi meningkat dari 62% menjadi 69%. Pada label G44.0, model mencapai presisi 0,84, sementara pada label G44.2 mencapai *recall* 0,87. Selain itu, sistem CBR memperkuat diagnosis dengan tingkat kemiripan hingga 0,82 dan kemampuan pembelajaran berkelanjutan melalui tahap *Retain*. Integrasi ini terbukti efektif dalam memberikan rekomendasi diagnosis yang lebih cepat dan tepat sasaran bagi tenaga medis.

Kata Kunci: Sakit Kepala, Natural Language Processing, Case-Based Reasoning, Random Forest, Data Augmentation

1. PENDAHULUAN

Penyakit sakit kepala menjadi gejala neurologis yang sering dialami dan dapat mengganggu bagi individu (Tripakornkusol et al., 2025). Pada tahun 2021, terdapat sekitar 1,81 miliar kasus penyakit sakit kepala di Asia Tenggara yang memberi dampak signifikan terhadap kualitas hidup dan keselamatan pasien (Zhao et al., 2025). Jumlah kasus sakit kepala yang besar membuatnya menempati peringkat ketiga sebagai kontributor utama dan penyebab disabilitas global bagi orang dibawah umur 50 tahun (Dissing et al., 2025). Sakit kepala dapat dipicu oleh faktor seperti stres, depresi, kecemasan, atau kualitas tidur yang buruk. Kondisi ini sering kali menjadi sumber



kekhawatiran dan tekanan tersendiri dalam berbagai kalangan usia, termasuk anak maupun orang tua (Mourid et al., 2025).

Dalam mengatasi sakit kepala, praktik medis saat ini menghadapi berbagai kesulitan dalam menilai, mendiagnosis, dan mengobati. Ketidakseimbangan tenaga profesional dan fasilitas medis, menyebabkan layanan yang diberikan kepada pasien berkualitas rendah, tidak tepat waktu, dan kurang efektif (Wu et al., 2024). Keluhan dari pasien yang mengalami sakit kepala cenderung bersifat subjektif. Hal ini menyebabkan kesulitan bagi tenaga medis dalam menetapkan diagnosis yang tepat dan cepat (García-Azorin et al., 2020).

Di era modern saat ini, artificial intelligence (AI) menawarkan kemampuan substansial dan problem-solving baru, serta mampu mengembangkan solusi yang sudah ada (Amin et al., 2020). AI dapat diadopsi untuk mengatasi berbagai masalah pada bidang transportasi (Venkatesh Raja et al., 2024) (Naqvi et al., 2022), konstruksi bangunan (Ezzat, 2020), kriminalitas (Krüger, 2023), makanan (Galani & Papakostas, 2022), hukum (Silva et al., 2022), pendidikan (Mulyanto et al., 2024) (Rybinski, 2022), hingga layanan kesehatan (Jeong et al., 2024) (Kawazoe et al., 2025) (Qiu et al., 2025). Salah satu teknologi yang terkenal saat ini adalah natural language processing atau dikenal sebagai NLP. Teknologi NLP berhasil melakukan revolusi di berbagai bidang melalui ChatGPT-3.5, ChatGPT-4, dan Microsoft Bing (Feng et al., 2025). Salah satu tujuan NLP dibangun untuk mengatasi permasalahan dalam memahami dokumen yang mengandung teks panjang dan terkadang ambigu (Hadj-Mabrouk, 2024).

Selain NLP, teknologi yang dapat digunakan untuk mengatasi permasalahan pengetahuan berbasis teks adalah kerangka kerja sistem case-based reasoning, atau biasa dikenal sebagai CBR (Mulyana et al., 2021). CBR memungkinkan kita untuk menghasilkan solusi baru melalui pengalaman sebelumnya atau pengetahuan masa lalu, sekalipun dalam skenario berbeda. Kemampuan dalam menggunakan kembali informasi yang sesuai membuat tingkat kepercayaan CBR, bahkan sistem AI secara umum meningkat (Caro-Martínez et al., 2024). Integrasi antara NLP dan CBR memungkinkan sistem untuk memberikan respons yang dinamis dan cerdas dalam berbagai kondisi yang berubah-ubah. Selain itu, sistem jenis ini mampu memberikan rekomendasi yang disesuaikan berdasarkan riwayat interaksi, preferensi, dan tingkat pengalaman operator sebelumnya (Canizales-Martinez et al., 2025).

