

## PENERAPAN METODE *LIGHT GRADIENT BOOSTING MACHINE* (*LIGHTGBM*) DALAM KLASIFIKASI JENIS PENYAKIT ASAM LAMBUNG BERDASARKAN GEJALA

Nur Fadillah Sari<sup>1\*</sup>, Chyquitha Danu Putri<sup>2</sup>, Fahrिम Irhamna Rachman<sup>3</sup>

<sup>1,2,3</sup> Universitas Muhammadiyah Makassar

[105841110422@student.unismuh.ac.id](mailto:105841110422@student.unismuh.ac.id), [chyquithadanuputri@unismuh.ac.id](mailto:chyquithadanuputri@unismuh.ac.id),

[Fachrim141020@unismuh.ac.id](mailto:Fachrim141020@unismuh.ac.id)

\* Corresponding Author

Received: 03-06- 2026

Revised: 15-06-2026

Approved: 25-06-2026

### ABSTRAK

Penyakit asam lambung merupakan gangguan pencernaan yang memiliki gejala saling menyerupai pada beberapa jenis penyakit, khususnya *Dispepsia*, *Gastroesophageal Reflux Disease (GERD)*, dan *Gastritis*. Kesamaan gejala tersebut dapat menyulitkan identifikasi awal sehingga diperlukan pendekatan klasifikasi berbasis data. Penelitian ini menerapkan metode *Light Gradient Boosting Machine (LightGBM)* untuk mengklasifikasikan jenis penyakit asam lambung berdasarkan data gejala pasien RSUD Daya Kota Makassar. Dataset yang digunakan berjumlah 976 data pasien dengan 19 atribut gejala dan tiga kelas diagnosis. Tahapan penelitian meliputi *preprocessing*, transformasi nilai gejala menjadi numerik, *label encoding* diagnosis, pembagian data latih dan data uji, pelatihan model *LightGBM*, serta evaluasi menggunakan *accuracy*, *precision*, *recall*, *F1-score*, *confusion matrix*, dan *feature importance*. Model menggunakan konfigurasi default *LGBMClassifier* tanpa proses *hyperparameter tuning*. Hasil pengujian menunjukkan bahwa skenario utama 80:20 menghasilkan *accuracy* 88,78%, *precision* 88,93%, *recall* 88,78%, dan *F1-score* 88,81%, sedangkan skenario 90:10 memperoleh *accuracy* tertinggi sebesar 89,80%. Fitur paling berpengaruh adalah mual, diare, muntah, anemia, dan gangguan tidur. Hasil ini menunjukkan bahwa *LightGBM* efektif sebagai model pendukung identifikasi awal jenis penyakit asam lambung berdasarkan gejala pasien.

**Kata Kunci:** Gejala Pasien, Klasifikasi, *LightGBM*, Penyakit Asam Lambung, Rekam Medis.

### PENDAHULUAN

Gangguan saluran cerna bagian atas memiliki beban kesehatan yang luas. Meta-analisis global memperkirakan prevalensi *Gastroesophageal Reflux Disease (GERD)* sebesar 13,98% atau sekitar 1,03 miliar orang, sedangkan studi epidemiologi Rome IV pada 26 negara melaporkan prevalensi *dispepsia fungsional* sebesar 7,2% [1], [2]. Besarnya prevalensi tersebut menegaskan pentingnya identifikasi awal yang akurat. Keluhan seperti nyeri ulu hati, sensasi terbakar di dada, mual, muntah, perut kembung, rasa pahit pada mulut, dan kesulitan menelan dapat mengganggu aktivitas harian serta meningkatkan kebutuhan pelayanan kesehatan apabila berlangsung berulang [3]–[5].

Istilah penyakit asam lambung dalam penelitian ini mencakup tiga kelas diagnosis yang ditemukan pada dataset, yaitu *Dispepsia*, *GERD*, dan *Gastritis*. *Dispepsia* merupakan kumpulan gejala saluran cerna atas berupa nyeri atau rasa tidak nyaman pada epigastrium. *GERD* berkaitan dengan refluks isi lambung ke esofagus dan umumnya ditandai *heartburn* serta regurgitasi. *Gastritis* merupakan inflamasi mukosa lambung yang dapat disertai mual, muntah, nyeri epigastrium, dan rasa tidak nyaman setelah makan [3]–[5].

Persoalan utama dalam identifikasi awal ketiga kondisi tersebut adalah tumpang tindih gejala. Pasien dengan Dispepsia, GERD, dan Gastritis dapat sama-sama mengalami mual, kembung, nyeri epigastrium, penurunan nafsu makan, dan gangguan tidur. Jika penilaian awal hanya bertumpu pada satu atau dua keluhan, kemiripan pola tersebut dapat meningkatkan risiko salah klasifikasi. Oleh karena itu, diperlukan pendekatan yang mampu mempelajari kombinasi antargejala secara sistematis sebagai pendukung keputusan klinis, tanpa menggantikan pemeriksaan dokter.

Perkembangan machine learning memungkinkan pembentukan model prediktif dari data kesehatan berlabel. Dalam supervised learning, algoritma mempelajari hubungan antara fitur input dan kelas diagnosis berdasarkan data historis. Teknik klasifikasi relevan untuk penelitian ini karena setiap pasien direpresentasikan oleh kombinasi 19 gejala biner yang dapat membentuk pola nonlinier dan interaksi antarfitur.

Penelitian terdahulu telah menggunakan sistem pakar berbasis Certainty Factor dan algoritma pohon keputusan C4.5 untuk membantu diagnosis penyakit lambung [6]–[9]. Pendekatan berbasis aturan berguna ketika pengetahuan pakar telah dirumuskan secara eksplisit, tetapi performanya bergantung pada kelengkapan aturan dan bobot keyakinan. Pohon keputusan tunggal relatif mudah diinterpretasikan, namun lebih rentan terhadap variasi data dan dapat kurang stabil ketika pola antargejala semakin kompleks. Kondisi tersebut membuka ruang bagi algoritma ensemble yang menggabungkan banyak pohon.

Light Gradient Boosting Machine (LightGBM) merupakan implementasi Gradient Boosting Decision Tree yang menggunakan pembentukan histogram untuk mengurangi biaya pencarian titik pemisah dan strategi pertumbuhan leaf-wise atau best-first. Berbeda dengan pertumbuhan level-wise yang mengembangkan seluruh simpul pada kedalaman yang sama, LightGBM memilih daun dengan penurunan loss terbesar. Pada jumlah daun yang sama, strategi ini cenderung menghasilkan loss lebih rendah, sedangkan penelitian awal LightGBM melaporkan percepatan pelatihan hingga lebih dari 20 kali dibanding GBDT konvensional dengan akurasi yang hampir sama [10]. Dalam data medis tabular, LightGBM juga telah menunjukkan performa kompetitif dibanding sejumlah algoritma klasifikasi klasik [11]. Meskipun demikian, pertumbuhan leaf-wise berisiko overfitting pada dataset yang terbatas, sehingga jumlah daun, kedalaman pohon, dan validasi model perlu dikendalikan secara hati-hati.

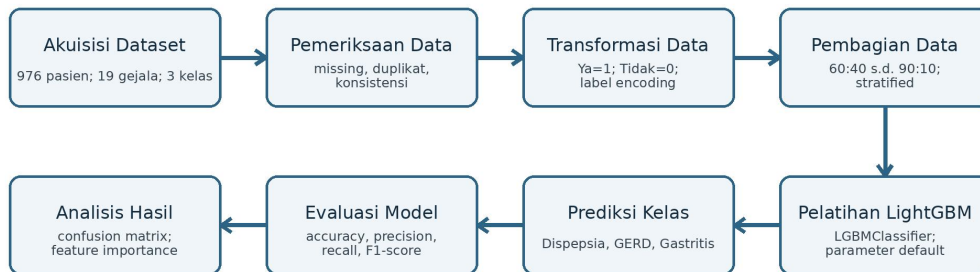
Berdasarkan permasalahan tersebut, penelitian ini bertujuan menerapkan LightGBM untuk mengklasifikasikan Dispepsia, GERD, dan Gastritis berdasarkan 19 variabel gejala pasien. Kontribusi penelitian meliputi evaluasi beberapa skenario pembagian data, analisis pola kesalahan melalui confusion matrix, serta identifikasi gejala dominan melalui feature importance. Hasil penelitian diharapkan menjadi dasar pengembangan sistem pendukung identifikasi awal penyakit lambung berbasis data.