Penelitian yang menggunakan konsep NLP telah menunjukkan bahwa teknologi ini memberikan solusi klinis yang efektif dalam dunia nyata, khususnya bidang kesehatan. Dalam analisis eksperimental yang dilakukan menunjukkan bahwa kinerja hasil evaluasi permodelan NLP mencapai F1 Score 88,85% dalam penentuan prioritas rujukan (Villena et al., 2025). Sedangkan penelitian yang menggunakan konsep CBR telah diterapkan untuk mencari nilai bobot kompleksitas yang optimal guna memperoleh nilai MAE, atau *Minimum Absolute Error* (Ardiansyah et al., 2022). Tak hanya itu, terdapat penelitian yang menggunakan konsep NLP dengan mengintegrasikan CBR telah digunakan untuk memahami pengetahuan berbasis teks siklus proyek konstruksi yang berhasil meningkatkan kinerja secara signifikan. Tak hanya itu penelitian tersebut mampu disimpan secara lengkap dan utuh selama siklus, tanpa cacat akibat pergantian staf dan keterbatasan waktu (Wang et al., 2022).

Sebagai langkah lanjutan, penelitian ini mengusulkan sebuah model integrasi antara Natural Language Processing (NLP) dan Case-Based Reasoning (CBR) untuk meningkatkan efektivitas dalam pengambilan keputusan medis. Teknik NLP digunakan untuk mengakuisisi pengetahuan dari rekam medis yang kemudian diproses menjadi basis kasus untuk membantu penanganan kasus sakit kepala. Data yang digunakan dalam penelitian ini berasal dari dokumen rekam medis di Klinik Utama (Poliklinik) UIN Sunan Kalijaga Yogyakarta. Diharapkan, penelitian ini dapat memberikan manfaat bagi tenaga medis dalam meningkatkan efektivitas dan akurasi penanganan kasus sakit kepala, serta memberikan solusi yang lebih cepat dan tepat sasaran.



2. METODE PENELITIAN

Tujuan dan sasaran suatu topik menentukan pilihan metode penelitiannya, sehingga penelitian ini mengusulkan metode kombinasi antara Natural Language Processing (NLP) dan Case-Based Reasoning (CBR). Model ini digunakan untuk memfasilitasi kebutuhan para dokter di bidang medis, terutama dalam meningkatkan pelayanan kepada masyarakat. Kombinasi kedua metode tersebut diharapkan dapat membantu proses analisis dan pengambilan keputusan secara lebih efektif di bidang kesehatan.

2.1 Ketersediaan Data

Data kasus yang digunakan dalam penelitian ini bersumber dari dokumentasi rekam medis nyeri kepala. Sistem ini menggunakan 40 kasus dari 2 jenis kasus sakit kepala, yakni Cluster headache syndrome dengan kode ICD X "G44.0" dan Tension-type headache dengan kode ICD X "G44.2", dengan masing-masing jenis kasus sakit kepala sejumlah 20 kasus. Kategori gejala, kode gejala, dan kode kebalikan gejala yang digunakan dalam dataset berdasarkan ICD-10 disajikan pada Tabel 3 dalam Lampiran.

Dalam eksperimen ini, data yang digunakan sebagai dataset adalah dataset sejumlah 40 data dan dataset sesudah proses augmentasi sejumlah 440 data. Proses augmentasi dilakukan untuk meningkatkan kualitas dan jumlah data yang lebih beragam sekaligus mempertahankan karakteristik data asli. Hal ini dilakukan agar dataset lebih bersifat representatif terhadap dunia nyata (Gao et al., 2025).