## **METODE PENELITIAN**

Penelitian ini menggunakan pendekatan kuantitatif berbasis machine learning untuk membangun model klasifikasi jenis penyakit lambung. Data bersumber dari gejala pasien RSUD Daya Kota Makassar yang telah dianonimkan sehingga tidak

memuat identitas pribadi. Dataset terdiri atas 976 pasien, 19 variabel gejala sebagai fitur input, dan satu variabel diagnosis sebagai target. Kelas target meliputi Dispepsia, GERD, dan Gastritis. Alur sistem penelitian ditunjukkan pada Gambar 1.

**ALUR SISTEM PENELITIAN**



Gambar 1. Diagram alur sistem penelitian

Setiap variabel gejala berbentuk kategorikal Ya dan Tidak. Nilai tersebut ditransformasikan menjadi numerik, yaitu Ya = 1 dan Tidak = 0. Diagnosis pasien dikodekan melalui label encoding menjadi tiga kelas target. Transformasi dilakukan agar seluruh atribut dapat diproses oleh LGBMClassifier.

Preprocessing mencakup pemeriksaan missing value, data duplikat, konsistensi nama kolom, serta keseragaman nilai gejala dan diagnosis. Penelitian hanya menggunakan gejala yang tercantum dalam dataset dan tidak memasukkan variabel demografis, hasil laboratorium, endoskopi, pengobatan, atau riwayat penyakit. Pembatasan ini perlu dipertimbangkan ketika menafsirkan performa model.

Tabel 1. Daftar fitur gejala yang digunakan dalam penelitian

No.	Fitur Gejala	No.	Fitur Gejala
1	Mual	11	Diare
2	Muntah	12	Sakit Tenggorokan
3	Nyeri Dada	13	Regurgitasi
4	Kembung	14	Suara Serak
5	Demam	15	Gangguan Tidur
6	Susah Menelan	16	Penurunan Berat Badan
7	Nafsu Makan Turun	17	Anemia
8	Perut Berat	18	Heartburn
9	Cepat Kenyang	19	Nyeri Epigastrium
10	Mulut Terasa Pahit	-	-

Data dibagi menjadi data latih dan data uji melalui empat skenario, yaitu 60:40, 70:30, 80:20, dan 90:10. Pembagian dilakukan secara stratified agar proporsi setiap kelas tetap terjaga, dengan random\_state = 42 untuk meningkatkan keterulangan eksperimen. Skenario 80:20 ditetapkan sebagai skenario utama karena memberikan keseimbangan antara jumlah data pelatihan dan ukuran data uji, sedangkan skenario lainnya digunakan untuk menilai kestabilan performa.

Model dibangun menggunakan LGBMClassifier dengan `boosting_type = gbdt` dan `objective = multiclass`. Penelitian ini tidak melakukan GridSearch, RandomizedSearch, maupun Bayesian Optimization; parameter utama mengikuti konfigurasi default pustaka LightGBM, sebagaimana diringkas pada Tabel 2. Model membangun sejumlah decision tree secara bertahap dan memperbaiki residual kesalahan pada setiap iterasi. Feature importance dihitung menggunakan `importance_type = split`, sehingga nilainya menunjukkan frekuensi sebuah fitur digunakan untuk membentuk pemisahan pada seluruh pohon, bukan arah hubungan atau besarnya efek klinis.

Tabel 2. Konfigurasi utama model LightGBM

Parameter	Nilai	Keterangan
Estimator	LGBMClassifier	Klasifikasi multikelas
<code>boosting_type</code>	<code>gbdt</code>	Gradient boosting decision tree
<code>objective</code>	<code>multiclass</code>	Tiga kelas diagnosis
<code>num_leaves</code>	31	Nilai default
<code>max_depth</code>	-1	Tanpa batas eksplisit
<code>learning_rate</code>	0,1	Nilai default
<code>n_estimators</code>	100	Jumlah boosting iteration
<code>min_child_samples</code>	20	Minimum data pada daun
<code>subsample</code>	1,0	Seluruh observasi digunakan
<code>colsample_bytree</code>	1,0	Seluruh fitur digunakan
<code>reg_alpha / reg_lambda</code>	0,0 / 0,0	Tanpa regularisasi tambahan
<code>importance_type</code>	<code>split</code>	Frekuensi fitur digunakan pada split
Hyperparameter tuning	Tidak dilakukan	Konfigurasi default

Evaluasi model menggunakan accuracy, precision, recall, dan F1-score dengan pendekatan multiclass weighted average. Accuracy menunjukkan proporsi prediksi benar, precision menggambarkan ketepatan prediksi kelas, recall menunjukkan kemampuan menemukan data aktual pada setiap kelas, sedangkan F1-score merupakan rata-rata harmonik precision dan recall. Confusion matrix digunakan untuk menganalisis pola salah klasifikasi, sedangkan feature importance digunakan untuk mengidentifikasi fitur yang paling sering berkontribusi dalam pemisahan pohon.

Tabel 3. Skenario pembagian data latih dan data uji

Skenario	Data Training	Data Testing	Jumlah Training	Jumlah Testing
60:40	60%	40%	585	391

Skenario	Data Training	Data Testing	Jumlah Training	Jumlah Testing
70:30	70%	30%	683	293
80:20	80%	20%	780	196
90:10	90%	10%	878	98

## HASIL DAN PEMBAHASAN

Dataset penelitian terdiri atas 976 data pasien dengan distribusi kelas yang relatif seimbang. Kelas GERD memiliki jumlah data paling banyak, yaitu 333 data atau 34,1%, diikuti Gastritis sebanyak 325 data atau 33,3%, dan Dispepsia sebanyak 318 data atau 32,6%. Distribusi yang relatif merata ini membantu proses pelatihan model karena setiap kelas memperoleh representasi data yang cukup sehingga risiko dominasi kelas tertentu dapat dikurangi.

Tabel 4. Distribusi jumlah pasien berdasarkan kelas penyakit

Kelas Penyakit	Jumlah Pasien	Persentase
Dispepsia	318	32,6%
GERD	333	34,1%
Gastritis	325	33,3%
Total	976	100%

Hasil preprocessing menunjukkan bahwa dataset dapat digunakan untuk pelatihan model tanpa memerlukan penanganan nilai kosong atau duplikasi data. Data gejala telah diseragamkan menjadi format numerik sehingga setiap atribut memiliki nilai biner. Tahapan ini penting karena kesalahan format pada data kesehatan dapat menyebabkan model membaca kategori secara tidak konsisten dan memengaruhi hasil prediksi. Dengan data yang bersih, proses pelatihan dapat difokuskan pada hubungan antara kombinasi gejala dan diagnosis.

Tabel 5. Ringkasan hasil preprocessing data

Tahap Preprocessing	Hasil
Pemeriksaan missing value	Tidak ditemukan nilai kosong
Pemeriksaan data duplikat	Tidak ditemukan data duplikat
Penyeragaman format data	Nama kolom, nilai gejala, dan diagnosis diseragamkan
Transformasi nilai gejala	Ya = 1 dan Tidak = 0
Label encoding diagnosis	Dispepsia, GERD, dan Gastritis dikodekan sebagai kelas target

Pengujian dilakukan pada empat skenario pembagian data. Hasil evaluasi memperlihatkan bahwa seluruh skenario menghasilkan accuracy di atas 84%. Skenario 90:10 memperoleh accuracy tertinggi sebesar 89,80%, sedangkan skenario utama 80:20 menghasilkan accuracy 88,78% dengan precision 88,93%, recall 88,78%, dan F1-score 88,81%. Nilai ini menunjukkan bahwa LightGBM mampu menjaga keseimbangan antara ketepatan prediksi dan kemampuan mengenali setiap kelas.

Tabel 6. Hasil evaluasi model LightGBM pada setiap skenario

Skenario	Data Training	Data Testing	Accuracy	Precision	Recall	F1-Score
60:40	585	391	0,8568	0,8573	0,8568	0,8564
70:30	683	293	0,8430	0,8444	0,8430	0,8434
80:20	780	196	0,8878	0,8893	0,8878	0,8881
90:10	878	98	0,8980	0,8978	0,8980	0,8978

Performa numerik tertinggi diperoleh pada skenario 90:10 karena model mempelajari data latih yang lebih banyak. Namun, data uji pada skenario ini hanya 98 pasien, sehingga estimasi performanya lebih sensitif terhadap komposisi sampel. Skenario 80:20 menggunakan 196 data uji dan menghasilkan accuracy 88,78%, hanya 1,02 poin persentase lebih rendah daripada skenario 90:10. Oleh sebab itu, skenario 80:20 digunakan sebagai dasar analisis utama. Hasil tersebut kemudian dibandingkan dengan penelitian terdahulu pada Tabel 7.