2.2 Alur Eksperimen

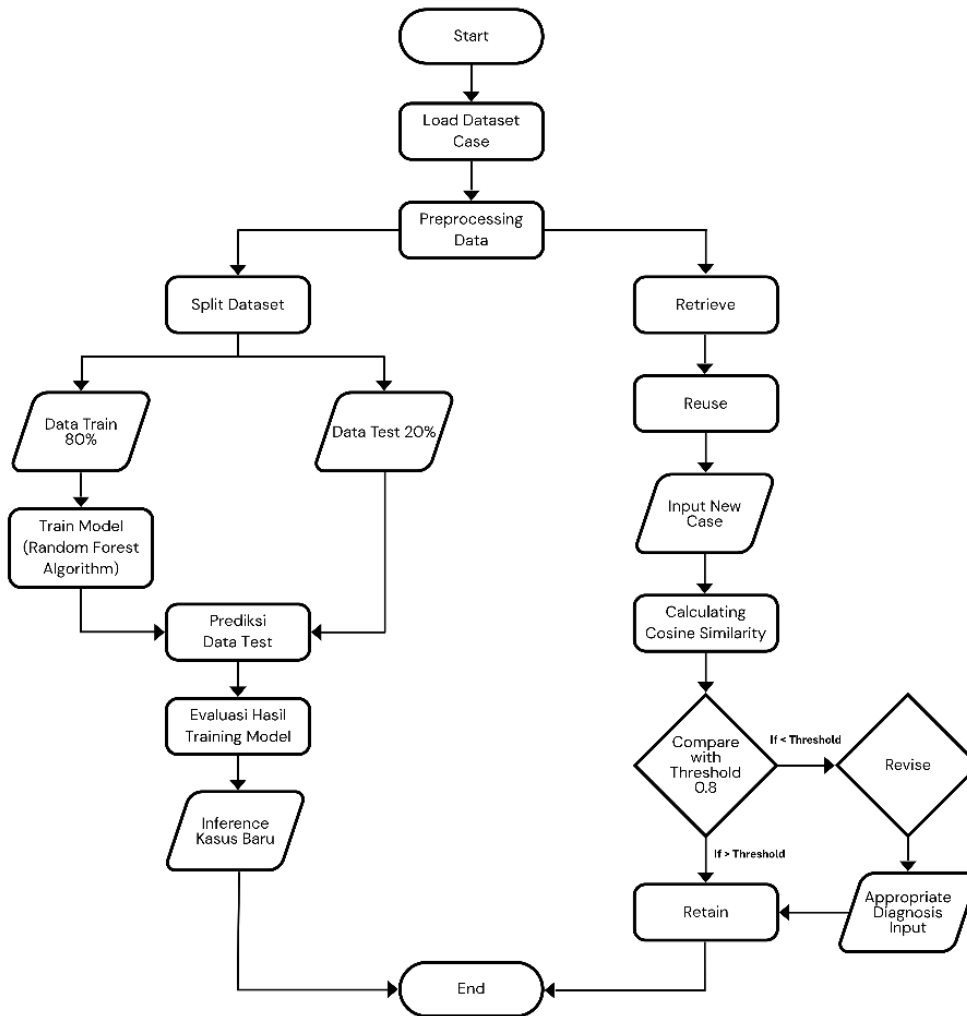
Alur eksperimen yang akan dilakukan pada studi ini disajikan dalam Gambar 1. Proses kerja sistem ini diawali dengan memuat dataset kasus sebagai sumber basis pengetahuan awal bagi model sistem yang dibangun. Setelah berhasil dimuat, data tersebut melalui tahapan pra-proses. Pada tahap ini, data menjalani proses pembersihan informasi yang tidak relevan dan normalisasi untuk meningkatkan akurasi dan kualitas data sehingga siap untuk diolah lebih lanjut [28]. Tak hanya itu, tahap ini sangat krusial untuk memastikan hasil yang konsisten dari sistem ketika menggunakan dataset [29]. Setelah data siap, alur kerja kombinasi dilakukan secara paralel, yakni permodelan machine learning NLP dan Case-Based Reasoning.

Pada jalur permodalan machine learning NLP, dataset yang digunakan dibagi menjadi 80% data latih dan 20% data uji. Hal ini dilakukan berdasarkan penelitian yang telah dilakukan oleh Yang et al. (2025) bahwa pembagian data latih dan data uji mempengaruhi keberhasilan (Yang et al., 2025). Data latih kemudian dipakai untuk melatih model dengan algoritma Random Forest. Algoritma Forest dipilih karena memiliki keunggulan menghasilkan hasil yang signifikan, akurasi yang lebih tinggi, dan kerentanan yang lebih rendah terhadap overfitting dibanding algoritma lain (Guadarrama Rios et al., 2025). Dari banyaknya keunggulan algoritma Random Forest, kecocokannya dalam mengatasi masalah klasifikasi dan pengambilan keputusan yang efisien dalam dunia bidang kesehatan dan kedokteran menjadi alasan utama dalam studi ini (C et al., 2023) (Zhu et al., 2021). Setelah model selesai dilatih, kinerjanya diuji dengan melakukan prediksi pada data uji dan dievaluasi hasilnya untuk mengetahui performa model. Model yang telah tervalidasi ini kemudian digunakan untuk melakukan inferensi atau prediksi terhadap kasus-kasus baru dengan menampilkan hasil prediksi dan akurasi sebagai output.