Tabel 7. Perbandingan performa dengan penelitian terdahulu

Penelitian	Metode dan objek	Data/evaluasi	Akurasi	Catatan
Alfariqi [9]	C4.5; tiga penyakit lambung	450 data; 90:10	96,00%	Pohon keputusan tunggal
Febriani et al. [8]	Certainty Factor; penyakit lambung	Uji kesesuaian sistem	100,00%	Bukan evaluasi holdout ML
Ramadhan et al. [13]	SVM; GERD vs non-GERD	Data RS; kernel polynomial	82,50%	F1-score 58,30%
Penelitian ini	LightGBM; tiga kelas diagnosis	976 data; 80:20	88,78%	Default parameter; tanpa tuning

Classification report pada skenario 80:20 menunjukkan bahwa kelas GERD memperoleh precision tertinggi, yaitu 0,94, dengan recall 0,91 dan F1-score 0,92. Kelas Dispepsia memiliki recall 0,89, yang menunjukkan bahwa sebagian besar data Dispepsia dapat dikenali dengan baik oleh model. Kelas Gastritis memperoleh precision 0,89, recall 0,86, dan F1-score 0,88. Perbedaan nilai antarkelas relatif kecil sehingga model tidak hanya unggul pada satu kelas tertentu, tetapi juga mampu mempertahankan performa yang cukup seimbang pada tiga kelas penyakit.

Tabel 8. Classification report pada skenario 80:20

Kelas	Precision	Recall	F1-Score	Support
Dispepsia	0,84	0,89	0,86	64
GERD	0,94	0,91	0,92	67
Gastritis	0,89	0,86	0,88	65

Confusion matrix pada skenario 80:20 memberikan gambaran lebih rinci mengenai pola kesalahan model. Dari 64 data aktual Dispepsia, 57 data diprediksi benar, sedangkan 7 data lainnya salah diklasifikasikan sebagai GERD atau Gastritis. Pada kelas GERD, 61 dari 67 data diprediksi benar. Pada kelas Gastritis, 56 dari 65

data diprediksi benar. Jumlah prediksi benar mencapai 174 data dari total 196 data uji, sedangkan 22 data mengalami kesalahan prediksi.

Tabel 9. Confusion matrix model LightGBM pada skenario 80:20

Kelas Aktual	Prediksi Dispepsia	Prediksi GERD	Prediksi Gastritis	Total
Dispepsia	57	2	5	64
GERD	4	61	2	67
Gastritis	7	2	56	65
Total	68	65	63	196

Kesalahan klasifikasi paling banyak terjadi antara Dispepsia dan Gastritis. Hal ini dapat dijelaskan secara klinis karena kedua kondisi tersebut sama-sama sering menimbulkan keluhan pada area lambung, seperti nyeri ulu hati, mual, muntah, perut kembung, dan rasa cepat kenyang. Di sisi lain, GERD cenderung lebih mudah dikenali oleh model karena memiliki beberapa gejala yang lebih khas, seperti heartburn, regurgitasi, sakit tenggorokan, suara serak, dan mulut terasa pahit. Pola ini konsisten dengan nilai precision dan F1-score GERD yang lebih tinggi dibandingkan dua kelas lainnya.

Analisis feature importance menunjukkan bahwa mual memiliki nilai tertinggi, diikuti diare, muntah, anemia, dan gangguan tidur. Karena importance\_type yang digunakan adalah split, nilai pada Tabel 10 merepresentasikan frekuensi fitur dipilih sebagai pemisah pada seluruh pohon. Nilai tinggi tidak menunjukkan hubungan sebab-akibat, arah asosiasi, ataupun bahwa suatu gejala dapat digunakan secara tunggal untuk menegakkan diagnosis.