Sementara itu, jalur lain menerapkan pendekatan Case-Base Reasoning (CBR) yang berfokus pada penyelesaian masalah dengan merujuk pada kasus-kasus serupa di masa lalu. Prosesnya dimulai dengan mengambil (Retrieve) kasus lama yang relevan. Lalu menggunakan kembali (Reuse) kasus tersebut sebagai solusi acuan. Selanjutnya, pengguna diminta memasukkan kasus baru yang ingin diselesaikan. Sistem akan menghitung tingkat kemiripan antara kasus baru dan kasus lama yang diambil dengan teknik Cosine Similarity. Teknik Cosine Similarity mengukur kesamaan antar kasus dengan melihat tingkat kemiripan yang tinggi (Dai, 2025).



Langkah krusial berikutnya pada jalur CBR adalah proses pengambilan keputusan berdasarkan hasil perhitungan Cosine Similarity. Nilai akan dibandingkan dengan ambang batas (threshold) yang telah ditetapkan, yakni 0,8. Jika nilai hasil Cosine Similarity lebih besar atau sama dengan nilai threshold, kasus tersebut dianggap cukup mirip sehingga solusinya dapat langsung diadopsi dan disimpan (Retain) ke dalam basis pengetahuan. Sebaliknya, jika nilai dibawah threshold, sistem akan masuk ke proses perbaikan (Revise) untuk melakukan penyesuaian dengan memasukkan diagnosis yang sesuai. Setelah diperbaiki, kasus baru yang telah berhasil diselesaikan ini juga akan disimpan (Retain). Kedua jalur proses ini pada akhirnya akan bertemu di titik "End" menandakan alur eksperimen ini selesai.



Gambar 1 Alur Eksperimen


3. HASIL DAN PEMBAHASAN

Proses eksperimental diawali dengan persiapan dataset hasil augmentasi. Dataset tersebut digunakan untuk melatih model klasifikasi NLP dengan menggunakan algoritma Random Forest (FR). Model ini dilatih agar dapat membedakan antara dua kelas diagnosis penyakit nyeri kepala, yakni G44.0 dan G44.2. Kinerja model dievaluasi menggunakan data uji yang menghasilkan Confusion Matrix seperti yang ditunjukkan pada Gambar 2. Dari matrix tersebut, terlihat bahwa model berhasil memprediksi 27 kasus G44.0 dengan tepat dan 34 kasus G44.2 dengan tepat.



Namun, terjadi kesalahan klasifikasi di mana model salah memprediksi 22 kasus yang seharusnya G44.0 sebagai G44.2, dan 5 kasus yang seharusnya G44.2 sebagai G44.0.

Berdasarkan *classification report* pada Tabel 1, model mencapai akurasi keseluruhan sebesar 69%. Untuk label G44.0, model berhasil memiliki presisi yang tinggi (0.84). Hal ini berarti saat model memprediksi G44.0, prediksinya cenderung tepat. Namun recall menunjukkan tingkat yang lebih rendah (0.55), menandakan model hanya mampu mengidentifikasi 55% dari seluruh label G44.0 yang sebenarnya. Sebaliknya, untuk label G44.2, model menunjukkan recall yang sangat baik (0.87) tetapi dengan presisi yang lebih rendah (0.61). Hal ini mengidentifikasi bahwa model dapat memprediksi sebagai besar kasus G44.2, tetapi terkadang salah melabeli kasus lain sebagai G44.2.



Gambar 2 Hasil Confusion Matrix Dataset Augmentasi

Tabel 1 Klasifikasi Dataset Augmentasi

	Precision	Recall	F1-Score	Support
G44.0	0.84	0.55	0.67	49
G44.2	0.61	0.87	0.72	39
Accuracy			0.69	88
Macro Avg	0.73	0.71	0.69	88
Weighted Avg	0.74	0.69	0.69	88


Pada tahap inferensi untuk kasus baru, sistem bekerja secara parallel; baik model NLP maupun CBR memberikan hasil prediksi yang bersifat probabilistik. Alur proses dalam kasus seperti ini, di mana kasus baru didiagnosis sebagai G44.0 dengan tingkat keyakinan hingga 96%. Secara paralel, sistem CBR melakukan proses Retrieve untuk mencari kasus serupa dalam dataset. Hasilnya menunjukkan bahwa CBR menemukan kasus-kasus lama yang didiagnosis G44.0 dengan kemiripan (*similarity*) tertinggi hingga 0.82. Tingkat kemiripan melampaui threshold 0.8 sehingga sistem otomatis masuk ke tahap Retain untuk menyimpan kasus baru dan solusinya ke dalam dataset sehingga dapat digunakan sebagai basis pengambilan keputusan.

Sebagai perbandingan dan untuk menetapkan hasil kinerja dasar (*baseline*), pengujian juga dilakukan menggunakan dataset asli tanpa proses augmentasi. Tahapan eksperimen yang dilakukan serupa, tetapi hanya sebatas pada model NLP dengan algoritma Random Forest. Tujuan dari pengujian ini adalah untuk melihat sejauh mana model dapat belajar dan melakukan klasifikasi pada data-data yang jumlahnya terbatas. Model yang dilatih secara keseluruhan mencapai akurasi sebesar 62%. Analisis mendalam terlihat pada Gambar 3 dalam bentuk Confusion Matrix. Confusion Matrix menunjukkan bahwa dari total 8 data uji, model berhasil mengklasifikasikan 3 kasus G44.0 dan 2 kasus G44.2 dengan benar. Namun, terjadi kesalahan



klasifikasi di mana 2 kasus G44.0 salah diprediksi sebagai G44.2 dan 1 kasus G44.2 salah diprediksi sebagai G44.0.

Classification report disajikan pada Tabel 2 untuk menunjukkan performa berdasarkan label kasus G44.0 dan G44.2. Model menunjukkan bahwa tingkat presisi mencapai 0.75, namun dengan recall yang lebih rendah, yaitu 0.60. Sebaliknya, untuk kelas G44.2, tingkat presisi yang dihasilkan lebih rendah, yaitu 0.50, namun recall-nya lebih baik, sebesar 0.67. Kinerja ini menegaskan bahwa tanpa proses augmentasi data, kemampuan model untuk belajar dan melakukan generalisasi secara akurat cukup terbatas, sehingga hasil ini menjadi acuan penting dalam menilai efektivitas teknik augmentasi pada tahap selanjutnya.



Gambar 3 Hasil Confusion Matrix Dataset Tanpa Proses Augmentasi

Tabel 2 Klasifikasi Dataset Tanpa Proses Augmentasi

	Precision	Recall	F1-Score	Support
G44.0	0.75	0.60	0.67	5
G44.2	0.50	0.67	0.57	3
Accuracy			0.62	8
Macro Avg	0.62	0.63	0.62	8
Weighted Avg	0.66	0.62	0.63	8

4. KESIMPULAN

Studi ini menunjukkan bahwa model kombinasi NLP-CBR mampu memberikan kontribusi dalam bidang kesehatan dan kedokteran dalam pengambilan keputusan. Hal ini ditunjukkan dengan kemampuan model dalam memprediksi kasus baru berdasarkan pengetahuan dari rekam medis. Hal ini ditunjukkan dengan dengan hasil eksperimen dengan data augmentasi secara signifikan meningkatkan kemampuan klasifikasi dengan tingkat akurasi meningkat dari 62% menjadi 69%. Model yang dilatih dengan dataset augmentasi menunjukkan presisi tinggi untuk label G44.0 dengan tingkat 0.84 dan recall tinggi untuk label G44.2 dengan tingkat 0.87. Tingkat keberhasilan ini mencerminkan peningkatan dalam kemampuan model untuk mengenali pola kasus secara lebih seimbang. Selain itu, sistem CBR turut memperkuat proses diagnosis dengan tingkat similarity kasus hingga 0.82, kemampuan Retain sebagai upaya pembelajaran berkelanjutan.