Interpretasi klinis memperlihatkan tingkat plausibilitas yang berbeda pada fitur anemia dan diare. Anemia merupakan alarm feature pada evaluasi pasien dengan dispepsia dan dapat berkaitan dengan gastritis atrofi melalui defisiensi zat besi atau vitamin B12 akibat penurunan sekresi asam lambung dan intrinsic factor [14], [15]. Karena itu, kontribusi anemia pada model memiliki dasar klinis, tetapi tetap memerlukan konfirmasi laboratorium dan endoskopi. Sebaliknya, diare bukan gejala kardinal gastritis maupun dispepsia. Nilai importance yang tinggi dapat mencerminkan pola koeksistensi atau overlap gangguan saluran cerna dalam dataset; studi Rome IV menemukan irritable bowel syndrome pada 26,1% responden yang memenuhi kriteria dispepsia fungsional [2]. Dengan demikian, fitur diare perlu diperlakukan sebagai prediktor statistik yang spesifik terhadap dataset, bukan penanda diagnostik mandiri.

Tabel 10. Sepuluh fitur gejala dengan nilai importance tertinggi

Peringkat	Fitur Gejala	Nilai Importance
1	Mual	1316
2	Diare	1204
3	Muntah	1168
4	Anemia	1088
5	Gangguan Tidur	1038
6	Nyeri Epigastrium	1028
7	Demam	1021
8	Nyeri Dada	988

Peringkat	Fitur Gejala	Nilai Importance
9	Mulut Terasa Pahit	938
10	Nafsu Makan Turun	937

Secara keseluruhan, LightGBM mampu mengolah fitur biner, menangkap interaksi antargejala, dan menghasilkan metrik yang relatif konsisten pada beberapa pembagian data. Dibanding pohon keputusan tunggal, pendekatan ensemble menggabungkan kontribusi banyak pohon sehingga lebih mampu memodelkan pola nonlinier [9]–[12]. Namun, perbandingan antarpublikasi pada Tabel 7 harus ditafsirkan secara hati-hati karena berbeda dalam sumber data, jumlah kelas, definisi target, skema validasi, dan penggunaan tuning. Akurasi 100% pada sistem Certainty Factor, misalnya, berasal dari pengujian kesesuaian aturan dan tidak ekuivalen langsung dengan evaluasi holdout pada model machine learning [8].

Model ini tetap merupakan sistem pendukung identifikasi awal, bukan pengganti diagnosis dokter. Dataset hanya memuat gejala dan berasal dari satu fasilitas kesehatan, sehingga generalisasi ke populasi lain belum dapat dipastikan. Validasi eksternal, evaluasi kalibrasi probabilitas, pemeriksaan potensi bias, serta penambahan variabel klinis seperti usia, riwayat penyakit, hasil laboratorium, dan endoskopi diperlukan sebelum implementasi layanan kesehatan.

## KESIMPULAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa:

- 1) LightGBM dengan parameter default dan tanpa hyperparameter tuning mampu mengklasifikasikan Dispepsia, GERD, dan Gastritis. Skenario utama 80:20 menghasilkan accuracy 88,78%, precision 88,93%, recall 88,78%, dan F1-score 88,81%; skenario 90:10 memperoleh accuracy tertinggi 89,80%.
- 2) Mual, diare, muntah, anemia, dan gangguan tidur merupakan fitur dengan frekuensi split tertinggi. Importance tersebut menunjukkan kontribusi statistik dalam model dan tidak dapat ditafsirkan sebagai hubungan kausal atau dasar diagnosis tunggal.
- 3) Pengembangan berikutnya perlu menerapkan stratified k-fold cross-validation dan hyperparameter tuning melalui GridSearchCV, RandomizedSearchCV, atau Bayesian Optimization, disertai validasi eksternal multisenter, perbandingan dengan algoritma lain, analisis SHAP, serta penambahan data demografis, laboratorium, dan endoskopi.

## DAFTAR PUSTAKA

- [1] J. S. Nirwan, S. S. Hasan, Z. U. Babar, B. R. Conway, and M. Ghori, "Global prevalence and risk factors of gastro-oesophageal reflux disease (GORD): Systematic review with meta-analysis," *Scientific Reports*, vol. 10, art. no. 5814, 2020, doi: 10.1038/s41598-020-62795-1.
- [2] J. Tack et al., "Functional dyspepsia and its subgroups: Prevalence and impact in the Rome IV Global Epidemiology Study," *Alimentary Pharmacology & Therapeutics*, vol. 62, no. 3, pp. 330–339, 2025, doi: 10.1111/apt.70189.
- [3] S. N. Fadilah and Y. Herdiana, "Nanoformulasi untuk pengobatan penyakit GERD," *Farmaka*, vol. 21, no. 3, pp. 389–398, 2023.