DAFTAR PUSTAKA

Amin, K., Kapetanakis, S., Polatidis, N., Althoff, K.-D., & Dengel, A. (2020). DeepKAF: A Heterogeneous CBR Deep Learning Approach for NLP Prototyping. In M. Ivanovic, T. Yildirim, G. Trajcevski, C. Badica, L. Bellatreche, I. Kotenko, A. Badica, B. Erkmén, & M. Savic (Eds.), INISTA 2020 - 2020 International Conference on INnovations in Intelligent



- SysTems and Applications, Proceedings. Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/INISTA49547.2020.9194679>
- Ardiansyah, A., Ferdiana, R., & Permanasari, A. E. (2022). Optimizing complexity weight parameter of use case points estimation using particle swarm optimization. *International Journal of Advances in Intelligent Informatics*, 8(2), 165. <https://doi.org/10.26555/ijain.v8i2.811>
- C, L., S, P., Kashyap, A. H., Rahaman, A., Niranjana, S., & Niranjana, V. (2023). Novel Biomarker Prediction for Lung Cancer Using Random Forest Classifiers. *Cancer Informatics*, 22. <https://doi.org/10.1177/11769351231167992>
- Canizales-Martinez, J. P., Ochoa-Zezzatti, A., & Villar-Patiño, C. (2025). Alarm Recommendation Intelligent System for Multilayer Ceramic Capacitor (MLCC) Electroplating Using Case-Based Reasoning and Natural Language Processing. *Lecture Notes in Computer Science*, 15464 LNAI, 248–271. https://doi.org/10.1007/978-3-031-83879-8_18
- Caro-Martínez, M., Recio-García, J. A., Díaz-Agudo, B., Darias, J. M., Wiratunga, N., Martin, K., Wijekoon, A., Nkisi-Orji, I., Corsar, D., Pradeep, P., Bridge, D., & Liret, A. (2024). iSee: A case-based reasoning platform for the design of explanation experiences. *Knowledge-Based Systems*, 302. <https://doi.org/10.1016/j.knosys.2024.112305>
- Dai, Z. (2025). Analysis of college students' physical education learning effect and quality based on text data fusion. *Advances in Continuous and Discrete Models*, 2025(1), 64. <https://doi.org/10.1186/s13662-025-03925-9>
- Dissing, K. B., Jensen, R. K., Christensen, H. W., Jensen, M. E., & Lauridsen, H. H. (2025). Development and preliminary validation of the Danish headache questionnaire. *Chiropractic and Manual Therapies*, 33(1). <https://doi.org/10.1186/s12998-025-00573-4>
- Ezzat, M. (2020). A Framework for a Comprehensive Conceptualization of Urban Constructs. In D. Holzer, W. Nakapan, A. Globa, & I. Koh (Eds.), *RE: Anthropocene, Design in the Age of Humans - Proceedings of the 25th International Conference on Computer-Aided Architectural Design Research in Asia, CAADRIA 2020 (Vol. 2, pp. 111–120)*. The Association for Computer-Aided Architectural Design Research in Asia (CAADRIA). <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85091286980&partnerID=40&md5=6481b239274ce5a522c91a20a662588e>
- Feng, Z., Hu, G., Li, B., & Wang, J. (2025). Unleashing the power of ChatGPT in finance research: opportunities and challenges. *Financial Innovation*, 11(1). <https://doi.org/10.1186/s40854-025-00770-3>
- Galanis, N.-I., & Papakostas, G. A. (2022). An update on cooking recipe generation with Machine Learning and Natural Language Processing. In G. S. Tomar & J. Bansal (Eds.), *Proceedings - 2022 IEEE World Conference on Applied Intelligence and Computing, AIC 2022 (pp. 739–744)*. Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/AIC55036.2022.9848929>
- Gao, J., Giunchiglia, F., Zhao, T., Zhao, X., Li, C., & Xu, H. (2025). Oracle bone heritage data augmentation based on two-stage decomposition GANs. *Npj Heritage Science*, 13(1), 230. <https://doi.org/10.1038/s40494-025-01774-z>
- García-Azorín, D., Farid-Zahran, M., Gutiérrez-Sánchez, M., González-García, M. N., Guerrero, A. L., & Porta-Etessam, J. (2020). Tension-type headache in the Emergency Department Diagnosis and misdiagnosis: The TEDDi study. *Scientific Reports*, 10(2446). <https://doi.org/10.1038/s41598-020-59171-4>
- Guadarrama Rios, M., Zamberlan, F., Mavromoustakos Blom, P., & Rankovic, N. (2025). Knowing our choices: unveiling true voting patterns through machine learning (ML) and natural language processing (NLP) in European Parliament. *Social Network Analysis and Mining*, 15(1), 24. <https://doi.org/10.1007/s13278-025-01452-9>
- Hadj-Mabrouk, H. (2024). A literature review on the applications of artificial intelligence to European rail transport safety. *IET Intelligent Transport Systems*, 18(12), 2291–2324. <https://doi.org/10.1049/itr2.12587>
- Jeong, M., Sohn, J., Sung, M., & Kang, J. (2024). Improving medical reasoning through retrieval and self-reflection with retrieval-augmented large language models. *Bioinformatics*, 40, i119–i129. <https://doi.org/10.1093/bioinformatics/btae238>



- Kawazoe, Y., Tsuchiya, M., Shimamoto, K., Seki, T., Shinohara, E., Yada, S., Wakamiya, S., Imai, S., Aramaki, E., & Hori, S. (2025). Natural language processing of electronic medical records identifies cardioprotective agents for anthracycline induced cardiotoxicity. *Scientific Reports*, 15(1). <https://doi.org/10.1038/s41598-025-91187-6>
- Krüger, M. (2023). Comparative Analysis of Text-Based CBR Algorithms for Cybercrime Profiling Investigations. In M. Leyer, M. Leyer, & J. Wichmann (Eds.), *CEUR Workshop Proceedings* (Vol. 3630, pp. 347–358). CEUR-WS. <https://www.scopus.com/inward/record.uri?eid=2-s2.085184664902&partnerID=40&md5=6dac1b71a0fc6238fca3c06405478c6b>
- Mourid, M. R., Oweidat, M., Okesanya, O. J., Abady, E. M. A., Deeba, F., Oboli, V. N., & Alsabri, M. (2025). Pediatric Headache Management in the Emergency Department: A Review of Challenges and Solutions. *Current Treatment Options in Pediatrics*, 11(1). <https://doi.org/10.1007/s40746-025-00325-9>
- Mulyana, S., Hartati, S., Wardoyo, R., & Subandi. (2021). Utilizing natural language processing in case-based reasoning for diagnosing and managing schizophrenia disorder. *ICIC Express Letters*, 15(10), 1083–1091. <https://doi.org/10.24507/icicel.15.10.1083>
- Mulyanto, A., Hartati, S., & Wardoyo, R. (2024). An Integrated Model Of Natural Language Processing Technique And Case-Based Reasoning For Supporting Study Program Accreditation. *ICIC Express Letters*, 18(7), 749–757. <https://doi.org/10.24507/icicel.18.07.749>
- Naqvi, S. M. R., Ghufran, M., Meraghni, S., Varnier, C., Nicod, J.-M., & Zerhouni, N. (2022). CBR-Based Decision Support System for Maintenance Text Using NLP for an Aviation Case Study. In C. Li, G. Valentino, L. Kang, D. Cabrera, & D. Gjorgjevikj (Eds.), *Proceedings - 2022 Prognostics and Health Management Conference, PHM-London 2022* (pp. 344–349). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/PHM2022-London52454.2022.00067>
- Qiu, J., Zhu, T., Qin, K., & Zhang, W. (2025). The interaction network and potential clinical effectiveness of dimensional psychopathology phenotyping based on EMR: a Bayesian network approach. *BMC Psychiatry*, 25(1). <https://doi.org/10.1186/s12888-025-06510-2>
- Rybinski, K. (2022). Assessing how QAA accreditation reflects student experience. *Higher Education Research & Development*, 41(3), 898–918. <https://doi.org/10.1080/07294360.2021.1872058>
- Silva, H., António, N., & Bacao, F. (2022). A Rapid Semi-automated Literature Review on Legal Precedents Retrieval. In G. Marreiros, B. Martins, A. Paiva, A. Sardinha, & B. Ribeiro (Eds.), *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*: 13566 LNAI (pp. 53–65). Springer Science and Business Media Deutschland GmbH. https://doi.org/10.1007/978-3-031-16474-3_5
- Tripakornkusol, V., Sinsopa, N., Khamsai, S., & Sawanyawisuth, K. (2025). Phenotypes of headache in patients with obstructive sleep apnea. *Scientific Reports*, 15(1), 4806. <https://doi.org/10.1038/s41598-025-89538-4>
- Venkatesh Raja, K., Siddharth, R., Yuvaraj, S., & Ramesh Kumar, K. A. (2024). An Artificial Intelligence based automated case-based reasoning (CBR) system for severity investigation and root-cause analysis of road accidents – Comparative analysis with the predictions of ChatGPT. *Journal of Engineering Research*, 12(4), 895–903. <https://doi.org/https://doi.org/10.1016/j.jer.2023.09.019>
- Villena, F., Bravo-Marquez, F., & Dunstan, J. (2025). NLP modeling recommendations for restricted data availability in clinical settings. *BMC Medical Informatics and Decision Making*, 25(1), 116. <https://doi.org/10.1186/s12911-025-02948-2>
- Wang, H., Meng, X., & Zhu, X. (2022). Improving knowledge capture and retrieval in the BIM environment: Combining case-based reasoning and natural language processing. *Automation in Construction*, 139. <https://doi.org/10.1016/j.autcon.2022.104317>
- Wu, Y., Xie, H., Gu, L., Chen, R., Chen, S., Wang, F., Liu, Y., Chen, L., & Tang, J. (2024). Advancing Mental Health Care: Intelligent Assessments and Automated Generation of Personalized Advice via M.I.N.I and RoBERTa. *Applied Sciences (Switzerland)*, 14(9447). <https://doi.org/10.3390/app14209447>
- Yang, B., Lu, W., Xuan, Y., Hao, C., & Huang, X. (2025). The influences of social support