- [4] W. Widya, D. L. Badriah, L. Wahyuniar, and Mamlukah, "Faktor-faktor yang berhubungan dengan kejadian dispepsia pada pekerja di PT Hamsina Jaya MPPG Cirebon 2023," *Jurnal Ilmu Kesehatan Bhakti Husada: Health Sciences Journal*, vol. 14, no. 2, pp. 361–369, 2023, doi: 10.34305/jikbh.v14i02.924.
- [5] S. A. Khusna, V. N. Faridah, and T. P. Lestari, "Faktor penyebab terjadinya gastritis pada remaja di Puskesmas Deket Kabupaten Lamongan," *Jurnal Ilmiah Biosaintropis*, vol. 10, no. 1, pp. 90–96, 2024, doi: 10.33474/ejbst.v10i1.596.
- [6] M. D. Sinaga and A. A. Fajrin, "Sistem pakar diagnosa penyakit asam lambung pada orang dewasa menggunakan metode forward chaining berbasis web," *Jurnal Comasie*, vol. 7, no. 7, pp. 27–35, 2022.
- [7] M. A. Iswaniah, Purnawansyah, and S. H. Mansyur, "Sistem pakar pendiagnosa jenis penyakit asam lambung dengan metode Certainty Factor berbasis web (Studi kasus: RS Pelamonia)," *LINIER: Literatur Informatika dan Komputer*, vol. 2, no. 3, pp. 367–379, 2025.
- [8] H. A. Febriani, D. P. Wijaya, A. Pramuntadi, and W. D. Prastowo, "Sistem pakar diagnosa penyakit lambung menggunakan metode Certainty Factor berbasis web," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 4, pp. 1290–1300, 2024, doi: 10.57152/malcom.v4i4.1402.
- [9] I. Alfariqi, "Penerapan algoritma C4.5 untuk klasifikasi penyakit lambung," Skripsi, Program Studi Teknik Informatika, Universitas Islam Negeri Sultan Syarif Kasim Riau, Pekanbaru, Indonesia, 2021.
- [10] G. Ke, Q. Meng, T. Finley, T. Wang, W. Chen, W. Ma, Q. Ye, and T.-Y. Liu, "LightGBM: A highly efficient gradient boosting decision tree," in *Advances in Neural Information Processing Systems 30*, Long Beach, CA, USA, 2017, pp. 3146–3154.
- [11] D. D. Rufo, T. G. Debelee, A. Ibenthal, and W. G. Negera, "Diagnosis of diabetes mellitus using gradient boosting machine (LightGBM)," *Diagnostics*, vol. 11, no. 9, art. no. 1714, 2021, doi: 10.3390/diagnostics11091714.
- [12] R. R. Rachmadi, A. Sudarsono, and T. B. Santoso, "Implementasi metode LightGBM untuk klasifikasi kondisi abnormal pada pengemudi sepeda motor berbasis sensor smartphone," *Jurnal Komputer Terapan*, vol. 7, no. 2, pp. 218–227, 2021, doi: 10.35143/jkt.v7i2.5164.
- [13] T. F. Ramadhan, Asrianda, and Risawandi, "Penerapan metode algoritma SVM (Support Vector Machine) untuk klasifikasi penderita penyakit Gastroesophageal Reflux Disease," *RABIT: Jurnal Teknologi dan Sistem Informasi Univrab*, vol. 10, no. 2, pp. 1212–1219, 2025, doi: 10.36341/rabit.v10i2.6466.
- [14] P. Moayyedi et al., "ACG and CAG clinical guideline: Management of dyspepsia," *The American Journal of Gastroenterology*, vol. 112, no. 7, pp. 988–1013, 2017, doi: 10.1038/ajg.2017.154.
- [15] S. C. Shah, M. B. Piazuelo, E. J. Kuipers, and D. Li, "AGA clinical practice update on the diagnosis and management of atrophic gastritis: Expert review," *Gastroenterology*, vol. 161, no. 4, pp. 1325–1332.e7, 2021, doi: 10.1053/j.gastro.2021.06.078.