expressed from doctors and disclosed from peers on patient decision-making: an analysis from the online health community. *Scientific Reports*, 15(1), 2703. <https://doi.org/10.1038/s41598-024-85023-6>

Zhao, Y., Yi, Y., Zhou, H., Pang, Q., & Wang, J. (2025). The burden of migraine and tension-type headache in Asia from 1990 to 2021. *Journal of Headache and Pain*, 26(1). <https://doi.org/10.1186/s10194-025-01990-9>

Zhu, Y., Duan, J., & Wu, T. (2021). Animal fiber imagery classification using a combination of random forest and deep learning methods. *Journal of Engineered Fibers and Fabrics*, 16. <https://doi.org/10.1177/15589250211009333>



LAMPIRAN

Tabel 3 Data Gejala Berdasarkan ICD X

Category	Code	Symptoms	Reverse Code
Headache	G0	Headache	XG0
Type of Headache	G11	Pulsatile	XG11
	G12	Feels Tight	XG12
	G13	Severe	XG13
	G14	Feels Achy	XG14
	G15	Being Tight	XG15
	G16	Feels Like Being Stabbed	XG16
	G17	Nighttime Headaches	XG17
	G18	Headache That Wakes You Up from Sleep	XG18
Location of Headache	G21	Bilateral Headache-	XG21
	G22	Diffuse headache	XG22
	G23	Sided/Unilateral Headache	XG23
	G24	Periorbital Headache	XG24
Onset of Headache	G31	Intermittent	XG31
	G32	Continuous	XG32
	G33	Gradual	XG33
	G34	Recurring	XG34
	G35	Sudden	XG35
Intensity of Headache	G41	Mild	XG41
	G42	Moderate	XG42
	G43	Severe	XG43
Headache Duration	G51	30 Minutes To 1 Week	XG51
	G52	4-72 Hours	XG52
	G53	15-180 Minutes	XG53
Accompanyin Symptoms	G61	Nauseous	XG61
	G62	Vomiting	XG62
	G63	Anorexia	XG63
	G64	Photophobia	XG64
	G65	Phonophobia	XG65
	G66	Psychological	XG66
	G67	Mood Changes	XG67
	G68	Sleep Disorders	XG68
	G69	Reddish Eyes	XG69
	G610	Watery Eyes	XG610
	G611	Nasal Nose	XG611
	G612	Runny nose (Rhinorrhea)	XG612
	G613	Sweaty Forehead	XG613
	G614	Shoulder Stiffness	XG614
Aggravating/Relieving Factors	G71	Aggravated By Physical Activity	XG71
	G72	Improves After Rest	XG72
	G73	Interfere With Daily Activities	XG73
Spreading Location of Headache	G81	From The Back of the Neck	XG81
	G82	From Forehead	XG82
Trigger Factors	G91	Psychological Distress	XG91
Other Symptoms	O	Other Symptoms	O
Other Text	T	Other Text	T

